UNIVERSIDAD DE JAÉN

ESCUELA POLITÉCNICA SUPERIOR
DEPARTAMENTO DE INGENIERÍA CARTOGRÁFICA, GEODÉSICA Y FOTOGRAMETRÍA

TESIS DOCTORAL

AUTOMATIZACIÓN DE LOS PROCESOS DE SEGMENTACIÓN Y CLASIFICACIÓN DE VÍAS DE COMUNICACIÓN EN GENERALIZACIÓN CARTOGRÁFICA

PRESENTADA POR:
JOSÉ LUIS GARCÍA BALBOA

DIRIGIDA POR:
DR. D. FRANCISCO JAVIER ARIZA LÓPEZ

JAÉN, 28 DE ABRIL DE 2006

ISBN 978-84-8439-364-1

Nombre y apellidos del autor

José Luis García Balboa

Título de la Tesis Doctoral

Automatización de los procesos de segmentación y clasificación de vías de comunicación en generalización cartográfica

I.S.B.N.

978-84-8439-364-1

Fecha de Lectura

28 de Abril de 2006

Centro y Departamento en que fue realizada la lectura

Escuela Politécnica Superior

Departamento de Ingeniería Cartográfica, Geodésica y Fotogrametría

Composición del Tribunal/Dirección de la Tesis

Dirección de la Tesis	Dr. D. Francisco Javier Ariza López
Presidente/a del Tribunal	Dr. D. Manuel Sánchez de la Orden
Vocales	Dr. D. Luis Alfonso Ureña López
	Dr. D. Lucio Colaiacomo
	Dr. D. Javier Iribas Cardona
Secretario/a	Dr. D. Tomás Fernández del Castillo

Calificación Obtenida

Sobresaliente Cum Laude por Unanimidad

Universidad de Jaén

tesis doctoral

Resumen

La tesis doctoral está centrada en la automatización de dos procesos que han sido apuntados por diferentes expertos como necesarios para mejorar la generalización cartográfica de elementos lineales: su segmentación en secciones homogéneas y la clasificación de cada una de ellas. El ámbito del estudio se centra en las vías de comunicación del Mapa Topográfico Nacional 1:25 000, como fuente de partida para derivar escalas menores como la 1:50 000 o la 1:100 000.

Para el proceso de segmentación automática se han concebido, desarrollado y analizado tres técnicas diferentes: a) integración de áreas efectivas fundamentada en el algoritmo de Visvalingam, b) filtrado wavelet en un espacio longitud,curvatura y c) aplicación de una red neuronal artificial que distingue variaciones de sinuosidad y direccionalidad. Para cada una de ellas se ha realizado una propuesta de valores para su aplicación.

Para el proceso de clasificación automática se ha propuesto, a partir de un análisis de resultados con distintas estructuras, un modelo de red neuronal artificial que se alimenta de un conjunto de medidas cuantitativas (seleccionadas mediante un análisis de componentes principales) y de información cualitativa. Para el entrenamiento y validación de la red se ha dispuesto de una muestra de secciones, derivada de un proceso de segmentación semiautomática, clasificada manualmente en cinco clases que atienden a variaciones de sinuosidad y direccionalidad.

Todos los resultados, tanto de las técnicas de segmentación como de la clasificación mediante la red neuronal artificial, han sido sometidos a un análisis externo por parte de un panel de expertos nacionales e internacionales. La valoración ha sido muy positiva para la segmentación y clasificación que se ha utilizado para entrenar la red neuronal, lo que respalda el entrenamiento efectuado para ésta. El resto de técnicas de segmentación también han sido bien valoradas.

Abstract

This research is centered on the automation of two processes which have been referred by different experts as a necessity for the progress in cartographic line generalization: the segmentation into homogeneous sections and the classification of each of these sections. The scope of the study is the road lines of the Mapa Topográfico Nacional (National Topographic Map) at 1:25 000 scale, as a source for deriving smaller scales as 1:50 000 or 1:100 000.

In relation to the process of automated segmentation three different techniques have been conceived, developed and analyzed: a) efective areas integration based on the Visvalingam algorithm, b) wavelet filtering in a length, curvature space and c) application of an artificial neural network which identifies changes in sinuosity and directionality. A set of parameter values have been proposed for each technique.

In relation to the process of automated classification a model of artificial neural network has been proposed. The input of this neural network is a set of quantitative measures (selected by means of a principal components analysis) and qualitative data. Results with different structures have been analyzed. The training and validation of the network has been performed with a set of classified sections. The segmentation is semiautomated and the classification is manual, which identifies five classes which take into account changes in sinuosisy and directionality.

All the results, those from the segmentation techniques and those of the classification by means of the artificial neural network, have been analyzed by an external set of national and international experts. The segmentation and classification used for the neural network training has been valuated very positively, which support this training. The remaining segmentation techniques have also been well valuated.



UNIVERSIDAD DE JAÉN

AUTOMATIZACIÓN DE LOS PROCESOS DE SEGMENTACIÓN Y CLASIFICACIÓN DE VÍAS DE COMUNICACIÓN EN GENERALIZACIÓN CARTOGRÁFICA

JOSÉ LUIS GARCÍA BALBOA

tesis doctoral

A Cinta

A mis padres

A mis hermanos

"Los criterios de le evidencia son rigurosos. Pero, si los seguimos, nos permiten ver muy lejos, siendo incluso capaces de iluminar una profunda oscuridad"

Carl Sagan

Agradecimientos

En primer lugar quiero dar las gracias a mi director de tesis, el profesor Francisco Javier Ariza López, que me sugirió esta línea de investigación y que mostró en todo momento su confianza en mí para la consecución de este trabajo. Le agradezco lo que me ha enseñado durante tanto tiempo que me ha dedicado, desde que era estudiante de último curso, así como su apoyo y continua disponibilidad. Espero que en el futuro podamos seguir colaborando desde la confianza y amistad que nos une.

Además, quisiera mostrar mi agradecimiento a todos aquellos que, de alguna u otra manera, han colaborado para que este trabajo viera su fin:

- *Todas aquellas personas de otras universidades y de instituciones españolas y europeas, que colaboraron en la evaluación de los resultados de la tesis. Su aportación ha sido fundamental en este trabajo.*
- *Al personal de la Diputación de Jaén y de la Delegación de Jaén de la Consejería de Obras Públicas y Transportes que tan amablemente me proporcionaron información sobre los proyectos de trazado de vías de comunicación.*
- *Al Dr. Rafael López Luque, por su contribución en la concepción del método de clasificación automática mediante red neuronal artificial.*
- *A Juan Francisco Reinoso Gordo, amigo y compañero con el que comparto línea de investigación en generalización de elementos lineales, por sus sugerencias para mejorar el presente documento.*
- *A mis compañeros y compañeras de mi Departamento, en especial a: Marina Cruz Rodríguez, Antonio Tomás Mozas Calvache, Tomás Fernández del Castillo, Antonio Garrido Almonacid, José Luis Mesa Mingorance y Manuel Antonio Ureña Cámara, por su colaboración en la evaluación de resultados, a Jorge Delgado García y Pedro J. Castro Guzmán por facilitarme bibliografía, y a María Isabel Ramos Galán por su apoyo y amistad.*

- *A Antonio M. Ruiz Armenteros, inestimable amigo y compañero de asignatura, con el que la docencia se convierte en una actividad más grata, por su continuo ánimo, y por haber tenido paciencia durante aquellos momentos en los que no pude colaborar con él todo lo que hubiera querido. Espero poder devolverle el favor. También gracias a Vanesa.*
- *A Alan D. J. Atkinson Gordo, por su gran amistad y apoyo.*
- *A todos los amigos y familiares con los que no pude estar más tiempo, y que siempre supieron comprenderme y alentarme.*

Por supuesto, no quiero olvidarme de mi familia. Agradezco a mis padres su cariño y ánimo durante toda mi vida, así como su generosidad. También a María y Samuel, por los buenos ratos que pasamos, porque aunque ellos no lo crean, no siempre estaba estudiando.

Por último, mi especial agradecimiento a Cinta, la que más ha sufrido este trabajo, por su paciencia por tanto tiempo que yo no le pude dedicar y que ella sí me dedicó, por su cariño, aliento y comprensión en los momentos difíciles.

Índice

I. INTRODUCCIÓN 11

II. ANTECEDENTES 19
II.1. LA GENERALIZACIÓN CARTOGRÁFICA 20
II.1.1. Necesidad de la generalización 21
II.2. AUTOMATIZACIÓN DE LA GENERALIZACIÓN 26
II.2.1. Generalización manual vs generalización automática 26
II.2.2. Necesidad de formalizar el conocimiento 28
II.2.3. Generalización y S.I.G. 29
II.2.4. Investigación y desarrollo 30
II.3. MODELOS CONCEPTUALES DE GENERALIZACIÓN 33
El modelo de Ratajski 33
El modelo de Morrison 34
El modelo de Brassel y Weibel 35
El Modelo Conceptual Comprensivo de McMaster y Shea 35
Modelos basados en constreñimientos. El proyecto AGENT 40
II.4. CONTROL Y EVALUACIÓN DE LA GENERALIZACIÓN 45
II.5. GENERALIZACIÓN DE ELEMENTOS LINEALES 52
II.5.1. Representación de una línea en el entorno digital 53
II.5.2. Caracterización de la forma de una línea 55
II.5.2.1. La matriz distancia-dirección 57
II.5.2.2. La dimensión fractal 57
II.5.2.3. Medida de entropía 61
II.5.2.4. Medidas geométricas 63
II.5.2.5. La detección de curvas de Wang y Müller 69
II.5.3. Algoritmos de eliminación de puntos 71
II.5.3.1. Clasificaciones de los algoritmos 74
II.5.3.2. Algoritmo de Douglas-Peucker 76
II.5.3.3. Algoritmo de Visvalingam 78
II.5.3.4. Algoritmo de Thapa 83
II.5.4. Algoritmos de filtrado de curvatura 88
II.5.4.1. Filtrados por convolución espacial 90

II.5.4.2. Aproximaciones matemáticas 93
Curvas paramétricas cúbicas 94
Arcos cúbicos 95
II.5.4.3. Filtrados en el dominio de la frecuencia 99
Series de Fourier 100
Wavelets 102
II.5.5. Algoritmos de caricaturización 113
II.5.6. Evaluación de la generalización 116
II.6. SEGMENTACIÓN DE ELEMENTOS LINEALES 121
II.6.1. Necesidad de la segmentación 121
II.6.2. Segmentación mediante algoritmos de eliminación de puntos 123
II.6.3. Segmentación jerárquica mediante puntos de inflexión 126
II.6.4. Segmentación a partir de cruces con la línea de tendencia 132
II.6.5. Segmentación mediante la dimensión fractal 133
II.6.6. Empleo de wavelets 137
II.7. REDES NEURONALES 139
II.7.1. Conceptos de Neurona y Neurona Artificial 142
II.7.1.1. La neurona biológica 142
II.7.1.2. La neurona artificial 144
II.7.2. Características de una Red Neuronal Artificial (RNA) 147
II.7.2.1. Topología o arquitectura 147
II.7.2.2. Mecanismo de aprendizaje 148
II.7.2.3. Tipo de asociación realizada entre la información de entrada y la de salida 150
II.7.2.4. Forma de representación de las informaciones de entrada y de salida 151
II.7.3. La red Backpropagation 151
II.7.3.1. Funcionamiento de la red Backpropagation 152

III. MATERIAL Y METODOLOGÍA 156
III.1. INTRODUCCIÓN 157
III.2. MUESTRA DE ELEMENTOS LINEALES 162
III.2.1. Selección de la fuente 162
III.2.2. Selección de la muestra 164
III.2.2.1. Normativas de diseño de las vías de comunicación 170

III.2.3. Tratamiento previo 175
III.3. SEGMENTACIÓN MEDIANTE ALGORITMOS 176
III.3.1. Método de las áreas efectivas 177
III.3.1.1. Preparación del espacio de áreas efectivas 179
III.3.1.2. Detección de secciones mediante Douglas-Peucker 181
III.3.2. Método de Thapa Bidireccional Recursivo 183
III.3.3. Método del filtrado wavelet de la curvatura 185
III.4. CLASIFICACIÓN AUTOMÁTICA DE SECCIONES 188
III.4.1. Muestra de secciones para la experimentación 189
III.4.1.1. Segmentación 189
III.4.1.2. Clasificación 191
Método de clasificación 191
Número de clases 191
III.4.2. Selección de medidas caracterizadoras 193
III.4.2.1. Análisis multivariable 194
Análisis de componentes principales 194
III.4.2.2. Conjunto de medidas caracterizadoras 196
III.4.3. Clasificación mediante una red neuronal 200
III.4.3.1. Capa de entrada 201
Información cuantitativa procedente de las medidas caracterizadoras 202
Información cualitativa, según el tipo de red de carreteras 203
III.4.3.2. Capas ocultas 204
III.4.3.3. Capa de salida 204
III.4.3.4. Función de transferencia de las neuronas 205
III.4.3.5. Aprendizaje de la red 205
III.4.3.6. Implementación de la red neuronal 208
III.4.4. Resumen del proceso para la creación de la red neuronal 209
III.5. SEGMENTACIÓN MEDIANTE LA RED NEURONAL 211
III.6. EVALUACIÓN VISUAL DE LOS RESULTADOS 213
III.6.1. Evaluación durante el desarrollo de los trabajos 214
III.6.1.1. Criterios para el análisis visual 215
Evaluación de los procesos de segmentación 217
Evaluación del proceso de clasificación 217
III.6.2. Evaluación final de resultados por un panel de expertos 218

III.6.2.1. Panel de expertos 219
III.6.2.2. Diseño de la prueba 221

IV. RESULTADOS 228
IV.1. SEGMENTACIÓN MEDIANTE ÁREAS EFECTIVAS 230
IV.1.1. Determinación del parámetro σ 230
IV.1.2. Determinación del parámetro L 234
IV.1.3. Ajuste del parámetro DP 235
IV.2. SEGMENTACIÓN MEDIANTE WAVELETS 239
IV.2.1. Estudio de los parámetros de control 239
IV.3. ENTRENAMIENTO Y VALIDACIÓN DE LA RED NEURONAL PARA LA CLASIFICACIÓN AUTOMÁTICA DE SECCIONES 243
IV.3.1. Preparación de la muestra de secciones homogéneas y clasificadas 244
IV.3.1.1. Segmentación semiautomática 244
IV.3.1.2. Clasificación de las secciones 245
IV.3.2. Análisis de Componentes Principales de las medidas caracterizadoras 249
IV.3.2.1. Primer ACP 249
IV.3.2.2. Segundo ACP. Interpretación de componentes 252
IV.3.2.3. Análisis de correlaciones. Selección definitiva de variables 254
IV.3.3. Red Neuronal de clasificación de líneas 256
IV.3.3.1. Creación de los patrones de entrenamiento y prueba 256
IV.3.3.2. Estructura y aprendizaje de la red neuronal 257
Resultados del aprendizaje 259
IV.3.3.3. Validación de las redes neuronales 262
Análisis de los resultados sobre las distintas arquitecturas 271
Análisis de los resultados sobre los distintos patrones 274
IV.3.3.4. Re-entrenamiento de la red de 3 neuronas ocultas 280
Elección de un aprendizaje de la validación cruzada 284
IV.4. SEGMENTACIÓN MEDIANTE LA RED NEURONAL ARTIFICIAL 288
IV.5. EVALUACIÓN POR EXPERTOS 289
IV.5.1. Resultados bajo análisis 289
IV.5.2. Panel de expertos 292
IV.5.3. Análisis global 297

IV.5.4. Análisis por línea 299
IV.5.5. Análisis por categorías de líneas 302
IV.5.6. Conclusiones de la evaluación de expertos 306

V. CONCLUSIONES 309

REFERENCIAS 315

ANEXOS 336
A. Gráficas de evolución del nº de secciones de cada línea de la muestra con el parámetro dp 337
B. Trazados de la segmentación mediante wavelets 345
C. Gráficas de error del entrenamiento de las redes neuronales 346
D. Trazados de la segmentación mediante la red neuronal 357
E. Resumen de respuestas en la evaluación por el panel de expertos 362
F. Normativa sobre carreteras 375
G. Empleo del programa JavaNNS 381

ÍNDICE DE FIGURAS 388

ÍNDICE DE TABLAS 394

Capítulo I
Introducción

Un mapa puede definirse como una "representación en tamaño menor y en una superficie plana de parte o la totalidad de la superficie terrestre" (Robinson *et al*., 1984). Pero un mapa no puede representar toda la realidad (en este caso sería una fotografía), sino parcialidades de ella, como puede verse en el ejemplo de la Figura I.1. Sólo hará referencia a aquello que el cartógrafo considere importante para el uso y el usuario para el que ha sido elaborado, tratando de favorecer siempre la claridad y la comunicación de la información, sirviéndose para ello de una sólida formación tanto cartográfica como geográfica adquirida con anterioridad. En otras palabras, está empleando la generalización en el proceso de producción cartográfica.

Por tanto, la generalización cartográfica existe desde el instante en que fue elaborada la primera representación cartográfica, ya que los conceptos de mapa y generalización van íntimamente ligados. El cartógrafo se sirve de ella para extraer y enfatizar lo esencial mientras se suprime lo superfluo, reducir la complejidad del mapa en el proceso de reducción de escala, mantener las relaciones lógicas e inequívocas entre los elementos representados y para preservar la calidad estética y la exactitud tanto como sea posible (Weibel, 1995a; Weibel y Jones, 1998). El conseguir todos estos objetivos no es una tarea fácil, de hecho, la generalización, y su automatización, tal vez sea el proceso cartográfico más complejo al que deba enfrentarse el cartógrafo. Reveladoras son las palabras de Hangouet (1998): "El mapa es una imitación de la realidad, la generalización manual es una imitación del mapa, la generalización automática es una imitación de la generalización manual; luego la generalización automática es una imitación de una imitación de una imitación del terreno".

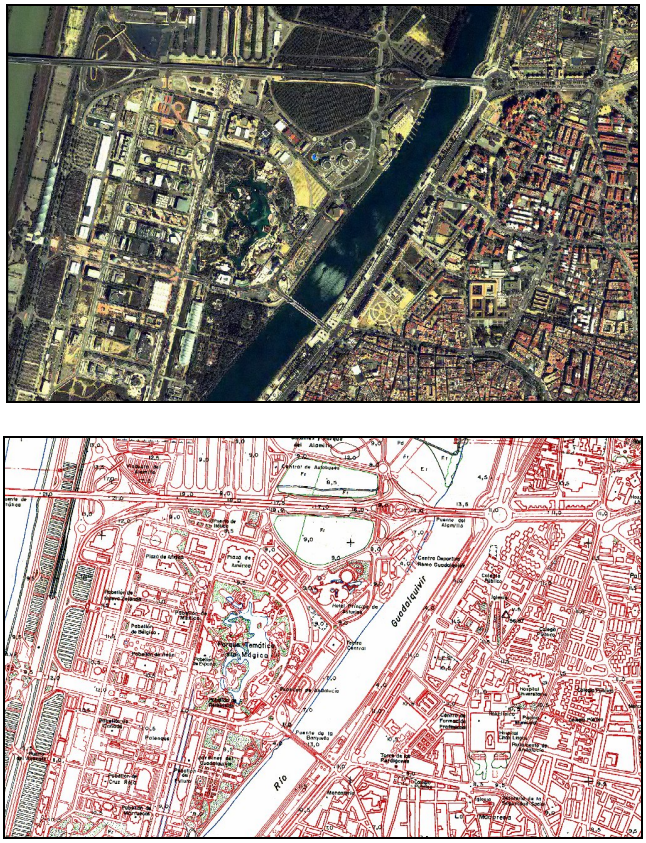


Figura I.1 - Fotografía aérea de parte de la ciudad de Sevilla (arriba) y cartografía derivada de la misma (abajo).

Es evidente que automatizar un proceso tan complejo traería consigo muchas ventajas en los procesos de producción cartográfica. En primer lugar se otorgaría mayor objetividad y repetitividad al resultado final. Pero no menos importante, se reduciría el tiempo necesario para obtenerlo; en algunos casos se necesita un producto inmediato, como es el caso de la cartografía a demanda en internet, en la que el usuario puede requerir distintos niveles de detalle, y por tanto de generalización; en otros casos, la inmediatez no es un requisito, pero sí la celeridad suficiente para derivar productos a partir de una misma base de datos. Un ejemplo de esto último es la producción en España del Mapa Topográfico Nacional 1:50 000 (MTN50) por generalización del Mapa Topográfico Nacional 1:25 000 (MTN25) (Urteaga y Nadal, 2001, pp. 157, 158; Iribas, 1997, 1999), pero también podría pensarse en la obtención de productos a escala menor (1:100 000, 1:200 000, etc.) a partir de la misma fuente que da origen al MTN25, con las ventajas económicas que ello conlleva. Dejando a un lado el proceso de producción cartográfica en su sentido más estricto, la generalización

también es imprescindible para un correcto manejo de los Sistemas de Información Geográfica (S.I.G.), en cualquier tarea de análisis de información espacial, que se realiza a un nivel de resolución determinado. Dentro del contexto digital, mucho más simple es la generalización del modelo (o de la base de datos), que tiene que ver con la resolución de los datos almacenados, pero sin ningún tipo de enfoque visual, sin la complejidad que entraña la representación cartográfica.

Esta misma complejidad que refuerza la necesidad de automatizar el proceso de generalización es la que ha dificultado el desarrollo de soluciones válidas que permitan relegar totalmente a la generalización manual. Desde el comienzo, esto llevó a la división del problema en diferentes partes, y por tanto en diferentes metas a alcanzar, para luego tratar de aunar todo en una solución global. Así, las investigaciones realizadas han ido centrándose en aspectos particulares del proceso de generalización, buscando soluciones para un tipo de operación concreta (simplificación, desplazamiento, etc.) sobre un tipo concreto de elemento (líneas de costa, vías de comunicación, cascos urbanos, etc.), pero sin ir más allá. Como en otras ramas científicas, la rápida evolución de la informática ha tenido una gran influencia en el desarrollo de la investigación. Así, las soluciones automáticas obtenidas han sido cada vez más completas y complejas, y de hecho las desarrolladas en los últimos años permiten un verdadero acercamiento a una solución global y completa de una base de datos geográfica.

No obstante, estos sistemas globales de generalización pueden controlar y armonizar distintas operaciones más simples, fruto de todas las investigaciones previas. De hecho, un requisito para la mejora de estos sistemas es el avance en tareas más sencillas, buscando la mejora o el desarrollo de nuevos algoritmos, o bien mejorando su aplicación sobre los diferentes elementos de la base de datos, desarrollando medidas que permitan controlar y evaluar el proceso de generalización, etc. Esto da pie a trabajos como el de esta tesis doctoral, centrada en una parte necesaria del proceso de generalización, como es el enriquecimiento de la información disponible de los elementos que se pretende generalizar.

Tradicionalmente, ha sido sobre los elementos lineales sobre los que ha recaído la mayor parte del esfuerzo por parte de los equipos de investigación, dado que se estima que la mayor parte de elementos de un mapa es de tipo lineal (considerando que un elemento superficial viene delimitado por una línea cerrada). Existen multitud de tratamientos específicos para la línea (los llamados algoritmos de simplificación, de suavizado, etc.), sin embargo todavía existe un amplio desconocimiento frente al tratamiento temático de las mismas. Es decir, a pesar de la multitud de algoritmos existentes para el tratamiento de líneas, no existe un conocimiento preciso de la idoneidad de unos algoritmos frente a otros a la hora de tratar distintos tipos de líneas.

De esta forma, tras esta breve presentación, queda justificado el trabajo que se pretende con esta tesis doctoral. Se persigue avanzar en el enriquecimiento de la información disponible para los elementos lineales formados por las vías de comunicación (carreteras y caminos), como paso previo para la mejora en la aplicación de los algoritmos existentes. Como se concretará a continuación en los objetivos pretendidos en este trabajo, este enriquecimiento se va a desarrollar mediante una doble tarea, que parte del hecho de la falta de homogeneidad de un elemento según su sinuosidad: primeramente mediante la búsqueda de técnicas de segmentación de un elemento lineal no homogéneo en secciones más homogéneas; en segundo lugar, desarrollando un método automático de clasificación de un elemento lineal, o una de sus secciones.

I.1. HIPÓTESIS DE PARTIDA Y OBJETIVOS

Para fijar las hipótesis de partida que sustentarán esta tesis doctoral, primeramente se asume que la investigación se enmarca dentro de los siguientes supuestos:

- La automatización de la generalización cartográfica es un objetivo alcanzable y necesario.
- Como parte del proceso global de generalización, la relativa a elementos lineales del mapa es primordial.

- La segmentación de elementos lineales y su caracterización es un paso previo y esencial para una mejor aplicación de las técnicas de generalización a este tipo de elementos
- Existe la necesidad de indagar sobre la adecuación de los algoritmos de generalización de elementos lineales al tipo de línea y a la escala final.

Las hipótesis de partida son las siguientes:

- La variación de sinuosidad de un elemento lineal permite su segmentación en secciones más homogéneas.
- Se puede automatizar la segmentación de un elemento lineal en función de su sinuosidad, emulando la realizada por un experto humano.
- Existen, y pueden detectarse, medidas que permiten enriquecer una sección de línea para su posterior clasificación automática.
- La clasificación de una sección de línea según su sinuosidad puede automatizarse, emulando la realizada por un experto humano.

Asumiendo estas hipótesis de partida, el objetivo general de este trabajo será ofrecer soluciones para la automatización de la tarea de segmentación y clasificación de elementos lineales. Como objetivos más específicos cabe señalar:

- Proponer, programar y analizar los resultados de nuevas técnicas de segmentación automática de elementos lineales en secciones homogéneas.
- Detectar un conjunto de medidas caracterizadoras incorreladas de un elemento lineal, o de sus secciones, para el enriquecimiento de éste.
- Proponer y ensayar un modelo de red neuronal artificial que permita la clasificación automática de un conjunto de secciones de línea.
- Someter los resultados obtenidos, tanto sobre segmentación como clasificación, a un análisis externo por parte de un panel de expertos en la materia.

Además, es necesario concretar el ámbito de la investigación, entendiendo éste como el tipo de información geográfica sobre el que se desarrollará, para facilitar

su posterior generalización para derivar una escala menor. De esta forma, el ámbito quedará fijado por las vías de comunicación (carreteras y caminos) a escala 1:25 000, fijando el cambio de escala objetivo en el 1:25 000 - 1:50 000.

Este cambio de escala es de especial relevancia en nuestro país, debido a la existencia de dos grandes series cartográficas a estas escalas, en la que la segunda se deriva por generalización de la primera. La elección de un tipo concreto de elementos lineales es necesaria por las grandes diferencias existentes entre los distintos tipos, como hipsografía o hidrografía, que provocaría resultados dispares en las investigaciones que pudieran realizarse. A favor de las vías de comunicación se puede decir que son de captura inequívoca en el proceso de producción del mapa y de especial interés en cualquier tipo de cartografía.

I.2. ORGANIZACIÓN DE ESTE DOCUMENTO

El resto del presente documento se estructura según los capítulos y orden propios de un trabajo de investigación: antecedentes, material y metodología, resultados y conclusiones, a los que se añade un capítulo con las referencias bibliográficas utilizadas y una serie de anexos que complementan diferentes capítulos del documento. A continuación se entra más en detalle sobre el contenido de los principales capítulos:

- Capítulo II. Antecedentes. Aquí se resume la bibliografía más relevante que ha sido consultada por el doctorando para conocer el estado de la cuestión y qué recursos podrían utilizarse para el desarrollo del trabajo. Se centra en lo relativo a la automatización de la generalización, haciendo hincapié en los elementos lineales y en las tareas de segmentación de éstos. Además se dedica un apartado a las redes neuronales artificiales.
- Capítulo III. Material y metodología. Primeramente, y relativo al material, se plantea la selección de una muestra de elementos lineales para efectuar los trabajos. A continuación se expone qué metodologías de segmentación mediante algoritmos se ensayarán y cómo se planteará una herramienta de clasificación automática de secciones mediante una red neurona artifi-

cial. Finalmente se plantea la metodología para la evaluación de los resultados mediante un panel de expertos.

- Capítulo IV. Resultados y discusión. En distintos apartados se presentan los resultados obtenidos en la aplicación de las distintas metodologías de segmentación y clasificación planteadas en el capítulo anterior. Así, este capítulo presenta los resultados según el siguiente orden: segmentación automática mediante áreas efectivas; segmentación mediante wavelets; entrenamiento y validación de la red neuronal para la clasificación automática de secciones; segmentación mediante la red neuronal; evaluación de resultados por expertos.
- Capítulo V. Conclusiones. Aquí se indica el grado de consecución de los objetivos planteados, se realizan recomendaciones generales y se plantea cómo podría darse continuación al trabajo desarrollado.

Capítulo II
Antecedentes

II.1. CONCEPTO DE GENERALIZACIÓN CARTOGRÁFICA

En cartografía la generalización retiene la noción de abstracción y extracción de los principios generales importantes, de forma similar a otras disciplinas, pero se extiende desde el dominio puramente semántico, hasta el espacial (y posiblemente temporal) (Weibel y Jones, 1998). Algunas definiciones del concepto de generalización cartográfica son las siguientes:

- "Modificación del detalle del mapa al disminuir la escala" (Schuurman, 1999).
- "Mantenimiento de la comunicación significativa de un fenómeno del mundo real durante las transiciones desde una escala o tema hasta otro" (Ormsby y Mackaness, 1999).
- "Proceso que intenta retener las características geográficas más importantes mientras al mismo tiempo reduce la complejidad de los fenómenos del mundo real representados" (Jaakkola, 1998, p. 195)
- "Ciencia (y arte) de exagerar los aspectos que son importantes para un propósito y escala particulares, y de eliminar los detalles irrelevantes que saturarían el mapa y confundirían al usuario" (Hardy, 1998, p. 187)
- "Proceso que trata de simplificar el contenido de la información de los datos geográficos al mismo tiempo que retiene el significado esencial inherente a los datos iniciales" (Ruas, 1998).
- "Consiste esquemáticamente en seleccionar los elementos a ser mantenidos a la escala deseada, simplificar las características irrelevantes, ensalzar las formas significativas, desplazar sin deformar las formas locales y globales y finalmente armonizar el aspecto final" (Plazanet, 1997).

En suma, lo dicho en las definiciones anteriores puede comprobarse en el proceso de generalización dado por la Figura II.1. El objetivo principal es crear mapas de elevada claridad gráfica, de forma que su imagen sea fácilmente percibida y el mensaje que se pretende difundir sea entendido sin dificultad (Weibel, 1995a). Para Richardson y Mackaness (1999), "la actividad de la generalización es una de las piedras angulares implicadas en el diseño cartográfico (...) La realidad física de nuestro mundo es abstraído y comprimida tanto gráficamente como semánticamente (...) de forma análoga a la caricatura en la que ciertas características son enfatizadas y otras no".

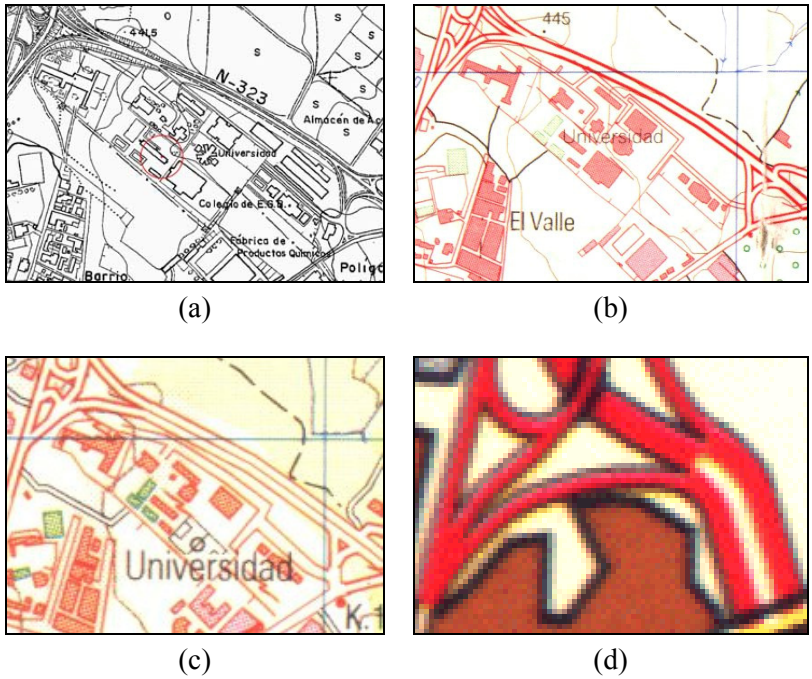


Figura II.1 - Cartografía de la zona de la Universidad de Jaén a distintas escalas:
a) Hoja 947-1-2, Mapa Topográfico de Andalucía 1:10 000 (ICA[1], 1996)
b) Hoja 947-I, Mapa Topográfico Nacional 1:25 000 (IGN[2], 1997)
c) Hoja 947, Mapa Topográfico Nacional 1:50 000 (IGN, 1999)
d) Mapa oficial de carreteras de Andalucía, Serie provincial 1:200 000, Jaén (ICA, 2003)

II.1.1. Necesidad de la generalización

La falta de acuerdo respecto de la necesidad de la generalización hace recordar las concluyentes palabras de Iribas (1997): "Es imprescindible si se pretenden realizar importantes saltos de escala, pero esto no es tan evidente cuando el cambio de escala es pequeño, sobre todo con la tendencia actual a sobrecargar

[1] ICA, Instituto de Cartografía de Andalucía.

de información los mapas". No obstante, esta necesidad se ha hecho cada vez más evidente y la necesidad de automatizarla ha sido totalmente asumida (Jaakkola, 1998, p. 195). Así, esta automatización ha sido objeto de estudio, a través de intensos esfuerzos, por parte de investigadores en los sectores público y privado, cobrando esta rama de investigación y desarrollo mayor interés, a la vez que aumenta el empleo, en los más diversos ámbitos de nuestra sociedad, de los sistemas cartográficos digitales y sobre todo los S.I.G. Una evidencia de este hecho es que la Asociación Cartográfica Internacional decidiera crear una comisión específica (ICA Comission on Map Generalization), donde los expertos en la materia comparten y discuten sus últimas investigaciones, celebrando reuniones anualmente y difundiendo sus resultados.

Son múltiples los argumentos que refrendan la esencialidad de este proceso en la producción cartográfica. Para Müller (1991) existen cuatro motivos básicos:

- *Requerimientos económicos*: Desde un primer momento los datos son filtrados en el propio proceso de toma, que depende directamente de la disponibilidad económica y tecnológica. Por tanto la generalización comienza ya en este paso, ya que sólo se pueden conocer parcialidades de la realidad.
- *Necesidad de datos robustos*: El error es un componente intrínseco en casi todas las bases de datos, introducido desde la recogida de datos y en cada proceso que se lleva a cabo sobre los mismos. La generalización se muestra como la herramienta que permite filtrar los errores y consolidar las tendencias.
- *Requerimientos multipropósito*: El concepto de múltiple uso impera lógicamente en todas las instituciones cartográficas. La generalización permite obtener cartografía a una escala menor a partir de una misma base de datos.
- *Requisitos de visualización y comunicación*: Es el motivo más conocido. Con el propósito de conseguir una mayor claridad gráfica, la generalización evita que se produzcan efectos no deseados como colisiones o coalescencias que dificultarían la interpretación y la función comunicativa del mapa.

[2] IGN, Instituto Geográfico Nacional

Además, una de las fundamentales metas de la generalización es la creación de bases de datos independientes de la escala. Éstas ofrecerían la posibilidad de almacenar una única base de datos con todos los datos necesarios para la elaboración de mapas con distinta escala o de temática diferente. Para la elaboración de cada uno de ellos se recurriría a distintas herramientas de generalización y filtrado, siempre que el resultado sea de calidad. En la actualidad se elabora una base de datos distinta para cada versión de un mismo mapa a distinta escala debido a que los datos procedentes de un mapa a escala mayor son excesivos o a que su propósito es diferente. Esto ocasiona diversos problemas (Weibel, 1995a):

- Redundancia de datos, pérdida de tiempo y de dinero, sobre todo a la hora de proceder a la actualización de los datos, que la sociedad demanda cada vez con mayor rapidez.
- Inconsistencias al actualizar múltiples bases de datos dependientes de la escala.
- Si es necesario aplicar la generalización sobre una de estas bases de datos, la falta de herramientas adecuadas puede hacer necesaria una edición interactiva e incluso la redigitalización.

Como ejemplo, en España el Instituto Geográfico Nacional está aplicando la generalización para derivar la serie a escala 1:50 000 a partir de la serie 1:25 000 (ver Iribas, 1999), sirviendo de ejemplo las figuras II.2 y II.3. Otro ejemplo es la obtención de la Cartografía Topográfica 1:10 000 y de la Base Topográfica 1:25 000 a partir de la Base Topográfica 1:5 000 en el Instituto de Cartografía de Cataluña, o la del Mapa Topográfico de Cataluña 1:100 000 a partir del mapa comarcal de Cataluña 1:50 000 (Institut Cartogràphic de Catalunya, 1997). Sin embargo, según Jaakkola (1998, p. 195), hasta ahora las agencias cartográficas nacionales de la mayoría de países se habían visto forzadas a producir y almacenar múltiples bases de datos de sus mapas topográficos. En Estados Unidos, el *National Map* (U.S. Geological Survey, 2001) almacenará todos los elementos cartografiables según las normas aplicables para cada tema y fuente, sin introducir ninguna generalización, pero se proporcionarán herramientas para soportar

su ejecución en su visualización gráfica. Además, se considera la generalización como una línea de investigación necesaria para derivar productos a partir del *National Map*.

Otra aplicación más reciente es la de la cartografía a demanda, entendiendo ésta como aquella que posee las características deseadas por el usuario. De esta forma, desde cualquier terminal de ordenador se puede demandar la visualización de una determinada zona geográfica a una determinada escala (como es el ejemplo de la Figura II.4), y para eso la base de datos puede ser única si ésta dispone de herramientas capaces de suministrar el producto solicitado por el usuario. Además, la superficie sobre la que proporcionar la información cartográfica puede ser drásticamente reducida de tamaño, como sucede en equipos portátiles como navegadores GPS, teléfonos móviles, o agendas personales (PDA) (Figura II.5). Como ejemplo, en Lehto y Sarjakoski (2005) se presenta una aplicación en lenguaje XML para la generalización en tiempo real sobre PDA.

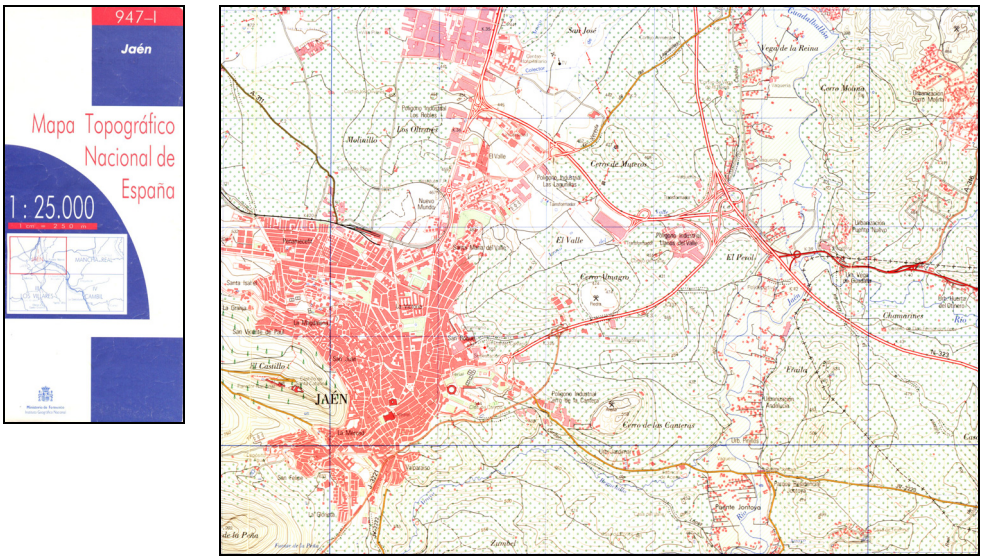


Figura II.2 - Fragmento de la hoja 947-I (Jaén) del MTN25 (Instituto Geográfico Nacional, 1997).

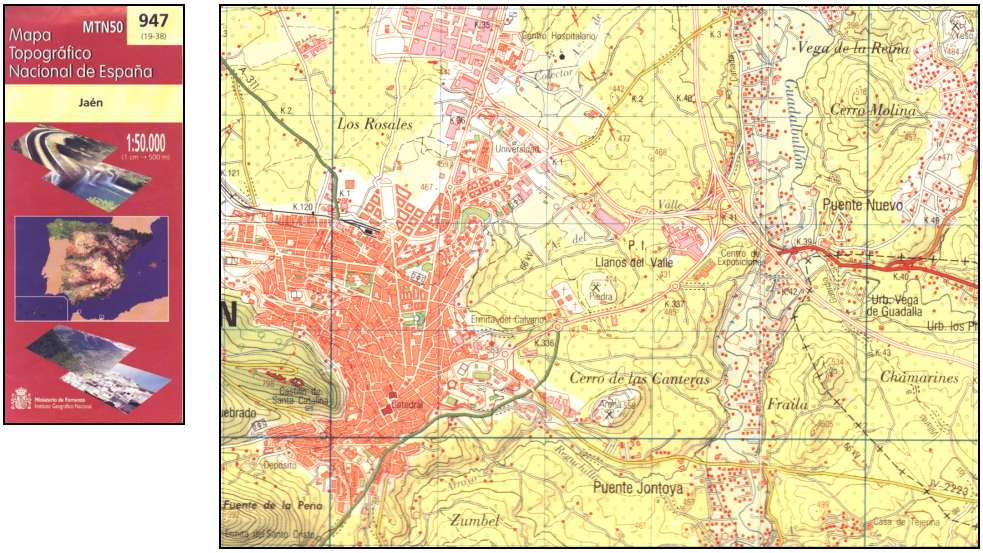


Figura II.3 - Fragmento de la hoja 947 (Jaén) del MTN50 (Instituto Geográfico Nacional, 1999).

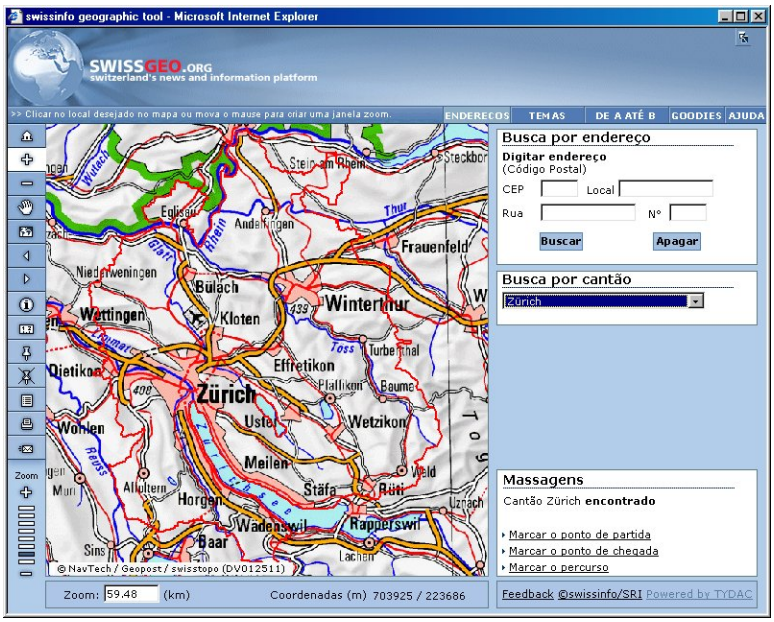


Figura II.4 - Ejemplo de servidor de cartografía en internet.



Figura II.5 - Equipos portátiles en los que se representa información cartográfica.

II.2. AUTOMATIZACIÓN DE LA GENERALIZACIÓN

El proceso tradicional de generalización ha sido manual, con gran aplicación de conocimientos expertos individuales artesanales, y con requerimiento de operarios especializados. De hecho, las diferencias de concepción entre los distintos ejecutantes de una serie cartográfica causa una heterogeneidad que ni los usuarios menos experimentados dejan de percibir y criticar. Para Ormsby y Mackaness (1999), en la evaluación de los resultados se evidencia la subjetividad con la que un mapa puede ser juzgado: "Incluso los cartógrafos a menudo ofrecen resultados con los que no están de acuerdo entre ellos". Incluso una línea generalizada podría ser diferente habiendo sido la misma persona la que ha operado sobre ella, debido a la ausencia de repetitividad por distintas causas: habilidad, condiciones ambientales, urgencia de la producción, control muscular o estado mental. Por ello el interés que siempre ha existido por establecer unas normas "universales" dentro de este conjunto de procesos.

II.2.1. Generalización manual vs generalización automática

Una característica de la generalización manual reside en el hecho de que el cartógrafo es capaz de percibir el elemento a generalizar en su totalidad y respecto al conjunto del mapa para después proceder a su manipulación a través de cambios globales, sirviéndose de un procesamiento simultáneo de

información. Por el contrario el procedimiento digital o automático está todavía lejos de percibir el mapa como un todo, ya que el ordenador necesita manipular la información de forma independiente y a través de una secuencia predeterminada de instrucciones. Esto provoca que no haya unanimidad respecto a la posibilidad de sustituir totalmente la generalización manual por la automatizada, siendo todavía muchos los cartógrafos que consideran que la generalización es un acto de creación, de tal forma que no se puede codificar o reglamentar de manera precisa. Zhan y Buttenfield (1996) consideran que el proceso de generalización realizado por un experto es tremendamente subjetivo, que elaborar un sistema que imite este proceso de toma de decisiones puede ser demasiado caro y que es imposible capturar todo el conocimiento experto (argumento que exponen para justificar una alternativa más sencilla y plantear su método de generalización). Por otro lado, es indiscutible que la automatización del proceso reducirá su componente artística, pero es el coste de un verdadero enfoque científico

En la actualidad, gracias a la informática existen procesos de generalización automáticos, pero estos métodos estándar están muy lejos del "arte y razón" que conlleva el proceso manual tradicional. Sin embargo, frente al proceso manual, el automático ofrecerá siempre el mismo resultado si los datos de partida, los procesos y sus parámetros de control son los mismos, ya que la secuencia de operaciones será siempre la misma. No obstante se pueden lograr diferentes resultados temáticos variando la selección, secuencia y grado de aplicación de las operaciones (Ruas y Plazanet 1996). De hecho, aunque se cree que la automatización de la generalización traerá consigo la eliminación de su subjetividad, "probablemente hay más variación en la selección y aplicación de un algoritmo de generalización en el entorno digital que en dos líneas generalizadas manualmente" (McMaster y Shea, 1992). Para evitarlo se necesita precisar qué algoritmos se están usando, en qué orden y cuáles son los parámetros de entrada. Esto no implica eliminar el carácter subjetivo y artístico que caracteriza a la cartografía, ya que el cartógrafo puede servirse de un sistema digital como si de un conjunto de herramientas se tratase.

Otra gran diferencia entre el contexto convencional y el digital es que en el primero no se hacía distinción entre *generalización del modelo* (o de la base de datos), relacionada con la derivación de bases de datos con menor, o diferente resolución espacial y temática, y *generalización cartográfica*, que tiene un enfoque visual y es mucho más complicada (Shuurman, 1999; Richardson y Mackaness, 1999). En los sistemas digitales la generalización puede afectar directamente a los datos del mapa y no solamente a los gráficos (Weibel, 1995a).

II.2.2. Necesidad de formalizar el conocimiento

El cartógrafo usa su juicio artístico y estético y su experiencia, de forma que la mayor parte del tiempo aplica el conocimiento cartográfico que no ha sido formalizado en reglas en ningún sitio (Plazanet, 1995). Algunas de las reglas cartográficas identificadas hacen referencia al respeto a las formas geométricas, la preservación de la topología intrínseca, el ancho del símbolo, la naturaleza semántica de los elementos, o el mensaje a transmitir (que a su vez depende de la resolución, el tema, etc.).

Por tanto, es necesario incorporar el conocimiento cartográfico y geográfico, que permite llevar a efecto la generalización manual, al contexto digital, constituyendo uno de los mayores problemas que se presentan en la actualidad, ya que es difícil formalizar un conocimiento de un proceso (Shea, 1991, p. 3) subjetivo, interactivo, idiosincrásico y holístico en su percepción y ejecución. Esta es la razón de los escasos ejemplos de automatización total de la generalización en la producción de un mapa.

En suma, la complejidad de las decisiones que hay que tomar hace necesario crear una representación artificial del conocimiento geográfico y cartográfico. Muchos autores opinan que los métodos basados en el conocimiento tienen un gran potencial. El primer problema a resolver sería cómo adquirir ese conocimiento para almacenarlo en un ordenador para posteriormente analizar la forma más óptima en que se podría explotar (Weibel, 1995a), entrando así en el ámbito de la Inteligencia Artificial. En los últimos años, se están ensayando modelos

orientados al objeto, aparentemente con mejores resultados, donde cada uno de ellos tiene un comportamiento previamente definido y decide de forma autónoma que hacer cuando recibe la orden de generalizarse (Hardy, 1998).

II.2.3. Generalización y S.I.G.

Con la aparición de los sistemas de información geográfica (S.I.G), y sus primeras aplicaciones cartográficas, la importancia de la generalización fue relegada, al pretender ignorar el concepto de escala, cuando en realidad "la ausencia de técnicas adecuadas de generalización es precisamente una de las limitaciones más serias para un uso significativo de los S.I.G." (Weibel, 1991). De hecho, los primeros mapas generados a partir de S.I.G. durante las décadas de los 60 y 70 fueron considerados como pobres productos gráficos por los cartógrafos (Schuurman, 1999). Apenas existía diferenciación entre la cartografía automatizada y los S.I.G.

Así, aún hay quienes piensan que la generalización es un reducto del pasado y que todo se puede solventar gracias a capacidad de los ordenadores. Se pueden así desactivar las capas monotemáticas de información además de otros elementos gráficos que no se quiera que aparezcan en pantalla para evitar una gran acumulación, ampliar y reducir la imagen cuanto se quiera, además de utilizar ventanas múltiples que permitan desplazarse simultáneamente por el mapa a un gran nivel de detalle. Pero esta afirmación es un error, pudiéndose argüir razonamientos en contra:

- Los procesos y fenómenos espaciales son normalmente dependientes de la escala. Más que percibir menor información al ir reduciendo la escala, lo que se percibe es información diferente (Mackaness, 1995). Por tanto, lo ideal sería analizar y visualizar los datos espaciales al nivel de escala para el que estos fenómenos son significativos y más fácilmente comprensibles (Weibel, 1995a).
- La abstracción y la reducción de complejidad son actividades fundamentales del razonamiento humano y parte del proceso general científico. Menos es más. (Weibel, 1995a)

- Las reducciones del mapa rebajan su calidad estética, siendo no sólo un problema de gustos, ya que la comprensión también se ve disminuida (Reinoso, 1998).
- El uso de múltiples ventanas o capas monotemáticas tiene el inconveniente de hacer lento el tratamiento de la información por el volumen de datos a manejar si no se ha hecho una reducción adecuada de los mismos (Reinoso, 1998).
- El S.I.G. ha sido fuertemente influenciado por la estética de la cartografía tradicional y por la teoría de la comunicación, por lo que una vista muy densa en pantalla en escalas pequeñas se considera inaceptable (Schuurman, 1999).

II.2.4. Investigación y desarrollo

La búsqueda de la automatización del proceso de generalización ha ido fijándose metas cada vez más ambiciosas conforme se producía el desarrollo de la informática:

- Durante las décadas de los 60 y 70 la atención se centró en la simplificación de la geometría de los elementos lineales (Schuurman, 1999), ya que la mayor fuente de información procedía de la digitalización de los mapas analógicos y existían obstáculos de carácter informático como son el almacenamiento y el procesamiento de los datos. De aquella época procede el renombrado algoritmo de Douglas-Peucker (Douglas y Peucker, 1973). Por tanto más que una solución con un objetivo cartográfico, se buscaba una solución para comprimir la información.
- Durante los 80 la investigación continuó centrándose en aspectos geométricos sobre elementos independientes, sin considerar el contexto o las dependencias entre objetos (Schuurman, 1999). Ejemplos son algunos algoritmos de simplificación y suavizado de elementos lineales. Esta falta de contextualización del problema por parte del ordenador provocó cierto desaliento sobre las posibilidades de automatizar el proceso y se produjo un avance muy lento en la investigación.

- La década de los 90 supuso un despertar del letargo de la década anterior. Por un lado se comenzaron a desarrollar operadores más complejos que los de simplificación y suavizado (p.e., los trabajos de Ruas (Ruas, 1998) para el desplazamiento, o Plazanet (Plazanet, 1996) respecto a la caricaturización de vías de comunicación). Además, el desarrollo de la informática permitió probar la aplicación de técnicas relativas a la Inteligencia Artificial, como son los sistemas basados en reglas, los sistemas expertos, las redes neuronales, los algoritmos genéticos, etc. En suma, se trata de técnicas más complejas que buscan adquirir el conocimiento que aplica el cartógrafo así como adquirir conocimiento sobre las propias herramientas disponibles (qué algoritmo es más adecuado, qué parámetro debería usarse, en qué orden, etc.). No obstante, no han permitido obtener soluciones globales y comprensivas, pero sí han contribuido a desarrollar nuevas operaciones y procesos disponibles para enriquecer el proceso de generalización.
- Las últimas investigaciones se están centrando en la explotación de sistemas orientados al objeto. De esta forma los propios objetos tienen un comportamiento respecto a cómo generalizarse. La inteligencia pasa de estar en una aplicación software a estar en los objetos de la propia base de datos. Los primeros resultados han sido claramente esperanzadores respecto a una solución completa para una base de datos geográfica. El ejemplo más claro de este tipo de planteamiento es el proyecto Agent que se comenta más adelante.

Durante todas estas etapas relativas a la investigación en generalización, la falta de confianza del sector empresarial, que duda de los beneficios que a largo plazo se podrían obtener, ocasiona que sean pocas las casas comerciales que dediquen parte de su presupuesto a labores I+D. Los S.I.G. comerciales vectoriales suelen incorporar escasos y anticuados algoritmos, mientras durante años sólo se ha conocido un programa específico de generalización que haya salido al mercado. Éste es *MapGeneralizer*, de la firma Intergraph y orientado a la producción cartográfica, pero que no ha tenido todo el éxito que se esperaba en un principio, por lo que aquella abandonó después esta línea de trabajo.

Todo ello ha inducido que la labor de investigación recaiga en las universidades y en grupos de investigación dependientes de instituciones nacionales. Uno de los más recientes e importantes impulsos dados en investigación, con un carácter muy aplicado, corresponde al proyecto AGENT (Automated Generalization New Technology, http://agent.ign.fr), fruto de la colaboración internacional del Institut Géographique National (Francia), Laser-Scan Ltd (Reino Unido), el Institut National Polytechnique de Grenoble (Francia), la University of Edinburgh (Reino Unido), y la University of Zurich (Suiza). Para Schuurman (1999), AGENT destaca por ser un convenio académico-comercial, por incorporar varias soluciones conceptuales y elementos de inteligencia artificial, así como por emplear metáforas sociales. Los resultados de este proyecto han supuesto el desarrollo del reciente software Clarity de Laser-Scan, asociado a la red MAGNET (Mapping Agencies Generalization NETwork). MAGNET está formada por varias instituciones cartográficas que marcan las demandas respecto a las capacidades que debe tener Clarity. El proyecto AGENT se resume en el apartado II.3.

Por todo lo dicho, es evidente la enorme dificultad que entraña la investigación en la automatización de la generalización cartográfica, que puede provocar el desaliento al tratar de abordarla en su conjunto. Es preferible atacar problemas concretos, recordando la popular máxima de "divide y vencerás" para que la comunidad científica pueda avanzar en este ineludible paso, inherente a la producción cartográfica en su sentido más amplio.

Si bien, hasta fechas recientes "no ha habido algoritmos o reglas que puedan automatizar directamente la generalización cartográfica" (Zhan y Buttenfield, 1996), el problema de la generalización automática no debe eternizarse. En palabras de Schuurman (1999), si en la próxima década "no emerge un método holístico, probablemente su necesidad sea desechada. Nos acostumbraremos a los mapas sobrecargados o casi vacíos, o bien a representaciones con una cobertura limitada. La siguiente generación de usuarios de S.I.G. seguramente no eche en falta lo que nunca ha conocido."

II.3. MODELOS CONCEPTUALES DE GENERALIZACIÓN

La búsqueda de un óptimo modelo de trabajo, identificando cada uno de los pasos a efectuar en las tareas de generalización, está presente desde que se tuvo conciencia de la necesidad de esta labor. Pero ha sido en las últimas tres décadas cuando se han concebido un mayor número de modelos cartográficos en generalización, los últimos surgidos como consecuencia del auge de la Informática y enfocados hacia este entorno; así, para Ruas (1999) un modelo de generalización es un conjunto de procedimientos y de informaciones genéricas para generalizar una base de datos geográfica. McMaster (1991) resume los modelos conceptuales desarrollados durante las décadas de los 70 y 80, que se presentan a continuación destacando las novedades que introdujo cada uno de ellos. De la década de los 90 se resume el modelo basado en constreñimientos, materializado en el proyecto Agent.

El modelo de Ratajski

El polaco Lech Ratajski (Ratajski, 1967) identifica dos tipos de procesos en la generalización: cuantitativos, que consisten en la progresiva eliminación del contenido del mapa al ir reduciendo la escala, y cualitativos, que tratan la transformación de formas elementales de simbolización en otras más abstractas.

Ratajski introduce el novedoso concepto del *punto de generalización*. Éste se alcanza cuando, al reducir la escala, la capacidad del mapa se ve reducida hasta el punto en que se hace necesario un cambio en el método de representación, que se producirá dentro de los métodos cualitativos o cuantitativos. La capacidad del mapa puede representarse mediante un triángulo cuya base representa la capacidad inicial del mapa y cuyo vértice superior representa el límite de capacidad del mapa (Figura II.6). Cuando el nivel de generalización se acerca a éste vértice, se ha de aplicar un nuevo método de generalización.

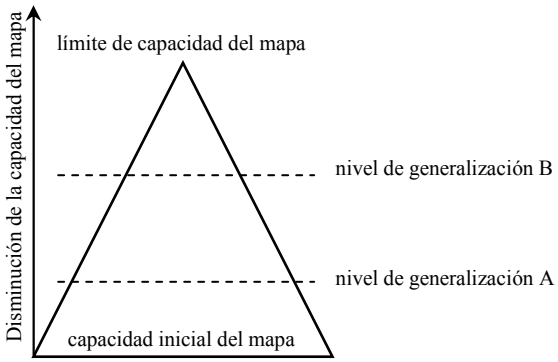


Figura II.6 - Representación del modelo de generalización de Ratajski.

Por ejemplo, supóngase una cartografía correspondiente a un casco urbano en el que se representan con detalle los edificios. Una progresiva reducción de escala acercaría el punto de generalización en el que se hace necesario un cambio en el método de representación de los edificios. Si éstos pasan a ser agrupados por manzanas, se habrá aplicado un proceso de generalización cualitativa.

El modelo de Morrison

El modelo de Joel Morrison (Morrison, 1974) parte del establecido por Robinson y Sale (1969), que distinguía cuatro pasos en la generalización: simplificación, clasificación, simbolización e inducción:

- *Simplificación*, definida como la determinación de las características importantes de los datos, su retención y posible exageración, y la eliminación de detalles poco importantes.
- *Clasificación*, mediante la ordenación, escalado y agrupación de los datos.
- *Simbolización*, como la codificación gráfica del resultado de la clasificación.
- *Inducción*, o "el lógico proceso de inferencia" y en el que el usuario es capaz de captar más información de la realmente representada en el mapa.

Para Morrison, cada uno de estos pasos constituye una probable transformación de características de un conjunto C de elementos, siendo éste el subconjunto de elementos que constituyen la realidad del cartógrafo. Cada transformación podrá ser inyectiva, biyectiva o suprayectiva.

El modelo de Brassel y Weibel

Este detallado modelo (Brassel y Weibel, 1988) distingue cinco procesos de generalización en un entorno digital:

- *Reconocimiento de estructuras*. Se identifican los objetos u agregaciones de objetos cartográficos, así como las relaciones espaciales y las medidas de importancia.
- *Proceso de reconocimiento*. Se decide cuál es el proceso exacto de generalización: (a) qué hacer con los datos originales, (b) qué tipos de conflictos han de ser resueltos y (c) qué tipos de objetos y estructuras serán almacenados en la nueva base de datos.
- *Modelado de procesos*. Compila las reglas y procedimientos de una librería de procesos previamente existente.
- *Ejecución de los procesos*. Las reglas y procedimientos son aplicados a la base de datos original para obtener la salida de datos generalizada.
- *Visualización de los datos*. Transforma los datos obtenidos de la generalización en el mapa generalizado.

Además los autores distinguen dos objetivos distintos en la generalización digital: estadísticos y cartográficos. Los primeros pretenden reducir la cantidad de datos y obtener análisis estadísticos, mientras los segundos buscan mejorar la efectividad visual desplazando la estructura del mapa.

El Modelo Conceptual Comprensivo de McMaster y Shea

Según sus autores (McMaster y Shea, 1992), se trata del primer modelo que aborda el problema de la generalización desde una doble perspectiva, técnica y filosófica, además del primero que se ha ideado pensando claramente en el entorno digital. El modelo distingue tres grandes apartados, que constituyen las tres grandes preguntas que todo cartógrafo se plantea a la hora de generalizar (Figura II.7):

- *Objetivos filosóficos*, o por qué generalizar.
- *Evaluación cartométrica*, o cuándo generalizar.
- *Transformaciones espaciales y de atributos*, o cómo generalizar.

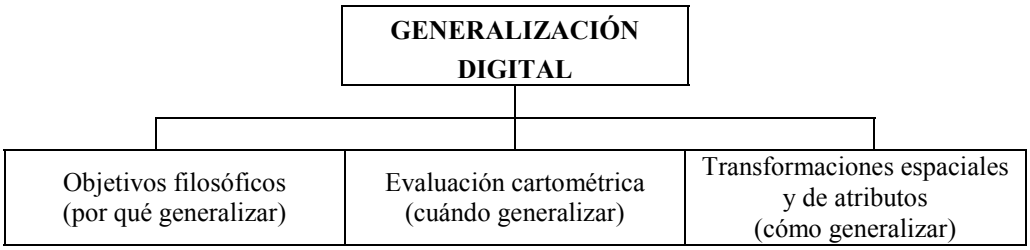


Figura II.7 - Esquema del Modelo Conceptual Comprensivo de McMaster y Shea (1988).

Con los **objetivos filosóficos** se pretende analizar por qué es necesaria la generalización en un entorno digital, existiendo tres tipos (Tabla II.1):

- *Elementos teóricos*. Son los principios cartográficos intuitivos y generales.
- *Elementos de aplicación específica*. Se trata de los requisitos específicos que requiere el problema de la generalización para un mapa concreto.
- *Elementos computacionales*. Tienen en cuenta la capacidad actual de los ordenadores.

Tabla II.1 - Objetivos filosóficos del Modelo Conceptual Comprensivo.

OBJETIVOS FILOSÓFICOS		
Elementos teóricos	**Elementos de aplicación específica**	**Elementos computacionales**
• Reducción de la complejidad. • Mantenimiento exactitud espacial. • Mantenimiento exactitud atributos. • Mantenimiento de la calidad estética. • Mantenimiento de la jerarquía lógica. • Aplicación consistente de las reglas de generalización.	• Propósito del mapa y usuario final. • Adecuación a la escala. • Retención de la claridad.	• Efectividad del coste de los algoritmos. • Reducción máxima de los datos. • Requisitos mínimos de memoria y disco.

En la **evaluación cartométrica** se examina cuáles son las situaciones que hacen necesaria la generalización digital: "cuándo generalizar". Los autores distinguen tres grupos de eventos en este caso (Tabla II.2):

- *Condiciones geométricas*, que invocarían el proceso de generalización.
- *Medidas espaciales y holísticas*, que complementarían a las anteriores.
- *Controles de transformación*, propios de las técnicas de generalización.

Tabla II.2 - Evaluación cartométrica del Modelo Conceptual Comprensivo.

EVALUACIÓN CARTOMÉTRICA		
Condiciones geométricas	**Medidas espaciales y holísticas**	**Controles de transformación**
• Congestión. • Coalescencia. • Conflicto. • Complicación. • Inconsistencia. • Imperceptibilidad.	• Medidas de densidad. • Medidas de distribución. • Medidas de longitud y sinuosidad. • Medidas de forma. • Medidas de distancia. • Medidas de la Gestalt. • Medidas abstractas.	• Selección del operador de generalización. • Selección del algoritmo. • Selección de parámetros.

Con las **transformaciones espaciales y de atributos** se ejecutan los distintos operadores que van a permitir realizar la generalización (ver ejemplos en la Figura II.8). Estos operadores se han desarrollado tanto emulando las técnicas manuales tradicionales como a través de métodos más matemáticos, y pueden modificar los datos digitales o su modo de representación. Ambos tipos de transformaciones, espaciales y de atributos, no son independientes ya que en muchas ocasiones están muy relacionadas.

Tabla II.3 - Transformaciones espaciales y de atributos del Modelo Conceptual Comprensivo.

TRANSFORMACIONES ESPACIALES Y DE ATRIBUTOS			
Transformaciones espaciales			**Transformaciones de atributos**
Simplificación. Suavizado. Agregación. Amalgamación.	Unión. Colapso. Refinamiento	Exageración. Realce. Desplazamiento.	Clasificación. Simbolización.

Siempre centrados en el modelo vectorial, no en el raster, los autores identifican diez transformaciones espaciales (Tabla II.3):

- *Simplificación*. Normalmente en el proceso de digitalización se registran más coordenadas de las necesarias, ocasionando un aumento en el tiempo de trazado o en el espacio de almacenamiento requerido, así como una ralentización en los procesos de cálculo. La simplificación se encarga de disminuir el

número de coordenadas reteniendo únicamente aquellas que mejor definen la geometría de la línea o elemento en cuestión.

- *Suavizado*. Otro efecto que se produce durante la digitalización es una excesiva angularidad (Töpfer y Pillewizer, 1966). Al suavizar una línea se pretende suprimir las pequeñas perturbaciones procurando mantener sus tendencias generales, obteniendo una salida de carácter más estético.
- *Agregación*. Mediante esta transformación los elementos puntuales, normalmente representados mediante un símbolo, son agrupados en una figura areal en el momento en que su número o densidad hace aconsejable que sean representados individualmente.
- *Amalgamación*. Permite reunir en un sólo polígono a varias figuras areales cuando se produce coalescencia entre ellas o si su tamaño es demasiado pequeño para ser representadas individualmente tras el proceso de reducción.
- *Unión*. Fusiona dos líneas en una sola cuando el espacio que media entre ambas es demasiado pequeño.
- *Colapso*. Impone un cambio de simbolización tras la reducción de escala debido a la disminución de tamaño. De esta forma, elementos areales pasarán a ser representados mediante elementos lineales o puntuales y elementos lineales mediante puntuales. Esta transformación ha sido muy usada tradicionalmente.
- *Refinamiento*. Es necesario en el caso en que aparezca una gran cantidad de figuras semejantes, siendo demasiado numerosas o demasiado pequeñas para poder ser representadas en su totalidad. El refinamiento radica en la selección de las figuras que mejor simbolicen la estructura global original. Un ejemplo claro es el de las cuencas hidrográficas.
- *Exageración*. Puede ocurrir que un elemento geográfico de clara importancia para el objetivo o usuario final del mapa no tenga el tamaño suficiente para ser representado a la escala considerada. En ese caso se incorporará en el mapa con un tamaño apropiado. Esta transformación evidentemente no actuará sobre representaciones simbólicas.

- *Realce*. Es análogo a la exageración pero para el caso de símbolos, ejerciendo un cambio en su tamaño y/o en su forma.
- *Desplazamiento*. Es útil en el caso de que dos o más elementos gráficos entren en conflicto debido a su proximidad o solape, o cuando se hallan demasiado próximos al límite del mapa.

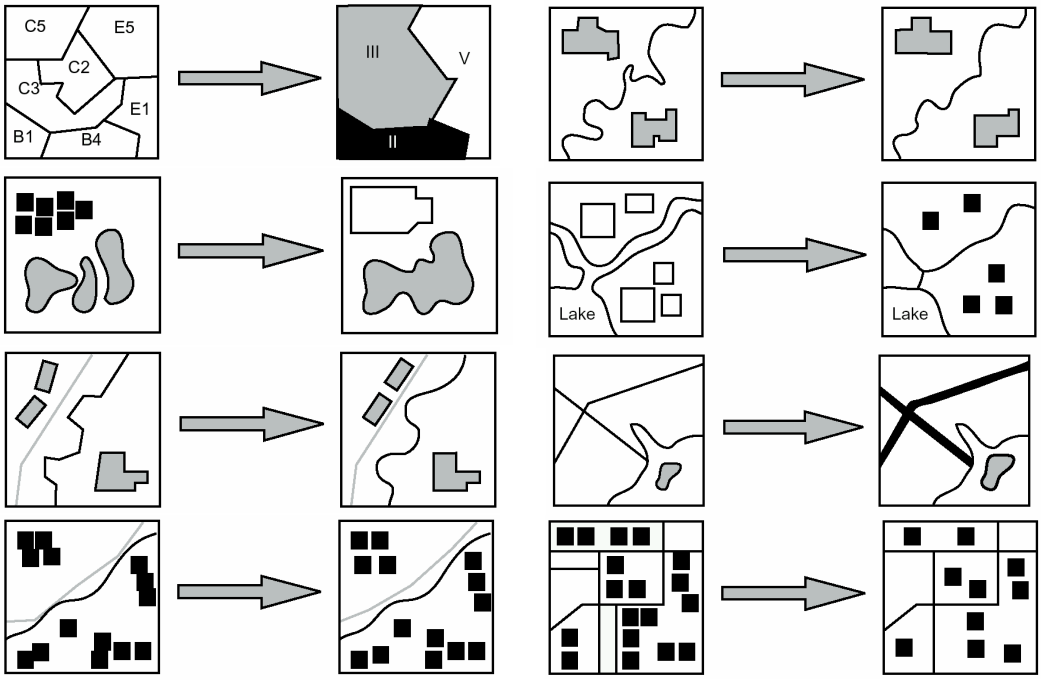


Figura II.8 - Ejemplos de operadores de generalización.

Las transformaciones de atributos se encargan de modificar la información asociada a las figuras del mapa, que implicará a su vez cambios espaciales. Son dos las transformaciones de atributos:

- *Clasificación*. Es uno de los métodos principales de generalización. Su necesidad es debida a la imposibilidad de representar todos los valores que se presentan en la realidad. Se procede mediante una agrupación de los elementos con características similares en categorías.
- *Simbolización*. Se muestra el resultado de la generalización mediante un símbolo o dibujo más significativo para el usuario, modificándolo a través de las variables visuales: tono, valor, tamaño, forma, grano, orientación y localización. La simbolización se realiza mediante (a) un cambio en la escala de

medida: nominal, ordinal, de intervalo o proporcional (siempre desde la última hacia la primera) y (b) mediante un cambio en el tipo de dato: punto, línea, área o volumen.

No existe una completa unanimidad respecto al número y definición de todos los operadores empleados en generalización. Ruas (2002) expone varias razones que explican esta circunstancia: ninguna comisión de cartografía ha trabajado en la terminología y por tanto no hay definiciones oficiales; los investigadores abordan la generalización en temáticas y escalas diferentes, refiriéndose a procesos manuales o informáticos; las traducciones entre los diferentes lenguajes dificultan la comprensión. Como ejemplo, en la Tabla II.4 se resumen los operadores identificados por otros autores.

Tabla II.4 - Operadores de generalización identificados por diferentes autores

Brassel (1985)	**Beard (1991b)**	**Mackaness (1991)**	**Ruas y Lagrange (1995)**
• seleccionar • eliminar • integrar • expandir • desplazar • borrar • clasificar • mostrar • reducir • reducir sinuosidad • superponer	• selección • omisión • simplificación • colapso • enlace • clasificación • generalización • agregación • asociación	• cambio de simbolización • superposición de simbolización • incremento de la diferencia de tamaño • selección • omisión • simplificación • combinación (reclasificación) • desplazamiento • exageración	• selección • suavizado • filtrado • caricatura • agregación • tipificación • colapso • alargamiento • desplazamiento

Una clasificación más reciente puede leerse en Ruas (2002, tras Mustiere, 2001), que primeramente establece tres grandes familias de operadores (de simplificación o eliminación de información, de caricaturización o exageración de las características, y de armonización o supresión de diferencias).

Modelos basados en constreñimientos. El proyecto AGENT

Un constreñimiento puede interpretarse de diferentes formas (Ruas, 1999, p. 39); por ejemplo, pueden considerarse como los objetivos del modelo de McMaster y Shea (1992) o la violación de las condiciones de este mismo modelo. Para

Ruas (1999, p. 68), los constreñimientos proceden de las especificaciones que requiere la generalización en cada situación. De esta forma, se pueden idear métodos de generalización guiados por constreñimientos, observando en cada momento si se produce una insatisfacción de una condición preestablecida.

En Beard (1991b), se efectúa una primera clasificación de los constreñimientos. Posteriormente, Weibel y Dutton (Weibel y Dutton, 1998), los enmarcan en el proceso global de generalización, constituyendo un modelo de generalización muy avanzado, que considera los siguientes tipos de constreñimientos:

- Gráficos, relativos a los tamaños y proximidades mínimas de los objetos.
- Topológicos.
- Estructurales, que pretenden mantener las estructuras espaciales y semánticas (formas, posiciones relativas, alineaciones, etc.).
- de la Gestalt, relativos a la estética y el equilibrio global de los datos.
- Procedurales, que describen las reglas de uso y la secuencia lógica de los operadores.

El modelo de generalización basado en constreñimientos más avanzado hasta el momento es el del proyecto AGENT (Automated Generalization New Technology). Éste es un proyecto de investigación y desarrollo financiado por el programa ESPRIT de la Unión Europea, llevado a efecto entre los años 1998 y 2000, en el que colaboraron tanto universidades (Institut National Polytechnique de Grenoble, Francia; University of Edinburgh, Reino Unido; University of Zurich, Suiza), como instituciones cartográficas (Institut Géographique National, Francia) y empresas privadas (Laser-Scan Ltd, Reino Unido). Uno de los aciertos de este proyecto es precisamente la combinación de conocimientos que cada tipo de institución puede aportar, por lo que el proyecto se robustece con (Lamy et.al, 1999):

- La experiencia en investigación y producción de una institución cartográfica.
- El *know-how* de un desarrollador de SIG que emplea tecnología de base de datos orientada al objeto.

- Los conocimientos cartográficos, de modelado topológico y de técnicas multi-agente de renombrados equipos de investigación.

El principal atractivo del modelo es que pretende tener en cuenta la naturaleza holística de la generalización. Así, dado el desarrollo tecnológico alcanzado, sus creadores creen que ya es factible el diseño y presentación autónoma de cartografía, según la temática y la escala impuestas por el usuario.

El objetivo se marca en el desarrollo de software de diseño cartográfico basado en tecnología multi-agente. Se denomina agente a cualquier entidad que se desarrolla en un entorno, que es capaz de percibir y en el que puede actuar, que es capaz de comunicarse con otros agentes y que exhibe un comportamiento autónomo. Se denomina Sistema Multi-Agente (MAS, Multi-Agent System) al conjunto de agentes que interactúan en un entorno común, enfocado a la resolución colaborativa de problemas globales, al mismo tiempo que satisfacen sus propios objetivos locales. Es decir, los agentes pueden comunicarse, cooperar, coordinarse, así como negociar entre sí, para satisfacer sus objetivos individuales y los de todo el sistema. El agente realiza continuamente un ciclo de percepción - razonamiento - decisión - acción hasta que se satisfacen los objetivos, cuando se alcanza un estado de equilibro (Demazeau, 1997).

Más concretamente, el proyecto pretende la definición y modelado de comportamientos de estructuras y agentes geográficos en el contexto de la generalización (Lamy et.al, 1999). Se basa en tres principios:

- Autonomía. Se pretende que el proceso de generalización sea automático. Sabiendo que alguien debe tomar la decisión de generalizar y cómo generalizar, se asume que un agente ha de ser capaz de generalizarse a sí mismo.
- Constreñimientos. Para actuar, un agente necesita saber si no satisface las especificaciones de generalización, denominadas constreñimientos. Cada agente tendrá un conjunto de constreñimientos relacionado con sus características (forma, localización, orientación), y que pueden ser competitivos entre sí. El agente tiene unos objetivos a alcanzar respecto a los constreñimien-

tos asociados y se debe alcanzar una solución de compromiso (véase el ejemplo de la Tabla II.5 y de la Figura II.9).

- Niveles de análisis. Algunas operaciones de generalización se basan en el análisis efectuado sobre un grupo de objetos (p.e., la eliminación cuando la densidad de información es elevada), mientras otras lo hacen sobre un objeto aislado (p.e., la amplificación del tamaño de un edificio si su tamaño no llega al mínimo). Así, son necesarios distintos niveles de análisis sobre los que se definen los agentes, que se concretan en: nivel micro (un objeto), nivel meso (un grupo de objetos) y nivel macro (una población de objetos) (véase el ejemplo de la Tabla II.5).

Tabla II.5 - Constreñimientos y objetivos de un edificio y un distrito a la escala 1:50 000 (Lamy et.al, 1999).

Constreñimientos de una edificación (agente micro)		**Objetivos del edificio**
Tamaño	La edificación debe tener un tamaño mínimo para ser legible. Este tamaño depende de la escala y de los umbrales del símbolo.	Area: > 300m2
Granularidad	La longitud de los bordes que constituyen el límite no debe ser inferior a un umbral, que depende de las especificaciones del mapa.	Longitud_minima_borde > 20m
Exactitud	La posición absoluta de la edificación debería ser preservada en la medida de lo posible.	Distancia de Hausdorff < 20m (de su posición inicial)
Constreñimientos de un distrito (agente meso)		**Objetivos del distrito**
Densidad	La densidad no debería ser muy elevada	Densidad: <0,8

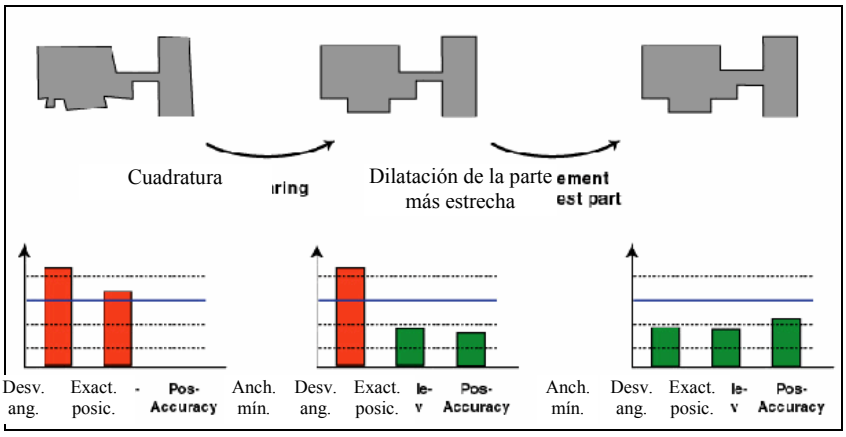


Figura II.9 - Ejemplo de autogeneralización de un micro-agente (edificación).

La fase de explotación del modelo se ha llevado a efecto mediante la red MAGNET (Mapping Agencies Generalization Network), formada por la empresa Laser-Scan y las instituciones cartográficas nacionales del Reino Unido (Ordnance Survey), Dinamarca (Kort & Matrikelstyrelsen), Bélgica (Nationaal Geografisch

Instituut) y Francia (Institut Géographique National). MAGNET ha disfrutado de los primeros tres años de explotación de los resultados de AGENT. Como fruto se ha derivado el nuevo software comercial *Clarity* de la firma Laser-Scan, para derivar cartografía a partir de datos existentes. MAGNET pretende desarrollar las capacidades de Clarity según las demandas de sus miembros. En la Figura II.10 se muestra un ejemplo de generalización realizada mediante Clarity, en el caso de las vías de comunicación de una cartografía a escala 1:50 000.

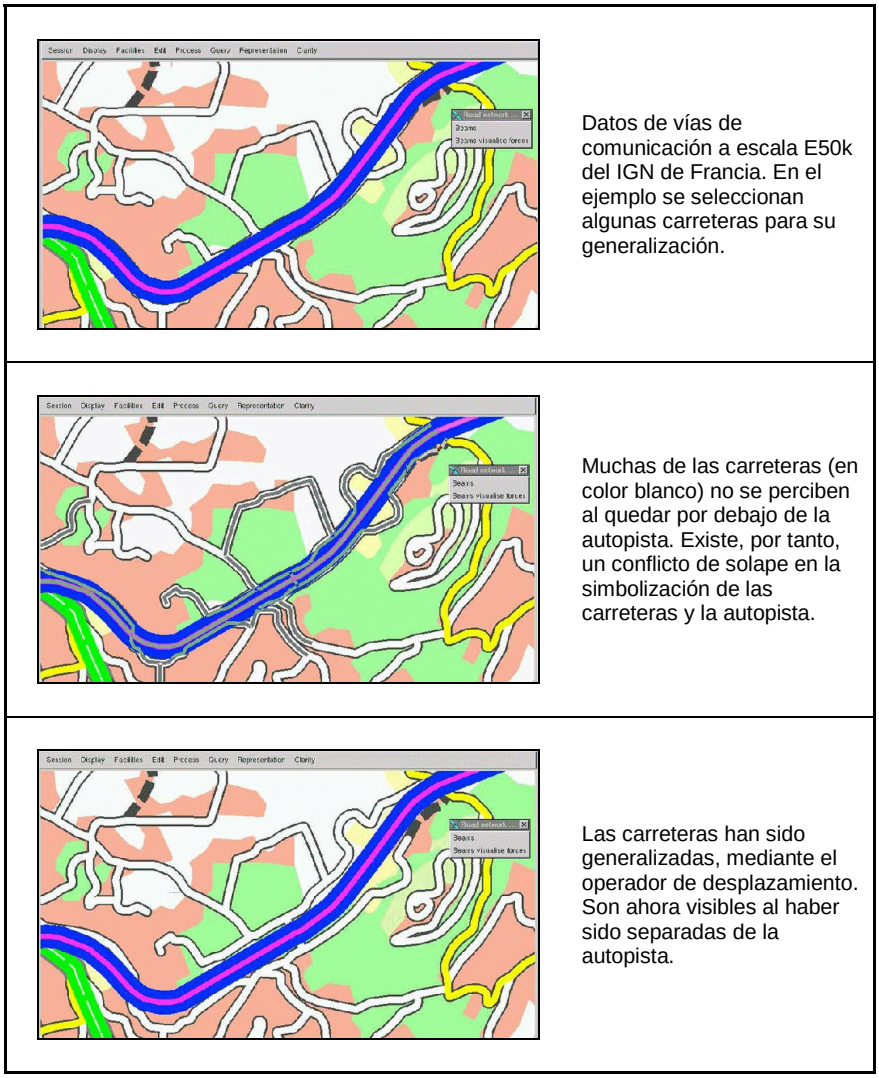


Figura II.10 - Ejemplo de generalización con el software Clarity (Laser-Scan).

II.4. Control y evaluación de la generalización

La evaluación de los resultados alcanzados tras aplicar la generalización es imprescindible, ya que es indudable que en todo proceso debe existir un control de calidad sobre el mismo. Dada la importancia que el control de calidad debe tener en la generación de un mapa nuevo, o base cartográfica digital nueva (calidad posicional, geométrica, temática, del modelado cartográfico, etc.), no es lícito pensar que tras su creación, la cartografía que se pueda derivar por generalización poseerá sus mismas cualidades satisfactorias. Es por ello que es necesario introducir ciertos parámetros que nos cuantifiquen la bondad del proceso de generalización.

Por otro lado, como ya se ha referido, la aplicación de la generalización es esencial para una fructífera utilización de los S.I.G. Sin embargo, no es menos cierto que al mismo tiempo es una transformación de la información espacial que altera su exactitud posicional, exactitud temática, topología, etc., y que por tanto afectará en gran medida a los resultados del análisis que se realice con el SIG. Para João (1995), es recomendable no emplear para el análisis una base de datos generalizada con el objetivo de visualizar la información, pero a menudo no hay otra información digital disponible, por lo que no hay otra alternativa que utilizarla.

En este contexto, el usuario de SIG preferiría minimizar, controlar y cuantificar los efectos de la generalización en sus resultados, pero el desarrollo de medidas evaluadoras ha sido muy escaso, y además no existe hábito de incluirlas entre la metainformación de la información geográfica. Un ejemplo a seguir es el del Australian Survey (1992), que especifica el desplazamiento promedio esperado en los diferentes tipos de elementos del mapa.

El cálculo de medidas evaluadoras no solo debe explicitar la calidad alcanzada tras la generalización, ya que también debería conducir el proceso, empleando objetivamente medidas que ayuden a decidir cuánto y cuándo generalizar. Sin embargo, no existen ningunas medidas aceptadas como definitivas que faciliten la decisión. El modelo conceptual desarrollado por McMaster y Shea (1992) presenta un alto interés conceptual, pero desde el punto de vista práctico en lo relativo a la

evaluación cartométrica, presenta el notable inconveniente de que los parámetros que se proponen son difíciles de cuantificar e incluso de definir.

Otro ámbito en el que las medidas tendrían una importancia crucial sería en el del enriquecimiento de las bases de datos. Es de conocimiento común que la generalización varía en función de las propiedades de los elementos de las bases de datos, por lo que es necesario que cada elemento tenga asociada una lista de propiedades que faciliten la toma de decisiones a la hora de aplicar la generalización. También el empleo de medidas debería facilitar la segmentación de elementos complejos o no homogéneos del mapa, por ejemplo una línea correspondiente a una carretera de montaña, en secciones que puedan ser consideradas homogéneas.

En suma, se puede decir que en la concepción, cálculo y comprensión de medidas evaluadoras se concentra gran parte del potencial y futuro desarrollo de la generalización cartográfica automatizada, ya que son útiles, o imprescindibles, en muy diversas tareas del complejo proceso de generalización: enriquecimiento de bases de datos, segmentación de elementos complejos, evaluación de la calidad de las tareas de generalización, inclusión en la metainformación de bases de datos derivadas mediante procesos de generalización, etc.

Según se especifica en el Proyecto AGENT (AGENT, 1999), los requerimientos para una buena medida son, desde el punto de vista teórico:

- *Robustez*: una pequeña variación en la generalización no debe llevar a un fuerte cambio en la medida.
- *Separabilidad*: debe capturar tan pormenorizadamente como pueda aquello para lo que fue concebida.
- *Invariante a la persona*.
- *Independiente de la representación*. El mismo objeto debe dar lugar a la misma medida, aunque su representación sea diferente.

Y desde el punto de vista del usuario:

- *Fácil de calcular*.
- *Fácil de usar*.
- *Fácil de interpretar*.

La cuantificación de la generalización es una necesidad evidente por cuanto nos permitirá conocer de forma objetiva la "calidad" de cada uno de sus aspectos. Sin embargo, la cuantificación conlleva necesariamente la comparación con unas especificaciones que, por lo general no existen; por otra parte, dado que la generalización incluye componentes intuitivos, no cabe esperar que la evaluación pueda ser totalmente objetiva.

Plazanet (1995) señala la conveniencia de realizar una clasificación de las medidas y establecer una terminología común, de común acuerdo entre la comunidad investigadora. Para esta autora, así se lograría un mejor intercambio de los resultados y se aceleraría, en el caso concreto que ella estaba trabajando, la investigación en el área crucial de la segmentación y clasificación de elementos lineales.

Weibel (1995b), considera los siguientes grupos de medidas cuantitativas:

- *Medidas globales*: Son un caso particular de las medidas sobre organizaciones. Muestran si el grado general de generalización es constante a lo largo del mapa. Se puede medir con índices de densidad (p.e. puntos, líneas o elementos superficiales por unidad de área), de distribución (p.e. dispersión, aleatoriedad o agrupamiento en el caso de puntos, complejidad para las líneas o distancia relativa a una localización concreta en el caso de elementos areales), de patrón, de agrupamiento o lineamiento, etc.
- *Medidas geométricas*[3]: Referidas tanto a las dimensiones, tamaño, forma de los objetos como a distorsiones que se generan (p.e. para el caso de elemen-

3 El estudio de la calidad de la generalización usa criterios que generalmente siguen la idea de preservar la estructura original tras la transformación. De esta forma surgen muchos parámetros que se verán a continuación, pero este tipo de medidas está bastante criticado por cuanto supone el mismo trato sobre elementos tan diversos como, por ejemplo, una frontera administrativa y una línea de costa. Es decir, al

tos lineales: medidas de longitud, sinuosidad, cambio de angularidad, disminución del número de coordenadas, etc.).

- *Medidas topológicas*: Medidas orientadas a medir las violaciones de las relaciones topológicas que se deben mantener (intersecciones, superposiciones, etc.).
- *Medidas relacionadas con el software*: Parámetros que permitan estimar la ganancia de productividad como resultado de la automatización (tiempo de CPU, coste horario de máquina, coste horario de operario, etc.).

En AGENT (1999) se distingue entre medidas sobre objetos y sobre organizaciones:

- *Medidas sobre objetos*: Son medidas sobre un objeto individual, p.e. sinuosidad, longitud, orientación, geometría, etc. También puede incluirse relaciones entre objetos (p.e., relaciones de geometría, como el paralelismo a una carretera), pero el valor de la medida será relativa a un objeto concreto.
- *Medidas sobre organizaciones (estructuras)*: Necesitan especificaciones para el conjunto de objetos que se analizan. Un ejemplo sería la densidad media de edificios en una zona.

A nivel algorítmico también se considera una clasificación de las medidas, diferenciando la comparación o evaluación de variaciones entre objetos en el mismo estado y entre el mismo objeto y distintos estados. La propuesta de AGENT (1999, p. 10) es:

- *Medidas Intrínsecas*: Se refieren a medidas de un objeto en un estado o a medidas de una organización (estructura) en un estado. Un ejemplo es el área de un polígono o una medida de conectividad en una red de carreteras.
- *Medidas Extrínsecas*: Para comparar diferentes estados de un objeto u organización. A su vez se divide en dos categorías:
- *Implícitas*: Para comparar dos medidas intrínsecas (p.e comparar dos tamaños de superficie de un mismo objeto).

---

igual que se buscan, en el caso de las líneas, algoritmos de generalización adecuados para cada tipo

- *Explícitas*: Indican el estado del objeto. Un ejemplo puede ser la medida de vector de desplazamiento de McMaster (1986).

Las Tablas II.6 a II.8, presentan el listado de medidas recopiladas en el proyecto AGENT. Así, el reporte DC1 de este proyecto (AGENT, 1999) constituye un intento de clasificación y definición de todas las medidas que se pueden encontrar en las distintas fuentes bibliográficas, incluyendo una ficha por cada medida con gran cantidad de información (nombre, referencias, descripción, tipos de datos sobre los que se puede aplicar, herramientas requeridas, posibles mejoras, etc.). Como se puede observar, todas las medidas señaladas forman un gran corpus de posibilidades, algunas de ellas probadas, otras simplemente propuestas, que abarcan los apartados mostrados en la Figura II.11.

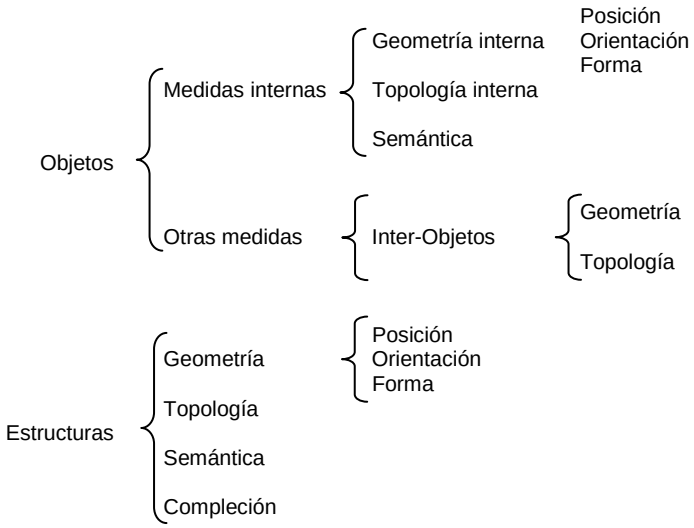


Figura II.11 - Clasificación de medidas en generalización en el proyecto AGENT (1999).

(curva nivel, carretera, río, etc.), se necesitan parámetros ajustados a cada tema y circunstancia.

Tabla II.6 - Clasificación de medidas internas (AGENT, 1999).

GEOMETRÍA INTERNA	
Forma	
Tamaño Longitud Área Perímetro Alto de curvatura Máxima altura de la curva Mínimo ancho de polígono Mínimo rectángulo encuadrante Coalescencia de línea (Mustiere, 1998) Detección conflictos coalescencia (Mustiere, 98) Banda Epsilon (Perkal, 1966) Distancia de giro (Arkin et.al, 1991) Distancia radial (Bel Hadj Ali, 1997)	**Sinuosidad /complejidad** Medidas de angularidad (McMaster, 1986) Medidas de curvilinealidad (McMaster, 1986) Máxima altura de la curva F. densidad de pendiente (Ballard y Brown, 1982) Gráfico de Richardson (Buttenfield, 1989) Entropía (Bjorke, 1993) Sinuosidad (Dutton, 1998) Descriptores de Fourier Densidad de Coordenadas (McMaster, 1986) Ratio de máximo acuerdo (Ballard y Brown, 1982) Dimensión Fractal Numero de curvas (Plazanet, 97)
Elongación / Excentricidad Excentricidad de Brown (Ballard y Brown, 1982) Elongación (Boesch, 1993) Elongación de Regnauld (Regnauld, 1998) Diseminación (Boesch, 1993) Circularidad (Davis, 1986) Elipticidad (Davis, 1986) Momentos (Boesch, 1993)	**Compacidad** Deficiencias Convexas (Boesch, 1993) Energía de curvatura (Young et.al, 1974) Medida de Miller (Campbell, 1993) Índice forma radial Boyce-Clark (Campbell, 1993) Medidas de compacidad (Davis, 1986) Cuadratura (Regnauld, 1998)
Aspectos Importantes Partes de anchura mínima de una construcción Búsqueda de cuellos (Wang y Müller, 1993) Forma de la curva (Plazanet, 1996) Descripción de la curva (Wang y Müller, 1998) Caracterización usando matriz dirección-distancia Número de puntos (Regnauld, 1998) Menor arista	
Posicion y geometria	
Posición Posición geométrica absoluta Centro de gravedad. Centro del mayor círculo inscrito (Cromley, 1992) Máximo-Centro (Cromley, 1992) Vector Desplazamiento (McMaster, 1986) Desplazamiento areal (McMaster, 1986)	**Orientación** Eje de inercia (Boesch, 1993) Orientación absoluta de un edificio (Hangouet, 1998) Orientación de una curva (Fritsch,97)
TOPOLOGÍA	
Auto intersecciones Cerramiento de polígonos Inclusión	

Tabla II.7 - Clasificación de medidas entre objetos (AGENT, 1999).

GEOMETRÍA INTER-OBJETOS	
Distancia Mínima distancia Euclídea (Müller, 1990) Posición relativa del objeto Coalescencia (ver Geometría Interna) Distancia Hausdorff (Hangouet, 1995) Distancia Frechet Distancia media entre líneas (Matos y Goncalves, 1998) Area algebraica Area Absoluta (McMaster, 1986) Indicadores de conflicto usando Diagramas Voronoi (Hangouet, 1998) Distancia al vecino mas próximo usando triangulación Delaunay	**Alineamiento** Paralelismo de líneas (Ip y Wong, 1997) Centrado (Mustiere, 1995) Orientación relativa de un edificio (Hangouet, 1998)
TOPOLOGÍA INTER-OBJETOS	
Contenedor:	Test punto en polígono
Conectividad:	Ruta más corta
Contigüidad	
Intersección:	Intersección de líneas
Vecindad:	Test de izquierda a derecha

Tabla II.8 - Clasificación de medidas sobre estructuras (AGENT, 1999).

GEOMETRÍA DE LAS ESTRUCTURAS		
Posición y geometría	**Forma**	
Posición Posición de centros bivariados (Cromley,1992) Punto de tendencia central (Cromley, 1992) Centro bivariado ponderado (Cromley, 1992) **Orientación** Análisis de Regresión	**Dispersión /Distribución** Valores medios de un grupo de edificios (Hangouet, 1998; Regnauld, 1998) Agrupamiento de edificios (Regnauld, 1998) Clasificación de la homogeneidad en un grupo (Regnauld, 1998) Análisis del vecino mas próximo (Campbell, 1993) Análisis de Cuadrantes (Campbell, 1993) **Alineamiento** Análisis de Regresión **Densidad** Densidad Individual (Hangouet, 1998) **Aspectos Importantes** Aspectos remarcables (Hangouet, Regnauld; RefIGN)	
ORGANIZACION DE LA TOPOLOGÍA	**SEMÁNTICA**	**CUMPLIMIENTO DE MEDIDAS Y MEDIDAS SOBRE MAPAS**
Jerarquización de líneas de costa complejas (Wang y Müller, 1993) Ratio de bifurcación (Campbell, 1993)	Importancia de las carreteras (Morisset y Ruas, 1997)	Diagramas de Error absoluto y relativo (Matos y Goncalves, 1998) Complejidad de mapas (Mackaness, 1995) Consistencia de generalización (Jansen, 1998)

Como se deduce de lo anterior, las medidas pueden ser muy simples o muy complejas, pero el mayor interés de muchas de ellas es el enriquecer las bases de datos para poder tomar decisiones a la hora de generalizar, por lo que, y dado que ninguna presenta una solución óptima, se suele recurrir a utilizar varias de ellas. No obstante, no existe aún una idea clara y concreta sobre la forma en que debe

evaluarse la calidad del proceso de generalización, empleando parte o más medidas de las indicadas anteriormente.

En apartados posteriores, como el II.5.2, dedicado a la caracterización de la forma de una línea, o el II.5.6., referente a la evaluación de la generalización sobre elementos lineales, se recogen algunos de los índices existentes para la cuantificación de la bondad de las generalizaciones.

II.5. GENERALIZACIÓN DE ELEMENTOS LINEALES

Aunque el punto es el elemento base para la geometría de los desarrollos cartográficos, su presencia aislada en la cartografía es menor. Prácticamente el 80% de los elementos (puntos, líneas, áreas) de un mapa de escala media son líneas (Thapa, 1988). "Las líneas pueden emplearse para describir la mayoría de los elementos presentes en los mapas. Los puntos pueden ser considerados como líneas degeneradas, y las áreas pueden ser descritas por sus límites, que son lineales." (Jasinski, 1990).

Así pues, la generalización de elementos lineales tiene gran importancia por éste y por los siguientes motivos (Li y Openshaw, 1992):

- Es el proceso de generalización más básico.
- Tradicionalmente ha sido punto de partida en cualquier nuevo estudio sobre los problemas de la generalización cartográfica.
- Se considera el primer obstáculo que necesita ser resuelto para el desarrollo de procedimientos más comprensivos de generalización (Keates, 1989).

Es por ello que los esfuerzos de investigación en generalización automatizada han estado tradicionalmente dirigidos hacia la generalización de elementos lineales, pretendiendo emular el proceso manual tradicional. Dado que ésta es una técnica holística en su aplicación, su automatización ha de superar numerosos obstáculos.

Sin embargo, son frecuentes las críticas (p.e. Wang y Müller, 1998) que recaen en la simplicidad de las operaciones que realizan los algoritmos diseñados, que suelen considerar la línea como una colección de puntos, midiendo ángulos y distancias que existen entre ellos, cuando esta no es la forma en que han venido siendo generalizados manualmente los elementos lineales de un mapa.

Así, existen multitud de tratamientos específicos para la línea como tal elemento (los llamados algoritmos de simplificación, de suavizado, etc.), pero los estudios realizados han mostrado las carencias y limitaciones de los algoritmos de generalización, especialmente en la simplificación. Ninguno de ellos proporciona una solución completa para cada caso, lo que no quita que, en algunas ocasiones, puedan contribuir a soluciones aceptables (Lecordix, Plazanet y Lagrange, 1997). Las herramientas existentes no son suficientemente eficientes por las numerosas condiciones a tener en cuenta, por las variaciones en la calidad de la salida y por la subjetividad de la generalización (Plazanet, 1997)

La calidad de los resultados parece variar según las características de la línea (Buttenfield, 1991). Por esta razón, es clara la necesidad de describir y calificar los elementos lineales (Plazanet, 1995). Además, sería necesario segmentar cada línea en secciones homogéneas previamente a esa descripción y calificación. Por tanto, de lo que se está hablando es de un enriquecimiento de las bases de datos con información que favorezca la toma de decisiones en este ámbito, reduzca los procesos de computación y disminuya los resultados erróneos. En suma, "una mera sucesión de pasos mecánicos solo pueden servir en casos excepcionales. Lo que se necesita es el procesamiento basado en el conocimiento" Brassel y Weibel (1988).

II.5.1. Representación de una línea en el entorno digital

Tradicionalmente una línea de un mapa ha sido registrada en una base de datos como una polilínea o lista de coordenadas x , y. Este método, al que podemos llamar vectorial, es favorable para almacenar la geometría de un elemento lineal para su posterior representación en pantalla o sobre papel. Sin embargo, en el

ámbito de la generalización, en los últimos años se ha tratado de hallar representaciones alternativas, ya que la polilínea carece de cualquier información que no sea la localización espacial de los vértices que la integran, por lo que no es un buen método para captar las características geométricas y formas globales de una línea, y por tanto, sus posibilidades holísticas son muy cuestionables.

Además, "Las listas de pares de coordenadas no son suficientemente significativas para permitir una generalización que sea válida en cualquier caso" (Plazanet et.al, 1995). Podría ser útil efectuar un cambio desde la representación vectorial hasta otro tipo de representación, para aplicar sobre él cualquier operador de generalización y retornar de nuevo a la representación vectorial. No obstante, es importante resaltar que una transformación para pasar de un tipo de representación a otro no debe ser considerada como una mera variación en la forma de describir la línea, ya que constituirá por sí misma un proceso de simplificación y/o de suavizado en la medida en que el cambio se produzca almacenando mayor o menor cantidad de información.

En AGENT (1999, p. 17) se enumeran algunas de las posibilidades para representar una línea. Curvas cúbicas, representaciones espectrales, splines... pueden ayudar para trazar y extraer la forma de una línea, posibilitando el desarrollo de nuevas técnicas cuyas posibilidades están aún por descubrir. Así, para avanzar la investigación en generalización se hace necesario que participen de forma conjunta disciplinas como la Cartografía, Ciencias de la Computación o las Matemáticas.

Es conveniente que una transformación cumpla una serie de criterios para su aplicación en generalización (Fritsch, 1997, p. 78, tras Mokhtarian y Mackworth, 1992):

- *Unicidad*: implica una representación idéntica cuando dos curvas sean iguales, es decir, que sea una transformación biyectiva.
- *Reversibilidad*: garantiza la transformación directa e inversa entre dos representaciones diferentes.

- *Estabilidad*: asegura que el parecido de dos representaciones diferentes si dos líneas son parecidas, y viceversa.

Sería fácil comprobar que se cumplen, efectuando una pequeña perturbación de la línea antes de retornar al modo vectorial y comprobando que el resultado final es parecido a la línea original. A estos criterios habría que añadir otros que garanticen su aplicación práctica en el ámbito de la generalización: eficiencia, facilidad de implementación y codificación de las propiedades geométricas.

Destacan los trabajos realizados por el Institut Géographique National de Francia (Fritsch, 1997; Affholder, 1993; Plazanet et.al, 1995), que han ensayado la posibilidad de representar una línea mediante aproximación matemática mediante arcos cúbicos, obteniendo resultados muy esperanzadores, así como representaciones frecuenciales con series de Fourier y wavelets.

II.5.2. Caracterización de la forma de una línea

Ya se ha comentado que es necesaria la formalización del conocimiento geométrico para poder atacar de forma adecuada el problema de la automatización de la generalización. Es necesario saber qué es y cómo es aquello que se pretende generalizar, antes de elegir los operadores de generalización necesarios y concretar los algoritmos a aplicar.

Por ejemplo, en el caso de las carreteras, su sinuosidad aporta información respecto a su peligrosidad o al tiempo que lleva el desplazamiento de un sitio a otro. Por tanto, se trata de características que deben ser mantenidas durante el proceso de generalización (Ruas y Plazanet, 1996). Esto, a su vez conlleva la elección de determinados operadores de generalización y determinados algoritmos.
En primera instancia podría pensarse que basta con conocer la naturaleza del objeto, ya que las vías de ferrocarril suelen ser de curvatura muy regular, o los límites administrativos angulosos, pero éstas no dejarían de ser indicaciones muy

poco precisas de su geometría, "su geometría no es lo suficientemente homogénea para evitar un análisis geométrico de cada objeto" (Ruas y Plazanet, 1996).

Esta fase del proceso de generalización no es algo que ha surgido con su automatización. También estaba presente en la tradicional generalización manual. El cartógrafo comenzaba por observar detenidamente el elemento lineal para advertir qué tipo de línea tenía ante sí (río, carretera...), seguidamente centrarse en su forma (si es sinuosa o no, etc...) y acto seguido acometer la tarea de su generalización en función de este conocimiento geométrico recién adquirido. McMaster (1995), comenta que los individuos parecen juzgar la forma de una línea atendiendo a dos criterios: la direccionalidad de la línea y su sinuosidad básica.

Además, la descripción de la geometría de una línea ha de llevar implícita la tarea de la segmentación de la línea en secciones consecutivas de diferentes características geométricas, pues no es correcto "generalizar" la descripción de su geometría refiriéndola a toda su longitud. Para aplicar correctamente las herramientas de generalización, es necesario captar los cambios que sufre su forma, ya que es bien sabido que aquellas ofrecen resultados de calidad muy variable en función de la variabilidad de ésta.

No obstante, este apartado se dedicará a detallar diversas medidas que se han aplicado o concebido expresamente para captar la forma de una línea o sección de línea, sin entrar a analizar el proceso de segmentación, al que se dedicará íntegramente el apartado II.6 de este documento.

Diversos autores se han aproximado a la caracterización de la forma de la línea de distinta manera: Medidas de atributos de la línea, caracterización cuantitativa de las líneas cartográficas o medidas de forma (Skopeliti y Tsoulos, 1999). No obstante la idea de trasfondo permanece: la captación del conocimiento geométrico de la línea (geometría interna en AGENT, 1999). En el presente documento se las denominará *medidas caracterizadoras*.

II.5.2.1. La matriz distancia-dirección

McMaster (1995) concibe la denominada *matriz distancia-dirección* (ver Figura II.12) para tratar de sintetizar la geometría de la línea de una forma cuantitativa fácilmente interpretable y comparable. Esta matriz pretende discretizar el módulo y dirección del vector correspondiente a cada segmento de la línea. Para ello basta con colocar el extremo inicial del vector en el centro de la matriz y acumular una unidad en la celda a la que apunte el extremo del vector.

Para tratar de distinguir distintas categorías de líneas, aplica el análisis cluster sobre las matrices generadas para un conjunto de líneas. A partir del análisis del dendograma de un análisis cluster jerárquico decidió realizar tres grupos: "líneas suaves rectilíneas", "líneas sinuosas" y "líneas con tendencia multi-direccional", con resultados bastante esperanzadores.

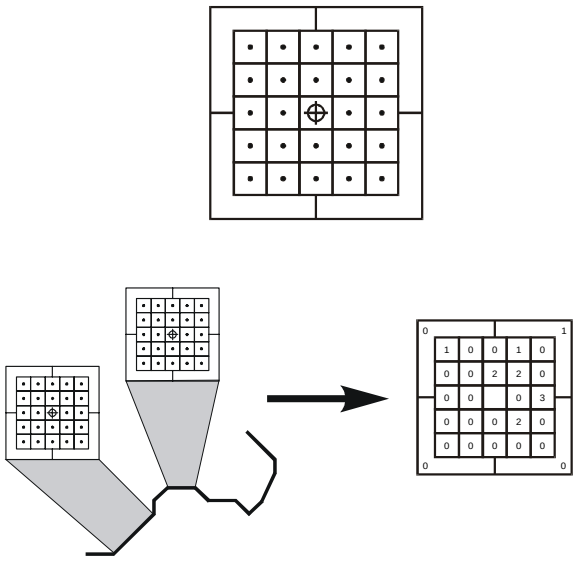


Figura II.12 - Matriz distancia-dirección de McMaster (1995).

II.5.2.2. La dimensión fractal

En 1949, Hugo Steinhaus percibió la paradoja del aumento de la longitud de las líneas de la naturaleza cuanto más exactas son las medidas que se realizan, llegando a cuestionar si tiene sentido hablar de la verdadera longitud, por ejemplo, de un río. Richardson (1961) detectó la existencia de una relación casi lineal en-

tre la longitud total de la línea y la resolución a la que se calcula, en el espacio logarítmico, un hecho que posteriormente tendría en cuenta Mandelbrot (1967, 1982) para definir el concepto de dimensión fractal.

Así, la longitud de una línea curva se puede medir efectuando $N(\varepsilon)$ pasos de longitud ε (ver ejemplo en la Figura II.13). La longitud aproximada será, por tanto, $L = N(\varepsilon) \times \varepsilon$. En curvas rectificables, es decir, en aquellas que admiten el cálculo de la longitud de su arco sobre un intervalo real dado, se tiene que cuando ε tiende a 0, el valor de $N(\varepsilon) \times \varepsilon$ aumenta tendiendo a un límite constante a. Es decir:

$$N(\varepsilon) = a\frac{1}{\varepsilon} \qquad N(\varepsilon)\varepsilon = a$$

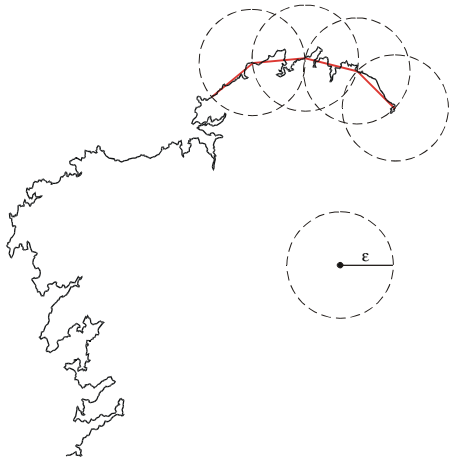


Figura II.13 - Aplicación del método del "walking divider" a la línea de costa gallega.

Pero para líneas fractales se establece que:

$$N(\varepsilon)\varepsilon^{D} \approx a$$

Es decir que la longitud L se puede obtener mediante la siguiente expresión, en la cual D es la dimensión fractal.

$$L = N(\varepsilon)\varepsilon \approx a\varepsilon^{1-D}$$

Para determinar D, se ajusta una recta de regresión a un conjunto de valores (log ε,log $N(\varepsilon)$) y se determina su pendiente, que se identifica con el valor $-D$

(Mandelbrot, 1967, 1982). El índice de correlación de la recta ofrecería una indicación de la fiabilidad del valor obtenido.

A este forma de calcular *D* se le denomina "walking divider" (implementado de forma algorítmica por Shelberg et.al, 1982), el cual está basado en el método manual empleado por Richarson (1961). Su mayor dificultad reside en la elección de los valores mínimo y máximo de ε para construir la recta. En este sentido se han ensayado diversas alternativas por distintos autores:

- Shelbert (Shelbert et.al, 1982) propone partir de un valor mínimo de la mitad de la longitud del segmento medio y aplicar una progresión geométrica, pero no comenta exactamente cuantas veces, sino que deja un margen entre 5 y 8.
- Longley y Batty (1989) fijan como valor máximo aquel con el que se dividía la línea en siete pasos.
- Jansinski (1990) efectúa diversas pruebas, fijando como paso mínimo inicial aquel igual al segmento de longitud más pequeña, al segmento de longitud media y a la mitad del segmento de longitud media, aplicando una progresión geométrica hasta alcanzar dos diferentes condiciones finales: que se puedan efectuar tres y cinco pasos para recorrer toda la línea. Sus resultados evidencian que el valor estimado de la dimensión fractal es muy sensible a estas dos variables.
- Plazanet (1996) emplea la propuesta de Broscoe y Prashker (1991): el mínimo sería la mitad de la longitud del segmento medio de la línea, y el máximo la mitad de la longitud total de la línea.

También existen críticas respecto a la idoneidad de una regresión lineal, ya que suele detectarse cierta curvatura en la línea que une los puntos sobre los que se efectúa el ajuste (Buttenfield, 1989; Jasinski, 1990).

Una vez obtenido el valor de la dimensión fractal de una línea, puede oscilar entre los valores 1 y 2, siendo el primero el caso de una línea recta y el segundo el de una línea diseñada para rellenar el espacio. Una de las propiedades básicas de

las líneas fractales es que pueden ser estadísticamente autosimilares (Mandelbrot, 1982), es decir, que sus formas se propagan al ir modificando la resolución, o escalas, a la que se observan.

En 1987, se vislumbraba la dimensión fractal como "el parámetro individual más importante de una forma cartográfica irregular" (Goodchild and Mark, 1987). Para Plazanet (1996, p. 88), puede ser considerada como una medida global, susceptible de proporcionar indicaciones de la complejidad de una línea; teóricamente cuanto mayor es la dimensión fractal, mayor es la complejidad de la línea, es decir, sinuosa a todos los niveles.

El empleo de la dimensión fractal ha sido experimentado por varios autores en el campo de la generalización cartográfica. Uno de los primeros trabajos fue realizado por Müller (1986, 1987), quien comenta que la preservación de la dimensión fractal puede ser empleada para apreciar la calidad de un algoritmo de generalización, o para estudiar la eliminación de los detalles, sobre todo en líneas que desde el punto de vista estadístico son autosemejantes. Además, la dimensión fractal ha sido empleada para detectar y caracterizar la forma de los elementos lineales (Jasinski, 1990; Buttenfield, 1989, 1991; Plazanet, 1996; Scopeliti y Tsoulos, 1999)

En relación al concepto de autosimilaridad, Buttenfield (1989) distinguió dos grandes grupos de objetos geográficos: los elementos geográficos *naturales*, como pueden ser las líneas de costa, los elementos de la red hidrográfica, las curvas de nivel, etc, que mostrarían mayores niveles de autosimilaridad estadística que los elementos geográficos *culturales*, que serían diseñados o definidos por el ser humano, como es el caso de las vías de comunicación, los límites administrativos, etc. Esto da pie a las palabras de Jasinski (1990), para el que el modelo fractal no puede ser aplicado como medida de la complejidad de una línea, en tanto no es una medida universal, sino solamente aplicable a algunos elementos lineales, o parte de ellos.

Así, Jasinski (1990) sintetiza como principales problemas detectados para el empleo de la dimensión fractal en cartografía: la fiabilidad de los métodos para estimar la dimensión fractal y la desconfianza de que las formas geográficas sean estadísticamente autosimilares. Esto limita su empleo en el ámbito cartográfico y por ejemplo, provoca que no sea suficiente a la hora de caracterizar la complejidad de un elemento lineal, debiendo ser complementada con otras medidas caracterizadoras.

II.5.2.3. Medida de entropía

Le entropía es una magnitud física que sirve para medir el desorden de un sistema. Un sistema tendrá mayor entropía y estará más desordenado que otro cuando el número de estados diferentes en los que se puede encontrar al primero es mayor que el del segundo.

Su empleo en cartografía se deriva de la teoría de la comunicación de Shannon (1948). La información es tratada como magnitud física y para caracterizar la información de una secuencia de símbolos se utiliza la entropía. Cuantos más estados permitidos tiene un sistema, mayor es la información que puede almacenar y proporcionar. La medida de la entropía puede aplicarse a información de cualquier naturaleza, y permite codificarla adecuadamente, indicando los elementos de código necesarios para transmitirla, eliminando toda redundancia.

De acuerdo a esta teoría, la información útil *R* de un mensaje *X* se obtiene sustrayendo la incertidumbre $H_y(X)$ a su entropía *H(X)*

$$R(X) = H(X) - H_y(X)$$

El cálculo de la entropía se realiza mediante la siguiente fórmula:

$$H = p_1 \log(1/p_1) + p_2 \log(1/p_2) + \ .. \ p_m \log(1/p_m)$$

donde:

- *H* es la entropía

- las *p* son las probabilidades de que aparezcan diferentes códigos (o símbolos o estados)
- *m* es el número total de códigos.

Por ejemplo, utilizando el logaritmo en base 2, y por tanto midiendo la entropía en bits, el lanzamiento de una moneda al aire para ver si sale cara o cruz (dos estados con probabilidad 0.5) tiene una entropía:

$$H = 0{,}5\ log_2(1/0{,}5) + 0{,}5\ log_2(1/0{,}5) = 1\ bit$$

Plazanet (1996), siguiendo a Bjørke y Midtbø (1993), interpreta la entropía como una medida de angularidad, concretamente de los ángulos que forman los segmentos consecutivos de una polilínea. Así, en una polilínea existirán *n* ángulos, cada uno con un determinado ángulo α, lo que permitirá calcular las distintas probabilidades $p(\alpha)$, calculando la entropía como:

$$H(X) = \sum_{\alpha=0}^{2\pi} p(\alpha) log(1/p(\alpha))$$

Para Plazanet, así se obtendría una indicación de la sinuosidad, pero excesivamente local, por lo que propone realizar el cálculo de la entropía a partir de la distancia existente entre los puntos de inflexión de la línea. De esta forma, un mayor valor de entropía significaría una menor homogeneidad. Siguiendo esta propuesta realizó la clasificación de un conjunto de líneas de carreteras de montaña (ver Figura II.14), que para la autora son bastante satisfactorios, pero no puede discernir si los problemas detectados se deben a la falta de significación de la medida o a problemas en la detección de los puntos de inflexión.

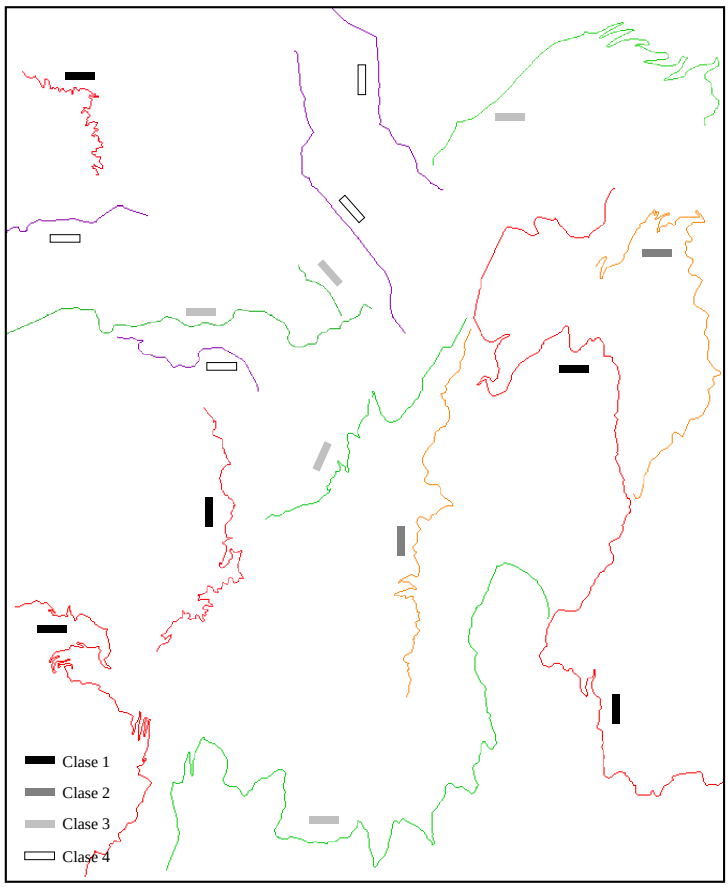


Figura II.14 - Clasificación de una muestra de líneas según su entropía (Plazanet, 1996, p. 89). De mayor a menor entropía: clase 1, clase 2, clase 3, clase 4.

II.5.2.4. Medidas geométricas

Una de las primeras ideas que surgieron hace años es la de la existencia en cualquier línea (salvo que sea prácticamente rectilínea) de una serie de puntos críticos que definen su forma principal. Es decir, hay puntos de la línea que pueden servir para sintetizar su forma principal, como pueden ser los puntos de inflexión, los picos, los fuertes cambios de dirección, etc. Esto dio pie al desarrollo de algunos algoritmos de eliminación de puntos que se han fundamentado en su existencia (Douglas-Peucker, 1973; Thapa, 1989; Visvalingam y Whyhatt, 1993).

Existe una relación muy estrecha entre estos algoritmos y el cálculo de medidas geométricas sobre la línea, ya que éstas se emplean en muchos de ellos para gobernar su funcionamiento. Es por ello por lo que pronto surgió la idea de cap-

tar la capacidad de uno de estos algoritmos a la hora de mantener la geometría de la línea, a través de las llamadas *medidas evaluadoras de la generalización* (que se comentarán en el apartado II.5.6). Esto dio pie a pensar que también se pueden emplear medidas geométricas para sintetizar la geometría.

Estudiando la selección de medidas geométricas, Jasinski (1990) considera cuatro aspectos como los más importantes a la hora de estudiar la forma de una línea: angularidad, longitud relativa, densidad o frecuencia del detalle y dimensión fractal. Siguiendo los trabajos anteriores de McMaster (1986) y de Buttenfield (1991) seleccionó ocho medidas geométricas que cubrieran los cuatro aspectos citados:

- *Angularidad media*. Para cada punto se calcula el ángulo entre la dirección del segmento anterior y la del siguiente, que puede variar entre 0 y 180º, sin tener en cuenta el signo.
- *Coeficiente de variación de la angularidad media*.
- *Ratio de curvilinearidad*. Es el número de puntos de inflexión de la línea.
- *Longitud media de los segmentos*.
- *Coeficiente de variación de la longitud media de los segmentos*.
- *Varianza del error*: es el desplazamiento perpendicular medio de cada punto respecto a la línea de anclaje (definida ésta como el segmento recto que une el primer y último punto de la línea).
- *Coeficiente de variación de la varianza del error*.
- *Dimensión fractal*.

Jasinski se sirve del análisis de componentes principales para estudiar la correlación entre todas estas medidas. Encontró una fuerte correlación entre la longitud media de los segmentos y las medidas de angularidad media y ratio de curvilinearidad. También concluyó que la dimensión fractal mantiene poca relación con el resto de medidas.

Plazanet (1995, 1996, 1997) enumera una serie de medidas que pueden efectuarse sobre una curva aislada (Figura II.15). En este caso, una curva viene definida como aquella que media entre dos puntos de inflexión consecutivos, y por tanto es necesario un suavizado previo, realizado con un filtrado gausiano. El punto de máxima curvatura es el vértice S. El segmento recto que une los dos puntos de inflexión es la línea-base. Algunas de las medidas señaladas son:

- *Altura de S sobre la línea-base* (altura de la curva).
- *Longitud curvilínea de la línea*. Es decir, la suma de la longitud de los segmentos que integran la curva.
- *Longitud de la línea-base*. Esto es, la distancia euclídea entre el primer y último puntos de la curva.
- *Ratio entre la longitud curvilínea y la longitud de la línea-base.*
- *Ángulo que forman las dos tangentes a la línea en sendos extremos de la curva.*
- *Área entre la curva y la línea-base.*
- *Área del triángulo formado por la línea base y el vértice S.*
- *Proyección del vértice S sobre la línea-base.*

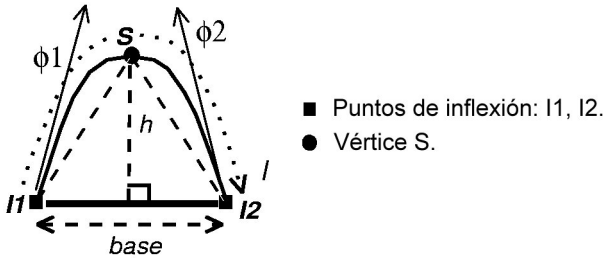


Figura II.15 - Medidas sobre una curva aislada (Plazanet, 1995, 1996, 1997).

Para una línea completa podrían calcularse la media, mediana, varianza, mínimo y máximo de cualesquiera de estas medidas, e incluso otras medidas más tales como:

- *Número total de curvas*.

- *Ángulos en valor absoluto en la línea de puntos de inflexión* (ésta es la línea que une aquellos consecutivamente).
- *Ratio entre la longitud de la línea de puntos de inflexión y la de la línea original.*

Todas estas medidas han de ser sometidas a un estudio que permita elegir y normalizar aquellas que sean significativas y no correladas. Plazanet, Bigolín y Ruas (1998, p. 325) ensayan una clasificación global de carreteras empleando dos medidas: el número de puntos de inflexión y la media del cociente entre la altura y la línea base de una curva, considerando como curva aquella existente entre dos puntos de inflexión consecutivos. Aplicando un análisis cluster no jerárquico mediante el algoritmo de las K-medias clasifican una muestra de líneas en: 1 - baja sinuosidad, 2 - baja sinuosidad con micro-inflexiones (granularidad), 3 - alta sinuosidad con pequeñas curvas y 4 - alta sinuosidad con curvas de tamaños diversos.

Hablando de medidas globales sobre toda la línea, los conceptos de sinuosidad, homogeneidad o complejidad han de ser explicitados. Para Plazanet (Plazanet et.al, 1995), se puede decir que una línea será tanto más compleja cuanto más sinuosa, heterogénea o densa sea. Esta autora explica estos tres términos de la siguiente forma:

- *Sinuosidad*. Una línea es considerada sinuosa si contiene muchos cambios de dirección o si incluye determinados tipos de curvatura (espirales, horquillas...).
- *Homogeneidad*. La falta de homogeneidad viene dada en el momento en que diferentes partes de la línea tienen diferentes niveles de sinuosidad.
- *Densidad*. Vendría reflejada por la cantidad de detalles.

En Plazanet (1996) se pueden encontrar algunos indicadores globales en cuanto a la complejidad, homogeneidad y sinuosidad.

Medidas de complejidad:

- *Razón entre el número de puntos de inflexión y la longitud de la línea*. Previamente es necesario un leve suavizado para eliminar las microinflexiones debidas a la digitalización de la información.
- *Resistencia al suavizado*. Si una línea es sinuosa a todos los niveles de análisis (global o locales) mayor será su resistencia al suavizado. Este valor se puede estimar mediante una expresión en función del parámetro σ de un suavizado gausiano (Rosin, 1993, 1994):

$$R(\sigma) = \sigma \times número\ de\ puntos\ de\ inflexión\ tras\ el\ suavizado$$

Medidas de homogeneidad:

- *Desviación típica de la longitud de la línea-base*. Puede ser un parámetro muy valioso para decidir si se puede segmentar la línea en secciones más homogéneas:

$$\frac{\sigma(distancia(PI_i, PI_{i+1}))}{longitud\ de\ la\ línea}$$

- *Desviación típica del número de puntos característicos*. Ofrecen una idea de la homogeneidad en la complejidad de las curvas de la línea.
- *Desviación típica de la altura de las curvas*. Es útil para estudiar la amplitud de las curvas.
- *Diferencia entre longitud máxima y mínima de la línea-base*. Permite evidenciar irregularidades más locales en una línea:

$$\frac{max(distancia(PI_i, PI_{i+1})) - min(distancia(PI_i, PI_{i+1}))}{longitud\ de\ la\ línea}$$

Medidas de sinuosidad:

- *Media del ratio entre la altura de la curva y la longitud de la línea-base*. Puede ser útil para indicar si las principales curvas que integran la línea son más o menos complejas.

- *Media del ratio entre la longitud curvilínea y la de la línea-base*. Da idea de la complejidad media de las curvas fundamentales que forman la línea.
- *Media de la superficie que media entre la línea y la línea-base*. Un mayor valor indicará mayor amplitud de las curvas.
- *Número medio de puntos característicos por curva*. Es una indicación de la complejidad media de las curvas. Estos puntos característicos deben ser definidos para poder detectarlos.
- *Media de los valores absolutos de los ángulos de la línea de puntos de inflexión*. Se trata de un indicador de la sinuosidad global de la línea.

Entre todas estas medidas Plazanet escoge como medida más robusta para la estimación de la complejidad global de una línea, la de *razón entre el número de puntos de inflexión y la longitud de la línea*, y es la que da base a la puesta en práctica de sus trabajos en segmentación de elementos lineales. Sin embargo, cree que es insuficiente para estimar la homogeneidad global, por lo que estima necesaria otra medida, como puede ser la de *diferencia entre longitud máxima y mínima de la línea-base* o la de *desviación típica de la longitud de la línea-base.*

Dutton (1999), aporta un punto de vista ligeramente distinto en cuanto a la evaluación de la sinuosidad de una línea, ya que calcula un valor de sinuosidad local S_V para cada vértice V de la línea. Este se corresponde con el ratio de la distancia sobre ± k vértices a lo largo de la línea y la longitud de la línea de anclaje (que une el primer y último punto considerados):

$$S_{V_k} = \frac{\sum d_{i,i+1}}{d_{v-k,v+k}}$$

Se trata, por tanto, de una aplicación local de una de las medidas globales de sinuosidad sugeridas por Plazanet. Si los puntos son colineales, el resultado será nulo, aunque Dutton indica que lo normal es obtener valores inferiores a 2. Para aumentar la robustez de la medida, este autor propone obtener varios valores de S_V para cada vértice, modificando el número de vecinos que entran en el cálculo, y luego efectuar un promedio:

$$S_{V_{m,n}} = \frac{\sum S_{V_{k=m,n}}}{n-m+1}$$

Si queremos estimar de forma más local la sinuosidad, podemos considerar *m=1* y *n=2*. Un resultado menos local se obtendría con *m=2* y *n=7*. Lógicamente, para asimilar un valor de sinuosidad para toda la línea se podría calcular un parámetro representativo de los valores S_V de la línea, como puede ser una media aritmética. También se podrían emplear los valores de S_V para detectar cambios de sinuosidad que permitan segmentar la línea en secciones más homogéneas.

También hay que resaltar la medida propuesta por Veregin (1999), el *error potencial*, que pretende ser útil para estimar, a priori, cual puede ser el error introducido por un algoritmo de filtrado de puntos, y por tanto, puede ayudar a elegir un algoritmo y/o porcentaje de eliminación de puntos más apropiado. Su cálculo es muy sencillo, ya que consiste en calcular el promedio de la superficie del triángulo que forma un punto con sus dos vecinos, siempre que la altura, perpendicular a la base formada por los puntos anterior y posterior, sea inferior a un ancho de banda determinado. Esta medida es sobre todo adecuada cuando el número de puntos eliminados no es muy elevado.

Por último, Van de Poorten y Jones (2002) plantean una serie de medidas geométricas sobre la triangulación Delaunay en la que basan su método de generalización mediante la eliminación de ramas (curvas) enteras de la línea: área de la curva (obtenida como la suma del área de la triangulación de la curva), longitud del perímetro de la curva (suma de los lados exteriores), alargamiento de la curva (longitud del esqueleto más largo), etc.

II.5.2.5. La detección de curvas de Wang y Müller

Wang y Müller (1998) presentan un método de generalización basado en el análisis de formas, lo que Brassel y Weibel (1998) denominan "reconocimiento de estructuras" o lo que es la "evaluación cartométrica" para McMaster y Shea (1992). Concretamente el método persigue la manipulación de las curvas de una línea,

derivándose de las directrices de la generalización manual de la Swiss Society of Cartography (1977).

Para los autores, las curvas "están ocultas tras las coordenadas x-y de la línea" y reflejan una estructura que debe extraerse, ya que las decisiones que toman los cartógrafos en el proceso de generalización dependen de las características de las curvas y de las relaciones que hay entre ellas. La generalización no se efectúa sobre cada vértice de la línea, sino que se aplica sobre las curvas, formadas por numerosos vértices.

Por tanto, una línea es una secuencia de curvas y ha de definirse lo que se entiende por curva: es la parte de la línea que contiene una serie de vértices consecutivos con el mismo signo de inflexión y con signo contrario en la inflexión de sus dos vértices extremos. Esto supone que: a) Las curvas positivas y negativas siempre están una junto a otra; b) cada curva linda con otra, cubriendo todos los vértices de la línea. Un ejemplo de la detección de las curvas de una línea puede observarse en la Figura II.16.

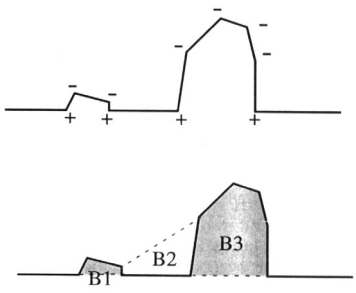


Figura II.16 - Ángulos de inflexión en cada vértice y curvas detectadas (B1, B2 y B3) (Wang y Müller, 1998).

A cada curva se le asignan una serie de atributos:

- *Tamaño*: es el área del polígono formado por la curva y su línea-base (línea que une el primer y último punto). Es adecuado para la selección o eliminación de curvas. Este tamaño se corrige mediante la siguiente expresión:

$$Tamaño\ ajustado = area\ (0.75 / cmp)$$

- *Forma*: Se deriva del índice de compacidad (*cmp*), definido como el ratio entre el área del polígono y la del círculo cuya circunferencia tiene la misma longitud que la del polígono. Se coge como forma estándar la de la mitad de un círculo, cuyo *cmp* es 0.75

Además, una curva puede considerarse como *curva aislada* o bien puede formar parte de una serie de *curvas similares*.

- Una curva será *aislada* si las curvaturas medias a ambos lados de la curva son menores a cierto umbral y siempre mucho menores que la curvatura media de la propia curva.
- Serán *similares* aquellas curvas que sean parecidas en cuanto al tamaño y a su forma. Para ello se emplean los dos atributos definidos anteriormente más la longitud de la línea-base. Se forma así un vector tridimensional por cada curva y se puede calcular la distancia euclídea entre dos curvas.

Para efectuar la generalización de una línea, sobre las curvas detectadas se aplica el siguiente proceso:

- Si se trata de una *curva aislada*, se le aplica el operador de exageración.
- En caso contrario, si forma parte de un conjunto de *curvas similares*, se le aplica el operador de combinación, uniendo tres curvas en una sola.
- Si no se cumple ninguna de las dos condiciones anteriores, se comprueba si se trata de una *curva mínima local*, con tamaño menor a sus dos vecinas. En caso positivo se comprueba si está por debajo de un umbral de superficie y se elimina.

II.5.3. Algoritmos de eliminación de puntos

En las décadas de los 70 y 80 fue desarrollada una gran cantidad de métodos para eliminar puntos de los elementos lineales del mapa. Sin embargo, la principal motivación para su desarrollo era la falta de espacio lógico para el almace-

namiento de las bases de datos, esto es, la compactación de información, cuando hubiera sido deseable una perspectiva más cartográfica.

Al proceso de eliminar una parte de los puntos que integran una línea para obtener un trazado más simple, por ejemplo con el objetivo final de aplicar una reducción de escala, solía identificarse unívocamente con el operador "simplificación" aplicado sobre los elementos lineales (un ejemplo de ello podemos verlo en Clayton, 1985 ó McMaster y Shea, 1992). Es decir, se consideraba que la simplificación pretendía disminuir la cantidad de información necesaria para representar una línea, reteniendo solo aquellos puntos que definen mejor la geometría para el nivel de generalización deseado. Los beneficios alcanzados eran la reducción del tiempo de trazado del mapa, del tiempo de procesamiento de los datos y del espacio de almacenamiento necesario (McMaster y Shea, 1992).

Sin embargo, en la actualidad el concepto de simplificación de una línea es más rico, ya que se considera que simplificar una línea consiste en retener sus características más destacadas, en función de la escala final y el uso del mapa, o dicho de otra forma, eliminar los detalles innecesarios (McMaster, 1986, tras Robinson et.al, 1978). Y "simplificar elementos puede requerir algo más que meramente eliminar vértices" (Dutton, 1999). Por este motivo, se ha denominar a este apartado genéricamente como "algoritmos de eliminación de puntos", ya que en nuestra opinión no es correcto considerarlos como algoritmos de simplificación. También podrían englobarse bajo una denominación genérica de "algoritmos de filtrado", en tanto filtran la secuencia de puntos de la línea, reteniendo sólo un subconjunto de ellos. Pero esta denominación no sería exclusiva de este tipo de algoritmos, ya que pueden existir otros cuyo objetivo sea filtrar cualquier otra característica de la línea, como puede ser su curvatura. Sería más adecuado, por tanto, concretar más el concepto y hablar de "algoritmos de filtrado de puntos".

Esta redefinición de este tipo de algoritmos conlleva intrínsecamente una reflexión sobre su utilidad en generalización cartográfica, ya que se acaba de referir que no pueden ser considerados a la ligera como algoritmos de simplificación. En numerosas ocasiones se ha comprobado cómo algunos de ellos ofrecían resul-

tados muy poco deseables al aplicarlos sobre determinado tipo de elementos lineales y sobre todo al emplearlos para grandes saltos de escala que implican un mayor filtrado. Más bien hay que considerarlos como herramientas útiles que se pueden emplear en procesos de generalización y que deben coordinarse con otro tipo de técnicas para alcanzar la meta final.

Los algoritmos de eliminación de puntos tienen su fundamento en los trabajos de Attneave (1954), quien advirtió de la existencia de puntos con una mayor riqueza informativa, y que por tanto varios de ellos podrían ser suficientes para retener la forma de una línea. Para Dutton (1999) la llegada de la cartografía digital acrecentó esta perspectiva respecto a la geometría de una línea, ya que se tenía la sensación de que los puntos adimensionales que forma la línea realmente existen y que su importancia puede ser cuantificada y cualificada.

Diversos autores han escrito acerca de los problemas e inconvenientes de los algoritmos de eliminación de puntos. Estas aportaciones no hacen sino corroborar la necesidad de reubicar este tipo de métodos como un tipo más de herramientas para poder ser utilizadas en el complejo proceso de generalización cartográfica:

- Concebidos como métodos de aproximación de curvas, esto es, como técnicas para representar una curva mediante una polilínea, es engañoso su empleo en la generalización de líneas (Li y Sui, 2000).
- Están concebidos para la reducción de información, más que para la generalización (Li y Openshaw, 1992; Fritsch, 1997).
- Al seleccionar puntos elegidos por su importancia global se pueden producir resultados que no sean óptimos al simplificar los elementos del mapa (Dutton, 1999).
- La calidad del resultado parece variar según las características de la línea (Buttenfield, 1991). Existen diversos estudios que han evidenciado la dificultad de la aplicación de estos algoritmos a diferentes elementos lineales (Plazanet, 1997).

- Su aplicación puede ser un proceso con mucha incertidumbre, que precisa el tanteo del parámetro (Herbert et.al, 1992).
- La línea resultante puede exhibir picos que provoquen una visión topológicamente distorsionada de la morfología de la línea (Li y Openshaw, 1992). Por ejemplo, son incapaces de garantizar que se producen intersecciones de la línea consigo misma tras su aplicación (Li y Sui, 2000). Estos problemas se presentan sobre todo cuando los cambios de escala son importantes (Fritsch, 1997, p. 64).
- Dado que el error presente en una línea es una combinación del error posicional de sus puntos y del error debido a la elección de una muestra de éstos, muchos usuarios emplean estos algoritmos sin un significado claro de los errores que pueden estar introduciendo (Veregin, 2000).

En suma, este tipo de algoritmos mantienen plena su vigencia, solamente ha cambiado la perspectiva que se tiene de su aplicabilidad en la generalización de elementos lineales, que aún necesita estudios que la delimiten. Como ejemplo, el más representativo de este tipo de algoritmos, el de Douglas-Peucker, es considerado como una rutina estándar tanto en libros de texto como en paquetes SIG, pero han de conocerse sus limitaciones.

Los algoritmos que se presentan a continuación pretenden ser una muestra representativa que permita conocer el funcionamiento y propiedades este tipo de métodos. En caso de querer ampliar el estudio de los mismos, existen numerosas referencias en la bibliografía, como pueden ser McMaster y Shea (1992) o Clayton (1985).

II.5.3.1. Clasificaciones de los algoritmos

Existen varias clasificaciones de las técnicas de eliminación de puntos en elementos lineales, procedentes de diversos autores, según distintos criterios. En este apartado se resumirán brevemente algunas de ellas.

Clayton (1985, p. 6) divide de forma sencilla los "algoritmos de eliminación sistemática de puntos" en dos categorías: a) *de eliminación secuencial*: solo va interviniendo una parte de la línea en el cálculo, hasta que se llega al final de la línea; b): *de eliminación global*: consideran la línea en su conjunto. Por otro lado, Dutton (1999), hace referencia a la clasificación realizada por Douglas y Peucker (1973), que distingue algoritmos de alcance local, regional y global.

Pero quizá la clasificación más conocida sea la referida por McMaster y Shea (1992). Estos autores la realizan atendiendo a la fracción de línea que interviene en el cálculo del algoritmo, de forma que dividen la categoría de eliminación secuencial sugerida por Clayton en cuatro categorías diferentes, conservando la categoría global. De esta forma, distinguen las siguientes cinco categorías de algoritmos:

- *Independientes del punto.* Cada punto de la línea se considera aislado del resto, esto es, no se tiene en cuenta la relación de cada uno respecto a sus vecinos o la línea completa. Son métodos cuyo único objetivo es reducir el almacenamiento en disco, despreocupándose totalmente de cualquier fundamento de tipo cartográfico. No obstante, los algoritmos que los implementan son muy utilizados en el proceso de digitalización para reducir en un primer momento el número de coordenadas a registrar. Ejemplos de algoritmos de este tipo son: "uno de cada" (Tobler, 1964) o una selección aleatoria de puntos (Robinson et.al, 1978).
- *De procesamiento local.* Junto con los anteriores, se trata de los métodos más simples. La perspectiva local supone un análisis conjunto del punto de interés y sus vecinos inmediatamente anterior y posterior para evaluar su mantenimeinto o eliminación. En esta categoría se sitúan el algoritmo de curvatura local (Jenks, 1981), el de Jenks (McMaster, 1983) o el del cambio angular entre puntos (McMaster, 1987).
- *De procesamiento local extendido, con constricciones.* En este caso son secciones de línea las que intervienen en el cálculo. El número de puntos participantes viene definido por criterios de distancia, angulares o de núme-

ro de puntos. Algunos de ellos son el algoritmo de Lang (Lang, 1969) o el de Opheim (Opheim, 1982).

- *De procesamiento local extendido, sin constricciones.* Análogo a la anterior categoría, la diferencia está en que el número de puntos intervinientes viene definido por la complejidad de la línea, no por un criterio algorítmico. Un ejemplo es el algoritmo de Reumann-Witkam (Reumann y Witkam, 1974) o el de Thapa (Thapa, 1988).
- *Globales.* Consideran la línea completa, tratando de seleccionar puntos críticos iterativamente. Estos métodos están más cerca que los anteriores del procesamiento holístico de una generalización manual. A este tipo pertenecen el algoritmo de Visvalingam (Visvalingam y Whyhatt, 1993), así como el asiduamente utilizado algoritmo de Douglas-Peucker (Douglas y Peucker, 1973).

Fritsch (1997) distingue entre algoritmos *ascendentes*, *descendentes* y *al vuelo*. Los primeros van seleccionando recursivamente los puntos de la línea original más importantes, mientras los segundos van eliminando los menos importantes, también recursivamente; los terceros van recorriendo la línea de principio a fin, estableciendo una línea anclaje-flotante móvil, donde el punto de anclaje irá marcando los puntos a mantener. Como ejemplos de cada tipo se pueden citar: Douglas-Peucker (ascendente), Visvalingam, Jenks (descendentes), Lang, Opheim o Thapa ("al vuelo"). Los algoritmos ascendentes y descendentes ofrecen un resultado invariable, independiente del sentido de lectura de la línea, y permiten prefijar el número de puntos a extraer de la línea original. Ninguna de estas características se cumple en los algoritmos "al vuelo".

En los siguientes apartados se detallan algunos de los algoritmos de eliminación de puntos más conocidos: Douglas-Peucker, Visvalingam y Thapa.

II.5.3.2. Algoritmo de Douglas-Peucker

Este es el algoritmo más clásico de generalización por excelencia y es el único que suele ser incluido en programas comerciales de cartografía digital y S.I.G.,

p.e. Arc/Info (ESRI, 1994), System9 (UNISYS, 1993), además de estar siendo empleado por instituciones cartográficas para disminuir el tamaño de sus bases de datos digitales o para la generación de nuevas cartografías a escala menor, p.e. la Carta Digital del Mundo (Fico, 1992). Incluso se llega a decir que es realmente el único algoritmo de generalización de líneas de carácter global en uso (Dutton, 1999, p. 36).

Ha sido estudiado, comparado y analizado a fondo por muchos, por no decir todos, los que trabajan en generalización, con unos resultados que han sido tradicionalmente alabados durante las décadas de los 70 y 80 (Buttenfield, 1986; Jasinski, 1990), ya que supuestamente ofrecía resultados similares a los de la simplificación manual (Clayton, 1985, p. 13; White, 1985; Buttenfield, 1991) y porque minimiza el desplazamiento, o distorsión geométrica, respecto a la línea original (McMaster, 1986, 1987; White, 1985).

En cambio, en años posteriores surgieron estudios que evidenciaron sus deficiencias, ya que en numerosas ocasiones ofrece resultados poco deseables, incluso incorrectos (Visvalingam y Whyatt, 1990; Beard, 1991a; Zhan y Buttenfield, 1996; Li y Sui, 2000). A pesar de todo, sorprende ver que todavía es la referencia que se escoge para evaluar nuevos algoritmos o técnicas de generalización de líneas y que incluso todavía sigue siendo objeto de estudio (p.e. Barber et.al, 1995; Veregin, 1999; Saalfeld, 1999; Zhao et.al, 2001).

Publicado por Douglas y Peucker (1973)[1], su popularidad tuvo lugar por ser uno de los primeros algoritmos de eliminación de puntos de carácter global, con un sentido más holístico que los ideados hasta entonces. Se fundamenta en la búsqueda de puntos críticos, que serán puntos que retengan la mayor cantidad de información de la geometría de la línea, claramente influenciado por los estudios de Attneave (1954).

[1] Urs Ramer propuso esencialmente el mismo algoritmo un año antes, en el contexto del procesamiento de imágenes (Ramer, 1972). Es por ello por lo que algunos autores hacen referencia a este algoritmo como el de Ramer-Douglas-Peucker (RDP).

En el transcurso del funcionamiento del algoritmo, los puntos críticos, que irán constituyendo la línea filtrada, serán los que vayan marcando la distancia perpendicular máxima respecto a la línea-base considerada. La primera línea-base, entre los denominados puntos *de anclaje* y *flotante*, quedará constituida entre el primer y último punto de la línea original. Acto seguido se calcularán las distancias perpendiculares de todos los puntos intermedios. Si ninguna de estas distancias es mayor a la tolerancia la simplificación habrá finalizado y sólo quedarán retenidos los puntos inicial y final de la línea. En el caso de que sí se supere la tolerancia el punto con mayor distancia será retenido como punto crítico que subdividirá la línea original en dos secciones, en cada una de las cuales se repetirá el proceso como si de dos líneas independientes se tratase, y así sucesivamente hasta que no haga falta efectuar subdivisión alguna de la línea (ver ejemplo en Figura II.17).

El mayor problema que presenta este algoritmo es que, como la mayoría de algoritmos de eliminación de puntos, no puede emplearse para grandes cambios de escala ya que el resultado no es satisfactorio. La elección del punto crítico en el algoritmo, tal y como está formulada, puede recaer en pequeños detalles de la línea, lo que es contrario a la esencia de la generalización manual, que intenta seleccionar las formas más destacadas (Visvalingam y Whyhatt, 1990,1991), es decir, "los puntos seleccionados por Douglas-Peucker no son siempre críticos".

II.5.3.3. Algoritmo de Visvalingam

Como se ha referido, el algoritmo de Douglas-Peucker no es adecuado para grandes reducciones de escala. Este hecho motivó las investigaciones de Visvalingam (Visvalingam y Whyhatt, 1990, 1993; Visvalingam y Williamson, 1995), tratando de elaborar y analizar una rutina que se adaptara mejor a estos cambios de escala: el algoritmo de Visvalingam. Éste es capaz de filtrar progresivamente secciones de línea al ir disminuyendo la escala, comenzando por las relacionadas con los detalles más locales hasta alcanzar las relativas a los más globales, manteniendo la forma de las figuras que permanecen. En resumen, "fue

conceptualizado como un algoritmo de eliminación de formas" (Visvalingam y Herbert, 1999).

Esta rutina se sirve del concepto de *área efectiva*, definida como el área del triángulo de cada punto de la línea respecto a sus dos vecinos, y que viene a significar el desplazamiento que sufrirá la línea en el caso de eliminar ese punto. Se irán realizando sucesivas pasadas por la línea, en cada una de las cuales se eliminará el punto con menor área efectiva, si es que es inferior a la tolerancia fijada (ver ejemplo en Figura II.18).

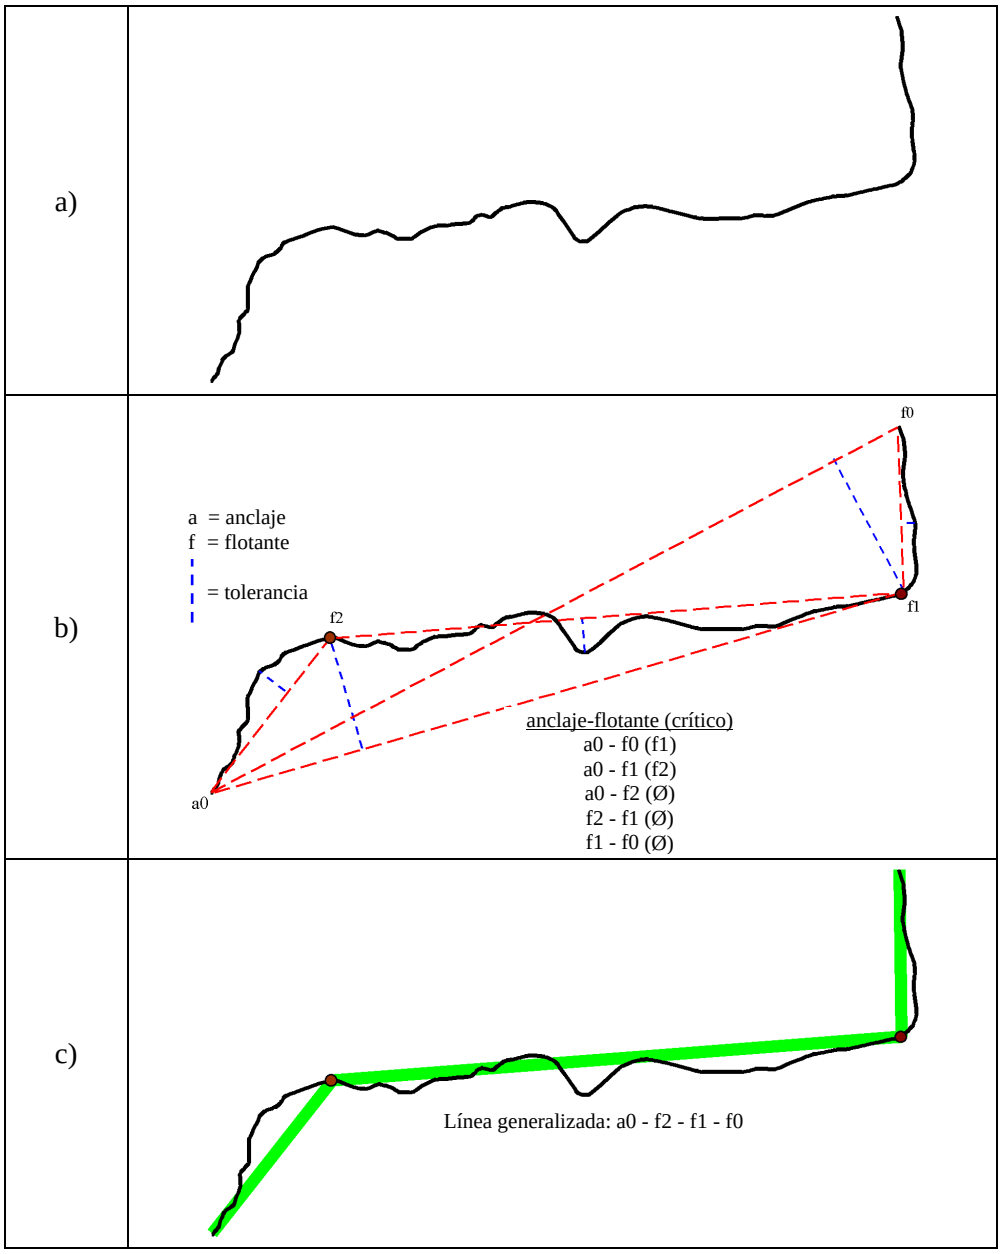


Figura II.17 - Ejemplo del funcionamiento del algoritmo de Douglas-Peucker. a) línea original; b) aplicación del algoritmo; c) línea generalizada.

Visvalingam y Williamson elaboraron en 1995 un estudio en el que compararon los algoritmos de Douglas-Peucker y de Visvalingam. Según estos autores, la razón de escoger estos dos algoritmos reside en que "estos dos métodos son intelectualmente superiores a otros en la abstracción de los principios clave y en sus elegantes formulaciones. Además son más fáciles de implementar [...]. También es fácil comprender las implicaciones cartográficas de su procesamiento geomé-

trico". Las líneas que emplearon fueron una muestra de una red de carreteras a la escala 1:1 250, en muchos casos perpendiculares entre sí, con circulares en las esquinas. Incluyeron en su estudio tres conceptos distintos para el análisis de la bondad de las rutinas:

- *Simplificación mínima*. Hace referencia al procedimiento por el cual la línea es simplificada pero intentando que su diferencia respecto a la original sea inapreciable. Únicamente se trata de una técnica para reducir el número de puntos necesarios para almacenar la línea tal y como es. El algoritmo de Douglas se mostró superior al de Visvalingam en esta cuestión, ya que requirió menos puntos. Además el de Visvalingam era tendente a cortar las curvas, muy pronunciadas y con los puntos muy próximos entre sí y, en consecuencia, de escasa área efectiva. Estos resultados contradicen los obtenidos por los mismos autores para escalas pequeñas.
- *Eliminación de formas menores*. Se trata de eliminar los pequeños detalles existentes a lo largo de las líneas. Aquí la técnica de Visvalingam se mostró superior, ya que la de Douglas retenía los detalles y curvas sólo parcialmente, provocando una distorsión en la forma de las carreteras así como desplazamientos. A pesar de todo el algoritmo de Visvalingam seguía adaptándose mal a las curvas, que eran cortadas.
- *Eliminación de formas mayores*. Fue en este capítulo en el que se acentuaron las diferencias entre los dos algoritmos. El método de Douglas es incapaz de retener la forma principal de las líneas debido a que los puntos críticos que va seleccionando tienen tendencia a caer en detalles, siendo los resultados nefastos para niveles de generalización drásticos. En cambio el algoritmo de Visvalingam va eliminando progresivamente elementos relacionados con la escala al acentuarse la generalización (concepto de generalización estructural). En Visvalingam y Herbert (1999) se señala que el algoritmo de Visvalingam se diseñó para este objetivo. Esta capacidad de este algoritmo es subrayada también por Van der Poorten y Jones (2002).

Estos resultados de Visvalingam y Whyhatt para escalas grandes no fueron exactamente los mismos que habían obtenido en el contexto de escalas pequeñas, ya

que en estas escalas la técnica de Visvalingam había sido superior en la simplificación mínima y no se había apreciado que cortase las curvas (Visvalingam y Whyhatt, 1993).

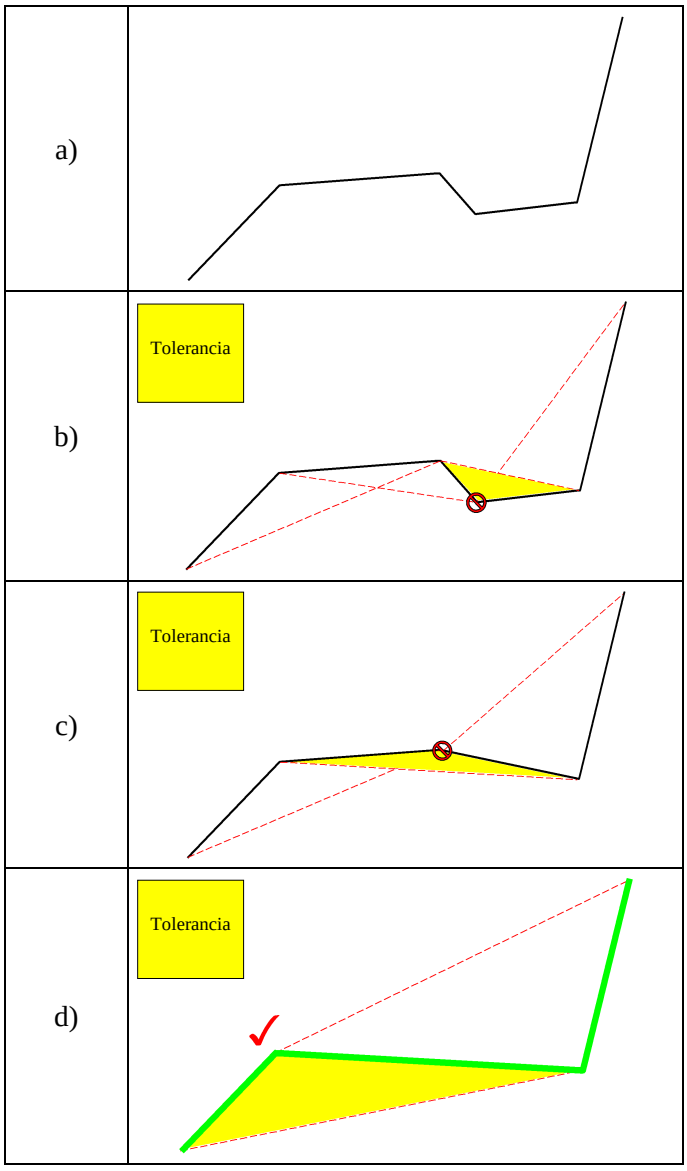


Figura II.18 - Ejemplo del funcionamiento del algoritmo de Visvalingam.
a) línea original; b) 1ª pasada; c) 2ª pasada; d) 3ª pasada y línea generalizada

Asimismo es de suponer que ha influido mucho la estructura de las líneas elegidas, ya que la red de carreteras utilizada era más bien una red urbana con numerosas vías perpendiculares entre sí, rotondas, isletas... Podemos manifestar que estos datos, con tantos detalles, han sido elegidos para resaltar los inconve-

nientes del algoritmo de Douglas en altos grados de simplificación y las ventajas de la técnica de Visvalingam en este mismo sentido.

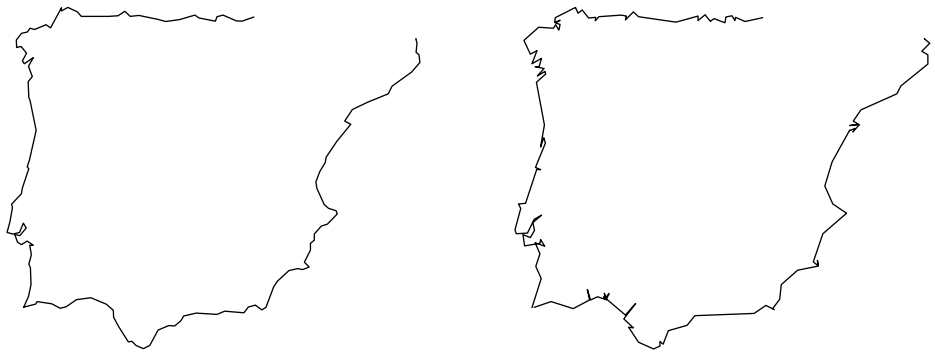


Figura II.19 - Ejemplos de filtrado con Visvalingam (izquierda) y Douglas-Peucker (derecha), ambos con el mismo número de puntos (Reinoso et.al, 2001).

En García (1998) y García et.al (1999) compararon ambos algoritmos con una muestra de líneas procedentes del MTN25 del IGN y no se apreciaron diferencias significativas en cambios de escala modestos, ni mediante el análisis visual de los filtrados ni mediante el cómputo de medidas evaluadoras geométricas. No obstante, ya se dejaba entrever una mayor capacidad de Visvalingam en las reducciones más fuertes del número de puntos. En Reinoso et.al (2001) se evidencia este hecho al aplicar ambos algoritmos sobre las líneas de costa de la península ibérica de la Carta Digital del Mundo a escala 1:1 000 000 con drásticas reducciones del número de puntos. En este caso la superioridad del algoritmo de Visvalingam para extraer la forma principal o caricatura de la línea es muy clara (ver Figura II.19)

II.5.3.4. Algoritmo de Thapa

El algoritmo de Thapa (1990) fue concebido para la compresión de información, para paliar el problema de que usualmente se digitaliza más información de la que es requerida para representar una línea a una escala dada. Como Douglas-Peucker, se fundamenta en la búsqueda de puntos críticos, que describirán el

esqueleto de una cadena más numerosa de puntos. Sin embargo, su funcionamiento no es global, como aquel, ya que no trabaja con la línea en su totalidad.

Se trata de uno de los pocos algoritmos que se sirve de un tratamiento estadístico, ya que emplea los valores propios de la matriz de varianza-covarianza normalizada, derivada de las coordenadas de la línea. Estos valores propios representan la inercia del conjunto de coordenadas considerado respecto a dos ejes locales. Cuando existe una serie de puntos más o menos alineados, uno de los valores será muy cercano a *1* (ya que está normalizado) y el otro a *0*. Cuando se introduzcan puntos desplazados respecto a la alineación, la diferencia entre los dos valores (*th*) se reducirá.

Así, el algoritmo consiste en ir calculando los valores propios y el valor de *th* conforme se van añadiendo puntos. En el momento en que el valor de *th* baja de un umbral, que será el parámetro de entrada al algoritmo, el penúltimo punto añadido pasa a la línea filtrada y se convierte en anclaje, comenzando de nuevo el proceso desde ese punto. Es decir habrá que ir efectuando los pasos referidos en la Tabla II.9.

Tabla II.9 - Proceso efectuado por el algoritmo de Thapa

1.	Se define el parámetro de entrada, es decir, el umbral de *th*.
2.	Se toman tres puntos de la línea a filtrar
3.	Se calculan los valores propios normalizados de la matriz de varianza-covarianza y se calcula *th*.
4.	Si *th* es mayor que una cierta tolerancia, se toma otro punto de la línea y se repite el paso 3. Si *th* es menor a la tolerancia, el punto 2 es un punto crítico.
5.	Se retiene el punto 2 y se repite el proceso desde el paso 2, tomando el punto 2 como el nuevo punto de partida.
6.	Se repite el proceso desde el paso 2 hasta que se alcanza el final de la línea.

Para obtener los valores propios de la matriz de varianza-covarianza entre los puntos de anclaje y flotante hay que resolver el determinante:

$$\begin{vmatrix} \sigma_x^2 - \lambda & \sigma_{xy} \\ \sigma_{xy} & \sigma_y^2 - \lambda \end{vmatrix} = 0$$

Por lo tanto los dos valores propios tomarán los valores (Ec. 2 y Ec. 3).

$$\lambda_1 = \frac{-b+\sqrt{b^2-4ac}}{2a} \qquad \lambda_2 = \frac{-b-\sqrt{b^2-4ac}}{2a}$$

siendo:

$a = 1$
$b = -(\sigma_x^2 + \sigma_y^2)$
$c = \sigma_x^2\sigma_y^2 - (\sigma_{xy})^2$

Los dos valores propios estarán normalizados si los dividimos por la traza de la matriz de varianza-covarianza. Y por tanto el valor *th* será igual a la diferencia entre ellos. De esta forma el valor de *th* oscilará entre 0 y 1:

$$th = /\lambda_1 - \lambda_2 / / (\sigma_x^2 + \sigma_y^2)$$

No obstante su gran capacidad para extraer puntos críticos, el algoritmo de Thapa presenta algunos problemas que limitan en gran medida sus posibilidades de aplicación en generalización cartográfica (García et.al, 2001):

a) La gran inercia que toma el algoritmo cuando se recorre una larga serie de puntos sensiblemente alineados, que hace que se obtengan resultados totalmente inapropiados y alejados de los objetivos perseguidos por la generalización. El comportamiento inercial del algoritmo no es una propiedad perjudicial en sí misma, ya que permite filtrar la línea. Pero cuando alcanza valores muy elevados el filtrado que realiza es demasiado drástico, eliminando de forma grosera gran cantidad de información, tanto valiosa como sin interés. Esto reduce el rango de cambios de escala en los que puede ser utilizado.

b) El diferente comportamiento del algoritmo según el sentido de lectura de la línea a filtrar, que hace que se obtengan resultados distintos. Esto viene motivado por tratarse de un algoritmo de procesamiento local extendido, según la clasificación de McMaster y Shea (1992). Así, el número de puntos que intervienen en el cómputo en cada momento depende de la morfología de la línea. Por el contrario, algoritmos de procesamiento local o global siempre ofrecen el mismo resultado, independientemente del sentido.

Para comprender mejor estos problemas se presenta en la Figura II.20 el filtrado de una línea sinuosa en zigzag de 81 puntos con un fuerte cambio de dirección de 90º. Aunque el filtrado idóneo sería el formado por los puntos a-b-c, el resultado obtenido al aplicar el algoritmo de Thapa con un valor *th* de 0,75 es el re-

presentado como a-b'-c si el sentido de lectura es a-b-c, y c-b''-a si el sentido de lectura es c-b-a.

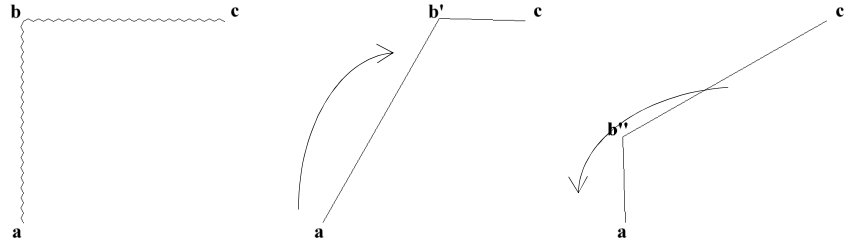


Figura II.20 - Línea original con cambio de dirección de 90º y líneas filtradas con Thapa en ambos sentidos con *th* = 0,75.

El porqué de este comportamiento es claro. Cuando se filtra la línea en el sentido a-b-c, el algoritmo va acumulando inercia con los 41 puntos que hay entre a y b. Esto hace que el valor de *th* no baje por debajo del valor crítico hasta llegar al punto b', que ya está demasiado alejado de b. En la Figura II.21 se puede observar un filtrado efectuado sobre la línea de costa de la Península Ibérica, con un resultado que exhibe los problemas de inercia señalados.

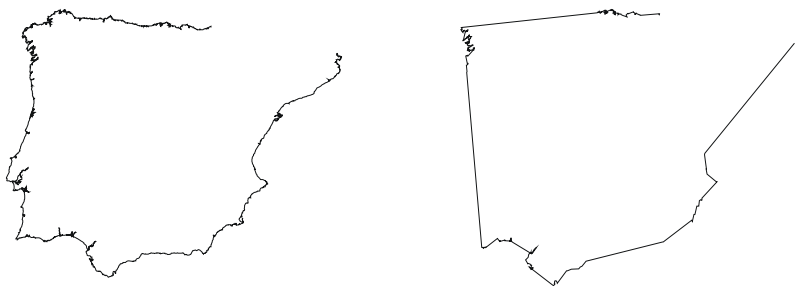


Figura II.21 - Ejemplo de filtrado con el algoritmo de Thapa.

En García et.al (2001) se realiza una propuesta para perfeccionar la aplicación del algoritmo de Thapa de forma que limite su comportamiento inercial y el filtrado sea más homogéneo en ambos sentidos de la línea. Recibe el nombre de Thapa Bidireccional Recursivo (TBR), el cual persigue:

- Ampliar el rango de cambios de escala en los que puede ser empleado, es decir, el porcentaje de puntos que se puede eliminar sin que aparezcan eli-

minaciones drásticas en algunas secciones de la línea que provoquen desplazamientos enormes.

- Aumentar la sensibilidad del parámetro de entrada, ya que se podría utilizar un margen más amplio de valores.

Para ello, los autores se sirven de la propiedad que presenta Thapa de ofrecer filtrados diferentes según el sentido de lectura de la línea original. La idea es aplicar el algoritmo en ambos sentidos de la línea alternativamente. En cada pasada, los puntos críticos estarán definidos por los de la pasada anterior (que es de sentido contrario a la actual) más los detectados ordinariamente por el algoritmo de Thapa. Este proceso, resumido en la Tabla II.10, converge en un número no muy elevado de pasadas.

Tabla II.10 - Proceso efectuado por el algoritmo de Thapa Bidireccional Recursivo.

1. Se define el parámetro de entrada, es decir, el umbral de *th*.
2. Se aplica el algoritmo de Thapa como se comenta en la Tabla II.9 una sola vez.
3. Se invierte el sentido de lectura de la línea.
4. Se vuelve a aplicar el algoritmo de Thapa, pero reteniendo como puntos críticos los de la pasada anterior más los nuevos detectados en la pasada actual.
5. Se repite el proceso desde el paso 3 hasta que no se detecte ningún punto crítico nuevo.

Si se aplica TBR a la línea de la Figura II.20 con el mismo valor del parámetro *th*, se obtienen progresivamente puntos críticos que se aproximan al fuerte cambio de dirección de 90º, como se puede comprobar en la Figura II.22.

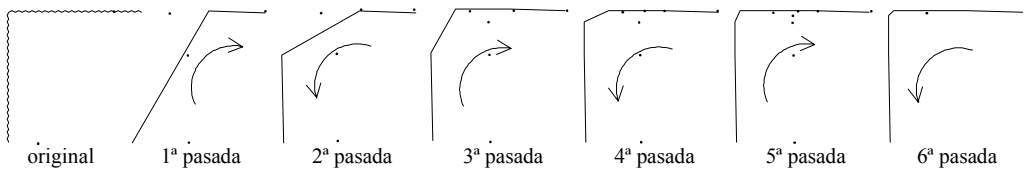


Figura II.22 - Línea original con cambio de dirección de 90º y líneas filtradas con TBR en ambos sentidos con *th* = 0,75.

En la Figura II.23 se presenta el filtrado efectuado con TBR sobre la misma línea original de la Figura II.21. El parámetro aplicado es el mismo que el aplicado con Thapa. La línea vuelve a recuperar la silueta de la Península Ibérica que se había perdido al aplicar Thapa, simplificando como líneas rectas únicamente las secciones más rectilíneas: parte de la costa cantábrica, portuguesa, malagueña y catalana. Ahora bien, se detecta un exceso de detalle en las zonas sinuosas, produciéndose una enorme descompensación en el filtrado. Según García et.al (2001), en presencia de líneas heterogéneas, el filtrado del algoritmo propuesto tiene una fuerte tendencia a concentrarse en los detalles de las secciones sinuosas y a simplificar las suaves como rectas, por lo que no sería una técnica adecuada para grandes reducciones de escala; "no es un algoritmo capaz de eliminar detalles al aumentar el nivel de generalización, al contrario que Visvalingam". Los autores apuntan esta circunstancia en cuanto a líneas heterogéneas, como potencialmente útil para segmentar estas líneas en secciones homogéneas.

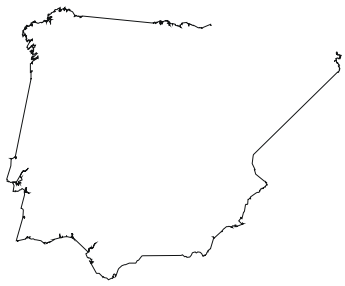


Figura II.23 - Ejemplo de filtrado de la costa de la Península Ibérica con el algoritmo TBR.

Aunque es manifiesta la mayor utilidad cartográfica de TBR frente a Thapa, comentan que, dado que no se ha modificado el principio matemático del algoritmo de Thapa, si se reduce lo suficiente el parámetro vuelven a aparecer problemas derivados del comportamiento inercial.

II.5.4. Algoritmos de filtrado de curvatura

A la vez que se desarrollaron los algoritmos de eliminación de puntos, se concibieron otro tipo de técnicas, los denominados algoritmos de suavizado, cuyo

objetivo era dotar a la línea de un aspecto más estético, que habría sido deteriorado, bien en el proceso de digitalización, o bien en el del filtrado de puntos, al haber sido acentuada la angulosidad. Por tanto se trata de efectos surgidos con la automatización de los procesos de producción cartográfica, ya que tradicionalmente las líneas trazadas por los cartógrafos solían conservar una apariencia fluida.

El suavizado se puede considerar como un filtro de paso bajo sobre la curvatura, como señala Jasinski (1990, p. 11) al establecer una analogía con el análisis digital de imágenes, ya que el suavizado trataría de eliminar, o filtrar, los cambios de curvatura de alta frecuencia. Se aplica para mejorar la calidad estética del mapa, así como la legibilidad y la claridad del mensaje que se pretende transmitir. De hecho, para Jasinski (1990, p. 11) el suavizado no es sino una de las diferentes formas existentes para realzar un elemento lineal en el proceso de generalización.

El suavizado o filtrado de curvatura se consigue desplazando los puntos a otras posiciones para eliminar pequeñas perturbaciones o microinflexiones, reteniendo tan sólo las tendencias más significativas de la línea (McMaster y Shea, 1992, p. 84). También se puede conseguir un filtrado sobre la curvatura con algoritmos de eliminación de puntos. De hecho existen técnicas consideradas mixtas (filtrado de puntos - filtrado de curvatura), como la de Li y Openshaw (1992) o el empleo de aproximaciones matemáticas, como los arcos cúbicos (Affholder, 1993, Plazanet et.al, 1995).

Existen numerosas revisiones o estudios acerca del suavizado de elementos lineales, por ejemplo en Fritsch (1997), McMaster (1989), McMaster y Shea (1992), Reinoso (1998) o Reinoso et.al (1999).

II.5.4.1. Filtrados por convolución espacial

Este tipo de algoritmos pretenden desplazar las coordenadas de un punto hasta una posición que está en función de las posiciones de cierto número de puntos del entorno y del mismo punto en cuestión.

El filtrado más sencillo viene dado por el cálculo de una media aritmética de *n + 1* puntos. Se recorrería la línea desde el principio hasta el final, calculando el promedio obtenido con las coordenadas de cada punto y los *n/2* puntos anteriores y *n/2* posteriores al punto. Cuanto mayor sea el valor de *n* mayor será el filtrado efectuado. Un caso más general sería efectuar una media ponderada en lugar de una aritmética, asignando pesos a los *n + 1* puntos que intervienen en cada momento (p.e., con *n = 4*, 10%, 20%, 40%, 20%, 10%).

Una variante de la técnica anterior viene dada por el *algoritmo de promedio con deslizamiento* de McMaster (McMaster y Shea, 1992). La diferencia reside en que se introduce un nuevo parámetro, *deslizamiento*, variable entre 0 y 1, con el que se realiza una media ponderada entre la coordenada resultante de la media aritmética y la coordenada original del punto.

En lugar de fijar los pesos de la convolución a priori en el código del algoritmo, pueden asignarse en función de la geometría de la propia línea. Por ejemplo, el peso puede venir dado por la inversa de la distancia de cada punto vecino hasta el punto a desplazar, que esta vez no intervendrá en el cálculo del promedio, pues su peso no se podría calcular. También podría introducirse un parámetro de deslizamiento a continuación, como es el caso del *algoritmo de promedio ponderado por la distancia de McMaster* (McMaster y Shea, 1992).

Un refinamiento de la convolución se encuentra en el *filtrado gausiano*, ya que esta vez la posición del punto se calcula como una ponderación de las posiciones de los puntos de la vecindad en la que los pesos de cada vecino están en función de una función de distribución de tipo campana de Gaus. En el centro de la campana se situará el punto a suavizar, cuyo factor de ponderación será el mayor, y a los dos lados de la campana los factores de ponderación irán disminuyendo

simétricamente para los vecinos. Este procedimiento es muy empleado como tratamiento previo que eliminar posibles microinflexiones que dificultarían operaciones posteriores (p.e. en un ajuste de arcos cúbicos como el de Affholder (1993)), y también ha sido empleado en procesos de segmentación de líneas para el enriquecimiento de bases de datos (Plazanet, 1996).

La función gausiana $g_\sigma(k)$ viene dada por la expresión:

$$g_\sigma(k) = \frac{1}{\sigma\sqrt{2\pi}} e^{\frac{-k^2}{2\sigma^2}}$$

donde:

- σ es la variable que modificará el grado de suavizado. A mayor valor de σ, mayor suavizado.
- k indicará el número de orden respecto al punto central de la campana (si $k = 0$ se trata del punto central, si $k = 1$ es el siguiente, si $k = -1$ es el anterior ...)

Las coordenadas suavizadas (x',y') se obtendrán como resultado de una convolución entre la función gausiana y las coordenadas de la línea original (x,y):

$$x'_i = \sum_{k=-4\sigma}^{4\sigma} x_{i-k} \times g_\sigma(k)$$

$$y'_i = \sum_{k=-4\sigma}^{4\sigma} y_{i-k} \times g_\sigma(k)$$

Como se puede observar, k varía tomando los valores enteros entre -4σ y 4σ. Por tanto, el número de puntos que intervienen en el cálculo del suavizado de uno de ellos es de 8σ vecinos, más el punto central. Así, cuando $\sigma = 1$ el número de puntos participantes es 9 y si $\sigma = 2$ el número es 17.

La Figura II.24 presenta el resultado de la aplicación de un suavizado gausiano de parámetro $\sigma = 1{,}5$. El número de puntos de la figura suavizada es el mismo que en la original, pero como se observa, se han introducido desplazamientos que suavizan mucho las formas (p.e. obsérvese la costa gallega).

Por otro lado, el *algoritmo de Boyle* (Boyle, 1970) se comporta de forma sustancialmente diferente a lo visto hasta ahora, ya que se realiza una media ponderada entre el punto previamente suavizado y aquel de la línea original que se encuentra *n* posiciones más adelante. La ponderación se distribuye con un 0.75 para el punto previamente suavizado y 0.25 para el indicado por el parámetro *n*.

Todos los procedimientos comentados provocan el desplazamiento hacia la parte cóncava de la línea original, aunque esto se puede atenuar mediante el referido parámetro de deslizamiento, para acercar la línea suavizada a la original. Otra corrección con el mismo fin es la de Lowe (1988), para el filtrado gausiano. Sin embargo el desplazamiento provocado resalta tanto las formas que puede ser considerado también como una herramienta de caricaturización (Fritsch, 1997 p. 72). En la Figura II.25 se muestra un ejemplo de suavizado sobre la costa africana de Lowe (1988), en el que se puede observar cómo la curva corregida se ajusta mejor a la localización de la línea original.

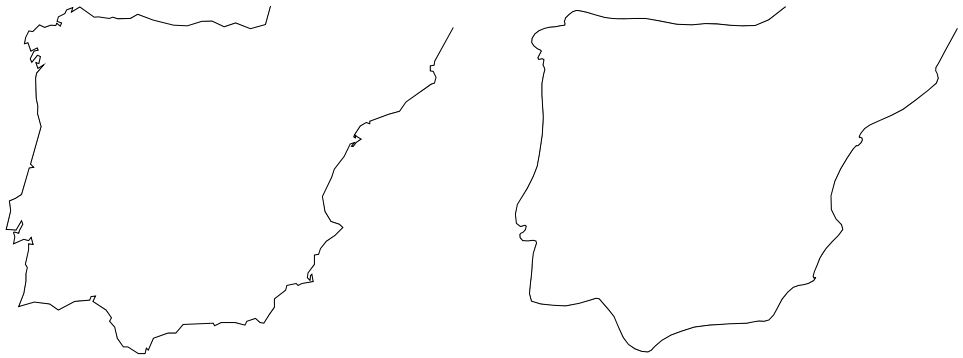
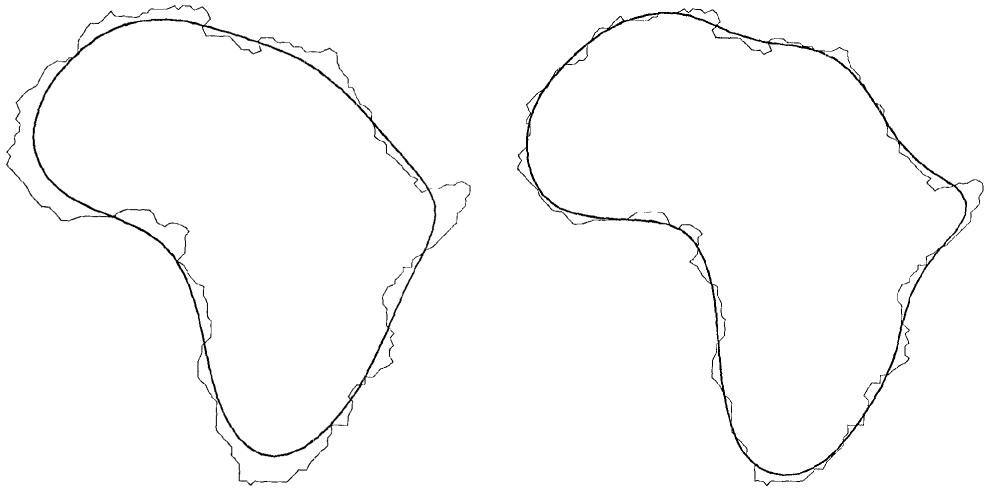


Figura II.24 - Ejemplo de suavizado gausiano con sigma 1,5 (12 vecinos más central) para la línea de costa de la península ibérica.



(a) (b)

Figura II.25 - Mapa de África suavizado mediante filtro gausiano con □ = *4*, mediante el método estándar (a) y aplicando la corrección (b) (Lowe, 1988).

II.5.4.2. Aproximaciones matemáticas

La tradicional representación de un elemento lineal mediante una polilínea es una aproximación mediante segmentos rectilíneos, o polinomios de primer grado, que obliga a que se utilice un gran número de puntos para una aproximación fiel. Aproximaciones de grado superior al lineal necesitarían menos almacenamiento, son más compactas y permiten una manipulación interactiva más fácil (Feito et.al, 1995)

Así, el objetivo de la aproximación matemática es describir un elemento lineal mediante una serie de parámetros que definen diversas figuras geométricas, como pueden ser circunferencias, parábolas, arcos cúbicos, curvas paramétricas cúbicas, etc. Tradicionalmente esta es una labor propia de entornos C.A.D., pero sus ventajas son potencialmente útiles para la generalización cartográfica, ya que el paso de la representación mediante polilínea a la representación matemática no es meramente una variación en la forma de almacenar una línea, sino que constituye por sí mismo un filtrado en la medida en que el cambio de coordenadas a parámetros se produzca almacenando mayor o menor cantidad de información

Plazanet (1996) clasifica estas técnicas de forma parecida a la clasificación que McMaster y Shea (1992) realizan para los algoritmos de eliminación de puntos: *locales* (p.e. ajuste mediante arcos cúbicos de Affholder (1993)), *locales extendidos* (p.e. B-splines) y *globales* (p.e. curvas de Bézier).

Curvas paramétricas cúbicas

Según Feito (Feito et.al, 1995), es preferible una curva cúbica a un polinomio de menor grado porque estos últimos son poco flexibles para controlar la forma de la curva, mientras los de grado mayor requieren un número muy elevado de cálculos y pueden introducir variaciones no deseadas.

Toda función puede expresarse de tres formas: explícita, implícita y paramétrica. La última es la mejor opción por varias razones: (a) Es fácil representar curvas con tangentes verticales, (b) se pueden obtener múltiples valores de y y de z para un mismo valor de x, (c) son elementos finitos, cuyo parámetro está normalizado entre 0 y 1, (d) es fácil calcular la continuidad en los puntos de unión, (e) ofrecen un mayor número de grados de libertad, (f) separan completamente los papeles de las variables dependiente e independiente y (g) permiten cualquier número de variables (Feito et.al, 1995).

La expresión de una curva paramétrica cúbica bidimensional comprende dos polinomios:

$$x(t) = a_x t^3 + b_x t^2 + c_x t + d_x$$
$$y(t) = a_y t^3 + b_y t^2 + c_y t + d_y \qquad 0 \leq t \leq 1$$

El método consiste en dividir la línea original en secciones, bien a intervalos regulares o de tamaño variable en función de las características de la línea. Cada sección se ajustará mediante una curva paramétrica cúbica. Para lograr un resultado de calidad hay que asegurar la continuidad en los extremos donde se unen. Existen distintos tipos de continuidad (Tabla II.11). Para un objetivo cartográfico

bastaría con la G^1, que es aquella en la que las primeras derivadas paramétricas en el punto de intersección son proporcionales.

Tabla II.11 - Tipos de continuidad en una curva paramétrica.

Continuidad paramétrica	Continuidad geométrica
• C^0. Los dos segmentos de curva se tocan • C^1. Las derivadas primeras de ambas curvas son iguales en el punto de contacto. • C^2. Las derivadas primeras y segundas de ambas curvas son iguales en el punto de contacto.	• G^0. Análoga a la C^0. • G^1. Las derivadas primeras de ambas curvas son proporcionales en el punto de contacto. • G^2. Las derivadas primeras y segundas de ambas curvas son proporcionales en el punto de contacto.

Cada uno de los polinomios referidos tiene cuatro coeficientes y, por tanto, cuatro grados de libertad. Por ello hay que establecer cuatro restricciones en los extremos del segmento de curva, que dan lugar a cuatro ecuaciones con cuatro incógnitas. Estas restricciones pueden ser: posición de los extremos, tangente en los extremos, derivada segunda en algún punto interior a la sección de la curva, etc. Las curvas paramétricas de tipo Hermite consideran la posición de los extremos y sus tangentes. Las de tipo Béziér consideran la posición de los extremos y dos puntos de control que definen sus tangentes.

Existen escasos ejemplos del empleo de curvas paramétricas cúbicas en generalización. Uno de ellos es el de Saux (1998), que emplea las B-splines sobre líneas de costa y líneas de batimetría, con resultados satisfactorios. El autor señala como operadores de generalización puestos en juego con esta técnica: compresión, suavizado, desplazamiento y agregación.

Arcos cúbicos

El ajuste por arcos cúbicos fue una de las primeras técnicas de aproximación matemática empleadas en generalización (ver Affholder, 1993), para su aplicación sobre vías de comunicación (autopistas, carreteras, ferrocarriles...), ya que suelen estar formadas por una concatenación de líneas rectas, arcos de circunferencia y arcos de clotoide o parábolas.

No es un proceso directo, requiere que la información posea una cierta estructura o comportamiento conveniente para que su aplicación sea eficaz. Los arcos cúbicos se ajustan entre pares de puntos de inflexión consecutivos, y hay que intentar que estos puntos sean los más representativos. Además, dado que se sustituyen tramos de la poligonal por tramos de arco, puede darse el caso de la aparición de problemas topológicos. Por tanto, la aplicación de los arcos cúbicos requiere de un cierto preproceso de la línea y de un estudio y corrección de los problemas topológicos:

a) *Suavizado de la línea.* Este preproceso no siempre será necesario, pero es común su necesidad dado que es normal que existan numerosas microinflexiones debido al proceso de digitalización, lo que traería consigo que aparecieran ligados numerosos puntos de inflexión, sin interés para nuestros propósitos. Affholder (1993) emplea el suavizado gausiano.

b) *Detección de puntos característicos*. En geometría Euclidiana los puntos característicos son los picos y los puntos de inflexión. Freeman (1978) propuso que había que expandir el concepto de estos puntos. Affholder (1993) considera que en la mayoría de los casos es suficiente con identificar los puntos de inflexión, aunque propone como puntos críticos:

   - Discontinuidades en la curvatura.
   - Puntos de máxima curvatura (p.e., cambios bruscos de dirección).
   - Puntos de mínima curvatura (p.e., puntos de inflexión).
   - Puntos que dividen la línea en secciones de características diferentes.

   En García (1998) y García y Ariza (2000a) se observó que en las líneas sinuosas se obtenían mejores resultados si además de los puntos de inflexión también se consideraban los cambios bruscos de dirección.

   Los puntos de inflexión (PI) se pueden localizar calculando a lo largo de la polilínea el signo del producto escalar entre tres segmentos consecutivos: *n-1, n* y *n+1*.

   Indudablemente, el grado de suavizado determinará el número de puntos de inflexión detectados (a mayor suavizado, menos puntos de inflexión), y por tanto el número de arcos cúbicos. Así, el parámetro de entrada del filtro gau-

siano de la fase anterior determinará el nivel de generalización de todo el proceso.

c) *Ajuste de los arcos cúbicos.* La función de ajuste por arcos cúbicos es muy simple: $y = ax^3$. Las principales ventajas de su utilización frente a otras funciones son: 1) al ser de bajo grado, reduce las tareas de computación; 2) se trata de una función que se ajusta localmente a la clotoide.

La función quedará definida en el sistema de referencia local con una rotación y una traslación (Figura II.26), con el origen en un punto característico de la línea (p.e., un punto de inflexión) y el eje *x* paralelo a la tangente local. La línea será, por tanto, una función definida a "tramos".

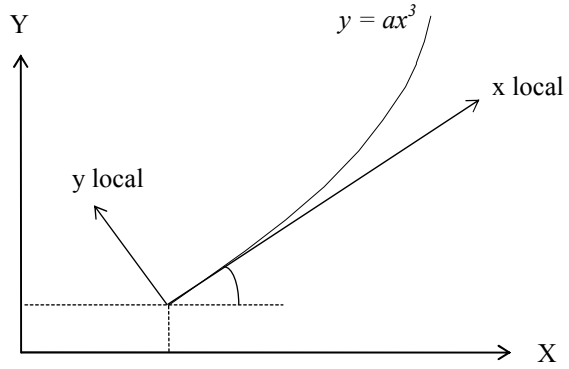


Figura II.26 - Función $y = ax^3$ en el sistema local.

Una vez han sido extraídos los puntos de inflexión, el ajuste por arcos cúbicos consiste en determinar una pareja de arcos entre cada dos puntos de inflexión consecutivos: PI_1 y PI_2. El primer paso es definir el sistema local de cada arco cúbico: (PI_1, θ_1) y (PI_2, θ_2). El origen será el correspondiente PI, el ángulo de rotación θ_1 quedará fijado por el segmento con sentido desde PI_1 hasta el siguiente punto de la línea original, y θ_2 por el segmento con sentido desde PI_2 hasta el anterior punto de la línea original.

Posteriormente se pasa al cálculo de la mejor pareja de arcos cúbicos entre PI_1 y PI_2, que será aquella que minimice la suma del área que media entre los arcos y la línea original. La mejor pareja se hallará por tanteo, probando cada punto intermedio P_i entre PI_1 y PI_2 como punto de contacto entre los

dos arcos, permitiendo cierto margen de libertad a θ_1 y θ_2. Affholder (1993) propone que éstos varíen en unos pequeños intervalos $\delta\theta_1$ y $\delta\theta_2$ tales que:

$$\delta\theta i = \pm \frac{tol}{D_{\theta_i - P_i}}$$

siendo:

tol la precisión de la línea original digitalizada.

$D_{\theta i\text{-}Pi}$ la distancia entre el PI considerado y el P_i en proceso.

Las conclusiones más destacables mostradas en Affholder (1993), García (1998), y García y Ariza (2000a) son:

- Permite una compresión de datos: largas listas de pares de coordenadas son sustituidas por un conjunto de puntos característicos y unos parámetros que definen los arcos cúbicos
- El ajuste permite obtener una representación simplificada y suavizada de la línea. Se observa la capacidad para reforzar la tendencia de la línea al eliminar las zonas de microinflexiones, permaneciendo la curva general que las engloba (ejemplo en Figura II.27).
- Existencia de notables desplazamientos entre la línea original y la suavizada, algo previsible cuando se pretende extraer la tendencia general y no mantenerla lo más fiel posible (ver Figura II.27).
- Sin embargo, se observan ajustes en los que aparecen picos en tramos donde no funciona correctamente la función cúbica (ejemplo en Figura II.28). En las pistas de montaña muy sinuosas se comprueba que el comportamiento en general no es adecuado, ya que se detectan numerosos picos y problemas topológicos (se cruza la línea sobre sí misma) en las generalizaciones más drásticas, procedentes de los niveles de suavizado gausiano más altos. Estos problemas no deben extrañar, ya que estas vías de comunicación no suelen estar diseñadas según una serie de figuras geométricas, sino que intentan adaptarse al terreno, siguiendo las curvas de nivel, por lo que la función $y = ax^3$ no se adapta bien (Figura II.29).

- Los mejores resultados se obtuvieron en autovías: resultados muy suaves, ausencia de picos y desplazamientos relativos menores que en las otras líneas.



Figura II.27 - La línea generalizada (línea continua) extrae la tendencia general de la línea original (línea punteada).

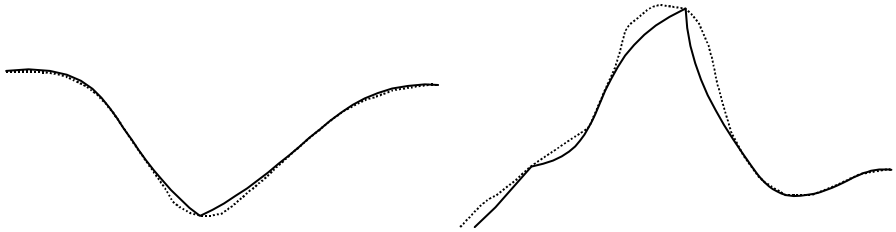


Figura II.28 - Ejemplos de picos que surgen en la línea generalizada (línea continua).

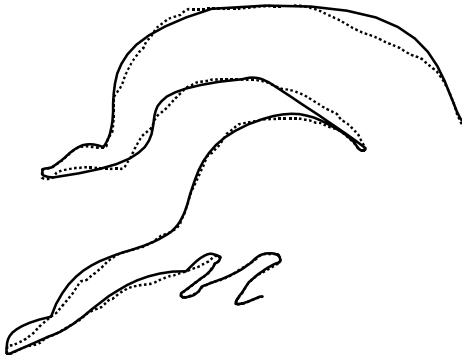


Figura II.29 - Generalización (línea continua) de parte de una pista de montaña.

II.5.4.3. Filtrados en el dominio de la frecuencia

Las técnicas espectrales son relativamente recientes, aunque ya han sido varios los autores que han indagado sobre la posibilidad de la generalización en el dominio de la frecuencia (Boutoura, 1989; Clarke et.al, 1993). Como trabajos en generalización más destacables hay que señalar los realizados por Fritsch (Fritsch, 1994, 1997; Fritsch y Lagrange, 1995; Plazanet et.al, 1995) en el seno del Institut Géographique National de Francia, que estudió la forma de represen-

tar una línea utilizando series de Fourier y wavelets, técnicas que se habían venido usando en el campo del procesamiento de señales.

En el dominio de la frecuencia la línea queda representada por un conjunto de coeficientes, cada uno de los cuales designa una determinada frecuencia espacial. Los coeficientes de baja frecuencia representan las formas y tendencias generales de la línea, mientras los de alta frecuencia lo hacen con los pequeños detalles. En todo proceso de generalización el objetivo es retener lo general para eliminar lo particular. Así, el uso de las representaciones frecuenciales queda justificado, ya que la generalización se alcanza reteniendo los coeficientes de baja frecuencia y eliminando los de alta frecuencia.

El primer problema que se encuentra para pasar una línea al dominio de la frecuencia es que se necesita conocer los distintos valores de curvatura que va tomando. Pero una polilínea no tiene curvatura, ya que está formada por segmentos rectos. Una solución es sustituir los vértices de una línea por pequeños arcos de circunferencia cuyo radio sea menor a la resolución de la línea, de forma que a ambos lados de cada vértice los puntos de contacto sean diferenciables (Plazanet et.al, 1995). García (García, 1998; García y Ariza, 1999, 2000b) opta por calcular la curvatura de cada punto a partir de la circunferencia que cada punto forma con sus vecinos anterior y posterior.

Un dato importante a tener en cuenta es que el número de coeficientes frecuenciales necesarios para obtener una línea análoga a la original puede ser muy superior al número de coordenadas original. Plazanet et.al (1995) necesitó 500 coeficientes de Fourier para mantener una buena aproximación a una sinuosa línea de 140 puntos.

Series de Fourier

Para esta representación se utilizan filtros análogos a los que se emplean normalmente en procesamiento de señales. La expresión general de la serie de Fou-

rier la podemos hallar fácilmente en la bibliografía: Cañada (1994) o Pinilla (1997) son algunos ejemplos.

Sea una función periódica *f(t)*:

$$f(t) = f(t + nT); \quad n = 0, 1, 2, \ldots$$

Se demuestra que cualquier función periódica *f(t)* que sea continua por tramos e integrable sobre cualquier intervalo pude representarse con la siguiente serie trigonométrica:

$$f(t) = \frac{1}{2}a_0 + \sum_{n=1}^{\infty}\left(a_n \cos n\omega_0 t + b_n \operatorname{sen} n\omega_0 t\right)$$

Pero la representación frecuencial de una línea no es una función periódica, por lo que será necesario utilizar la transformada de Fourier *F(ω)*, que es la que permite el tratamiento de este tipo de funciones:

$$F(\omega) = \Im\,[f(t)] = \int_{-\infty}^{\infty} f(t)e^{-i\omega t}\,dt$$

En general, los resultados obtenidos por Plazanet et.al (1995) (ver ejemplo en Figura II.30) no son plenamente satisfactorios, ya que se encontraron los siguientes defectos:

- Los detalles de tamaño medio ofrecen una fuerte resistencia a ser suavizados.
- Se producen notables desplazamientos en la localización de la curva.
- Las curvas, aunque amplificadas, son normalmente acortadas.
- Ocasionalmente se dan fenómenos de interferencia. Esto hace que la longitud de onda que se quiere eliminar reaparezca en los bordes de la curva.

En cambio, en algunos aspectos el empleo de series de Fourier se comportó muy bien:

- Los pequeños detalles son eliminados, con lo que el suavizado resultante es muy bueno.

- Se produce un amplificación de las curvas, ideal para reforzar las formas principales y para exagerar el trazado de las vías de comunicación.

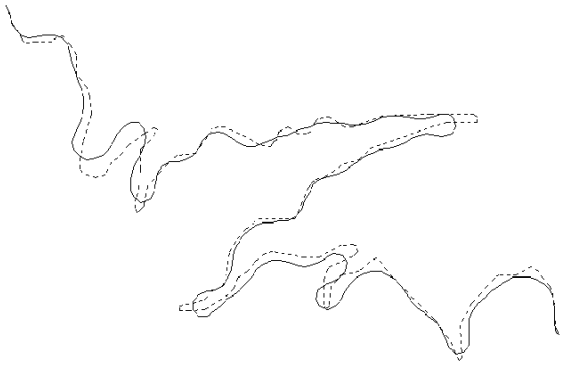


Figura II.30 - Filtrado (línea continua) mediante truncado de la serie Fourier (Plazanet et.al, 1995).

Wavelets

La técnica de la descomposición wavelet seguida en Plazanet et.al (1995) intenta solventar algunos de los problemas planteados con las series de Fourier. Los valores de curvatura son transformados en los coeficientes wavelet tras la descomposición a través de una función llamada "wavelet madre", como puede ser la de Haar (p.e. ver Stollnitz et.al, 1996). La generalización se efectúa eliminando los términos cuyos coeficientes están por debajo de un umbral. Los resultados que obtuvieron fueron prometedores, ya que desaparecieron los efectos de interferencia y no hay frecuencias resistentes al filtrado. A continuación se expondrá la base teórica de las wavelets, dado el elevado interés que puede tener en su aplicación en generalización cartográfica.

El empleo de la wavelet comienza por considerar que una línea es una función unidimensional definida "a trozos", en cada uno de los cuales la curvatura toma un valor constante, bien porque se considera como una sucesión de segmentos y pequeñas circunferencias como se sugiere en Plazanet et.al (1995), o, por ejemplo, calculando para cada punto el radio de la circunferencia que forma junto con los puntos anterior y posterior como se propone en García (1998), García y Ariza (1999, 2000b). Así se puede pensar que se está ante un vector en un espacio de

j dimensiones V^j, donde 2^j es el número de valores de curvatura, condición que obligará a remuestrear los valores de curvatura para que su número sea de la forma 2^n.

Una forma de definir una base ortogonal de un espacio vectorial es como el conjunto mínimo de vectores con los que se puede generar cualquier otro vector de dicho espacio mediante combinaciones lineales. Es decir, las componentes de esa base serán linealmente independientes. Una forma de calcular estas componentes ϕ de un espacio V^j es la siguiente:

$$\phi_i^j(x) = \phi(2^j x - i) \qquad i = 0, 1, \ldots, 2^j\text{-}1\text{----------}$$

$$\phi(x) = \begin{cases} = 1 & si \;\; 0 \le 2^j x - i < 1 \\ = 0 & en\ cualquier\ otro\ caso. \end{cases}$$

Por ejemplo, si se tienen 2^2 valores iniciales, *j* será igual a *2*, y la base de V^2 resultará de ir sustituyendo los valores de *i* y de *j* en la expresión anterior:

$\phi_0^2(x) = \phi(2^2x - 0) = \phi(4x)$ $\quad \phi_0^2(x) = 1 \;\; si \;\; 0 \le 4x < 1 \rightarrow 0 \le x < 1/4$

$\phi_1^2(x) = \phi(2^2x - 1) = \phi(4x-1)$ $\quad \phi_1^2(x) = 1 \;\; si \;\; 0 \le 4x-1 < 1 \rightarrow 1/4 \le x < 1/2$

$\phi_2^2(x) = \phi(2^2x - 2) = \phi(4x-2)$ $\quad \phi_2^2(x) = 1 \;\; si \;\; 0 \le 4x-2 < 1 \rightarrow 1/2 \le x < 3/4$

$\phi_3^2(x) = \phi(2^2x - 3) = \phi(4x-3)$ $\quad \phi_3^2(x) = 1 \;\; si \;\; 0 \le 4x-3 < 1 \rightarrow 3/4 \le x < 1$

De este modo, si se tiene una función *f(x)* definida a trozos con cuatro valores constantes [9 7 3 5], estos valores se podrán obtener multiplicando por los coeficientes 9, 7, 3 y 5 cada una de las cuatro componentes calculadas (Figura II.31):

$$f(x) = c_0^2\phi_0^2(x) + c_1^2\phi_1^2(x) + c_2^2\phi_2^2(x) + c_3^2\phi_3^2(x)$$
$$f(x) = 9\times\phi_0^2(x) + 7\times\phi_1^2(x) + 3\times\phi_2^2(x) + 5\times\phi_3^2(x)$$

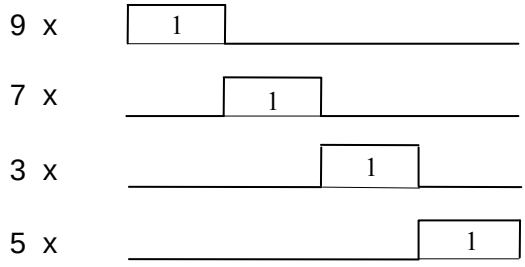


Figura II.31 - Obtención de los valores originales a partir de la base.

Lógicamente, cualquier vector definido en el espacio vectorial ortogonal V^j también estará contenido en el espacio V^{j+1}: $V^0 \subset V^1 \subset V^2 \subset ...$ Esto nos permite definir un nuevo espacio vectorial W^j, que es el complemento ortogonal de V^j en V^{j+1}, sabiendo que dos vectores son ortogonales si su producto escalar es nulo.

W^j también tendrá una base vectorial linealmente independiente cuyas componentes ψ_i^j serán llamadas *wavelets*. Se puede pensar que las wavelets nos permiten representar aquellas partes de una función en V^{j+1} que no pueden serlo en V^j. Las dos importantes propiedades de las wavelets son:

- Las wavelets ψ_i^j de W^j, junto con las componentes ϕ_i^j de V^j, forman una base en V^{j+1}.
- Cada componente ψ_i^j de W^j es ortogonal a cualquier componente ϕ_i^j de V^j.

Las wavelets de Haar establecen la base más simple posible. Su expresión matemática viene dada por:

$$\psi_i^j(x) = \psi(2^j x - i) \qquad i = 0, 1, \ldots, 2^j\text{-}1$$

$$\psi(x) = \begin{cases} = 1 & si\ 0 \le 2^j x - i < 1/2 \\ = -1 & si\ 1/2 \le 2^j x - i < 1 \\ = 0 & en\ cualquier\ otro\ caso. \end{cases}$$

Por ejemplo, la base de W^1 (Figura II.32) se obtiene de:

$$\psi_0^1(x) = \psi(2^1 x - 0) = \psi(2x) \qquad \psi_0^1(x) = 1 \quad si \quad 0 \le 2x < 1/2 \rightarrow 0 \le x < 1/4$$
$$\psi_0^1(x) = -1 \quad si \quad 1/2 \le 2x < 1 \rightarrow 1/4 \le x < 1/2$$
$$\psi_1^1(x) = \psi(2^1 x - 1) = \psi(2x\text{-}1) \qquad \psi_1^1(x) = 1 \quad si \quad 0 \le 2x\text{-}1 < 1/2 \rightarrow 1/2 \le x < 3/4$$
$$\psi_1^1(x) = -1 \quad si \quad 1/2 \le 4x\text{-}3 < 1 \rightarrow 3/4 \le x < 1$$

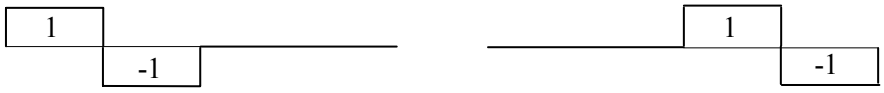


Figura II.32 - Componentes de la base de Haar en W^1.

De esta forma, la base en V^j puede representarse mediante las bases V^{j-1} y W^{j-1}. Éste es precisamente el proceso recursivo en que consiste la descomposición wavelet. La base en V^2, se puede obtener mediante la base V^1 y su complemento W^1. A

su vez V^1 se conseguirá mediante V^0 y su complemento W^0, con lo que V^2 se podrá reemplazar por V^0, W^0 y W^1:

$$V^2 \rightarrow f(x) = c_0^2\phi_0^2(x) + c_1^2\phi_1^2(x) + c_2^2\phi_2^2(x) + c_3^2\phi_3^2(x)$$
$$f(x) = 9\times\phi_0^2(x) + 7\times\phi_1^2(x) + 3\times\phi_2^2(x) + 5\times\phi_3^2(x)$$
$$V^1 \text{ y } W^1 \rightarrow f(x) = c_0^1\phi_0^1(x) + c_1^1\phi_1^1(x) + d_0^1\psi_0^1(x) + d_1^1\psi_1^1(x)$$
$$f(x) = 8\times\phi_0^1(x) + 4\times\phi_1^1(x) + 1\times\psi_0^1(x) - 1\times\psi_1^1(x)$$
$$V^0, W^0 \text{ y } W^1 \rightarrow f(x) = c_0^0\phi_0^0(x) + d_0^0\psi_0^0(x) + d_0^1\psi_0^1(x) + d_1^1\psi_1^1(x)$$

Para tener claro cómo trabaja la wavelet, se expondrá un ejemplo de García y Ariza (2000b) en el que se tiene una función unidimensional con ocho valores constantes: *[2 4 2 0 4 10 7 3]*. Utilizando la base de Haar, el proceso radica en ir agrupando los valores de dos en dos, calculando su media y almacenando las diferencias de estos respecto a la media, que serán llamadas coeficientes. En la siguiente pasada, de la misma manera se agruparán las medias de la pasada anterior de dos en dos y se repetirá el proceso. En última instancia se tendrá el valor medio y $2^n - 1$ coeficientes.

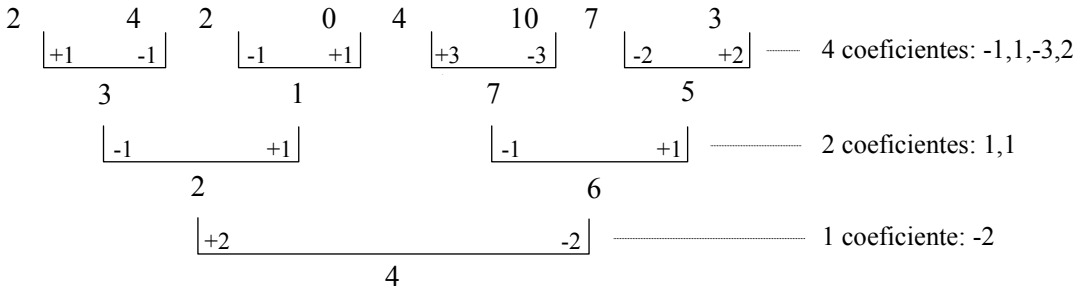


Figura II.33 - Ejemplo de descomposición de coeficientes wavelet.

El vector resultante de la transformación es el valor medio seguido de los siete coeficientes: *[4 -2 1 1 -1 1 -3 2]*. Los valores originales forman la base en V^3, los coeficientes *[-1 1 -3 2]* son la base en W^2, los coeficientes *[1 1]* son la base en W^1, *[-2]* es la base en W^0 y *[4]* es la base de V^0. En esta transformación ni se ha ganado ni se ha perdido información. Así, se podría efectuar la reconstrucción de los valores originales a partir del vector transformado, como se observa en la Figura II.34.

Además, para que la base sea normal su módulo debe valer la unidad. El módulo será el producto escalar de la base por sí misma y como todas componentes de

la base valen *1* ó *-1* el módulo siempre será igual a la raíz cuadrada del número de componentes de la base:

$$\sqrt{\sum_{i=1}^{2^j} 1^2} = \sqrt{2^j}$$

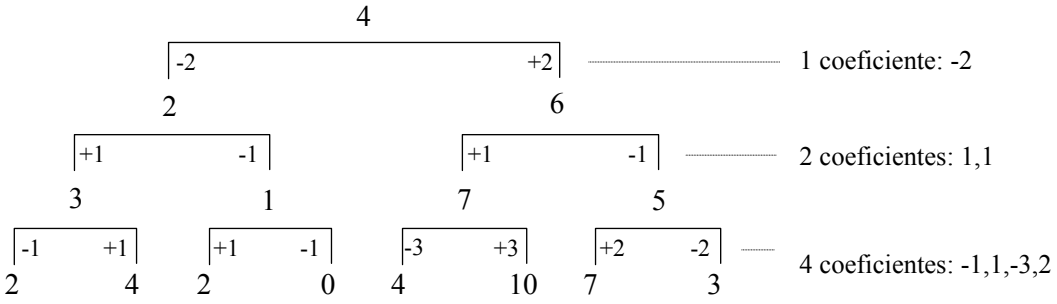


Figura II.34 - Ejemplo de reconstrucción a partir de coeficientes wavelet.

Por tanto, una forma para conseguir que la base sea ortonormal es dividir los coeficientes de V^j por su módulo $\sqrt{2^j}$, antes de proceder a la descomposición wavelet. En la Figura II.35 aparece el pseudocódigo del algoritmo que realiza la descomposición ortonormalizada en coeficientes wavelet, y en la Figura II.36 el del algoritmo que realiza la reconstrucción a partir de los coeficientes wavelet ortonormalizados.

```
Procedimiento Descomposición(c: array [1 .. 2^j] de reales)
   c = c/sqrt(2^j)          (normalización de los coeficientes de entrada)
   g = 2^j
   mientras (g ≥ 2) repetir
      desde (i = 1) hasta (i = g/2) repetir
         c'[i] = (c[2i-1]+c[2i])/sqrt(2)
         c'[g/2+i] = (c[2i-1]-c[2i])/sqrt(2)
      fin de desde
      c = c'
      g = g/2
   fin de mientras
fin del procedimiento
```

Figura II.35 - Pseudocódigo del algoritmo de descomposición wavelet (Stollnitz et.al, 1996).

```
Procedimiento Reconstrucción(c: array [1 .. 2^j] de reales)
   g = 2
   mientras (g ≤ 2^j) repetir
      desde (i = 1) hasta (i = g/2) repetir
         c'[2i-1] = (c[i]+c[2^j/2+i])/sqrt(2)
         c'[2i] = (c[i]-c[2^j/2+i])/sqrt(2)
      fin de desde
      c = c'
      g = 2g
   fin de mientras
   c = c*sqrt(2^j)          (se deshace la normalización)
fin del procedimiento
```

Figura II.36 - Pseudocódigo del algoritmo de reconstrucción wavelet (Stollnitz et.al, 1996).

Con la generalización mediante coeficientes wavelet lo que realmente se produce es una compresión de la información con posibilidad de pérdida controlada de parte de ella. Este proceso es bastante sencillo, consistiendo en ordenar los coeficientes, en valor absoluto, y eliminar los más pequeños igualándolos a cero. Al estar normalizada la base, la suma de los cuadrados de los coeficientes eliminados proporciona el error total introducido o la cantidad de información eliminada, por lo que se establecerá un umbral de corte.

A modo de ejemplo, se expondrá el ejemplo de García y Ariza (2000b) en el que se realiza la normalización, compresión y reconstrucción del mismo vector de la Figura II.33, [*2 4 2 0 4 10 7 3*]:

- Para normalizar la base, basta con dividir cada componente por $8^{1/2}$:

$$\left[\frac{2}{\sqrt{8}}\ \frac{4}{\sqrt{8}}\ \frac{2}{\sqrt{8}}\ 0\ \frac{4}{\sqrt{8}}\ \frac{10}{\sqrt{8}}\ \frac{7}{\sqrt{8}}\ \frac{3}{\sqrt{8}}\right]$$

- Al realizar la descomposición, los coeficientes wavelet resultan:

$$\left[4\ -2\ \frac{1}{\sqrt{2}}\ \frac{1}{\sqrt{2}}\ -\frac{1}{2}\ \frac{1}{2}\ -\frac{3}{2}\ 1\right]$$

- Se generaliza la serie, eliminando, por ejemplo, los cuatro coeficientes menores:

$$\left[4\ -2\ 0\ \ 0\ \ 0\ \ 0\ -\frac{3}{2}\ 1\right]$$

- La cantidad de información eliminada viene dada *por* $(1/2 + 1/2 + 0.5^2 + 0.5^2 = 1.5)$. Este valor es relativo a la cantidad de información de partida ($4^2 + 2^2 + 1/2 + 1/2 + 0.5^2 + 0.5^2 + 1.5^2 + 1 = 24.75$). Por tanto la información eliminada es ($1.5/24.75 \times 100 = 6\%$).

- El resultado de la reconstrucción de la secuencia simplificada es:

$$\left[\frac{2}{\sqrt{8}}\ \frac{2}{\sqrt{8}}\ \frac{2}{\sqrt{8}}\ \frac{2}{\sqrt{8}}\ \frac{3}{\sqrt{8}}\ \frac{9}{\sqrt{8}}\ \frac{8}{\sqrt{8}}\ \frac{4}{\sqrt{8}}\right]$$

- Por último, hay que deshacer la normalización de la base, multiplicando cada componente por $8^{1/2}$:

$$[2\ \ 2\ \ 2\ \ 2\ \ 3\ \ 9\ \ 8\ \ 4]$$

- Si se representa gráficamente ambas series se observa cómo se ha producido una simplificación (Figura II.37).

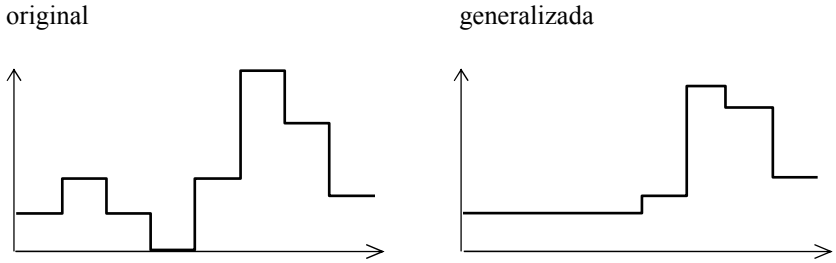


Figura II.37 - Funciones original y generalizada (García y Ariza, 2000b).

Una vez vista la base teórica de las wavelets, se resumirán los pasos consecutivos a realizar para su empleo en la generalización cartográfica de elementos lineales. Así, el proceso consiste en: paso al dominio frecuencial, remuestreo de la línea, codificación de la curvatura en coeficientes wavelet, eliminación de frecuencias, reconstrucción de los valores de curvatura y regreso al dominio espacial.

a) Paso al dominio de la frecuencia. En primer lugar se ha de pasar de una representación en forma de polilínea a una de tipo frecuencial (longitud, curvatura). La longitud será la acumulada desde el principio de la línea. Los métodos para obtener la curvatura pueden ser muy diversos. Un método sencillo consiste en ajustar arcos de circunferencia (Figura II.38), obteniéndose espectros de frecuencia tales como el de la Figura II.39.

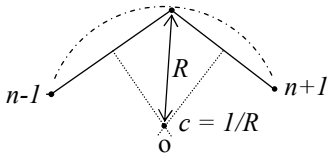


Figura II.38 - Radio de curvatura de un punto n.

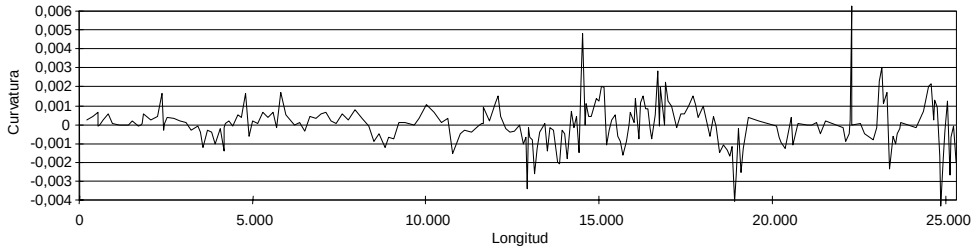


Figura II.39 - Espectro de frecuencia (longitud, curvatura) de una autovía (García y Ariza, 2000b).

b) *Remuestreo en el dominio de la frecuencia*. La representación wavelet necesita que el número de datos de partida sea de la forma 2^n y que estén equiespaciados. Esto no ocurre porque el total de vértices de una línea es un número cualquiera. Por ello se hace necesario un remuestreo de la línea, que será a intervalos regulares, con un número de intervalos de 2^n-1, con lo que habrá 2^n muestras. El intervalo elegido es el inmediatamente mayor a la longitud *l* del segmento más pequeño de la línea. De esta forma, se va dividiendo la longitud total *L* de la línea entre 2^n-1, para $n=1, 2, 3$...; en el momento en que $L/(2^n-1) < l$, entonces $2^{n-1}-1$ es el intervalo de muestreo. Un intervalo tan pequeño permite que la pérdida de información durante el muestreo sea despreciable. Al mismo tiempo que se remuestrean los valores de curvatura se hará lo mismo con los valores de *x* e *y*.

c) *Cálculo de la descomposición wavelet*. Una vez se dispone de las 2^n muestras de curvatura entra en juego la descomposición de estas muestras en los denominados coeficientes wavelet. Para ello se aplica, por ejemplo, el método de la Figura II.35. De esta forma pasaremos a tener el valor medio de curvatura y 2^n-1 coeficientes.

d) *Ordenación de los coeficientes y frecuencia de corte*. Con el fin de establecer qué coeficientes son los más relevantes para determinar la forma de la línea,

se ordenan de menor a mayor en valor absoluto. Se establecerá una determinada frecuencia de corte, por debajo de la cual todos los coeficientes serán igualados a cero. Este umbral quedará determinado mediante un tanto por ciento de la suma total de los cuadrados de todos los coeficientes. Se irán eliminando los menores al mismo tiempo que se suman sus cuadrados hasta alcanzar el límite establecido.

e) Reconstrucción a partir de los coeficientes wavelet. La reconstrucción permite tener una serie de valores de curvatura que formarán una representación frecuencial simplificada y que podrá ser asociada a las coordenadas *x* e *y* que habían sido remuestreadas en el paso (b). Dado que se han eliminado las frecuencias menores, los valores de curvatura ya no serán distintos para cada par de coordenadas; por el contrario, existirán series de coordenadas con idéntico valor de curvatura como se puede apreciar en la Figura II.40.

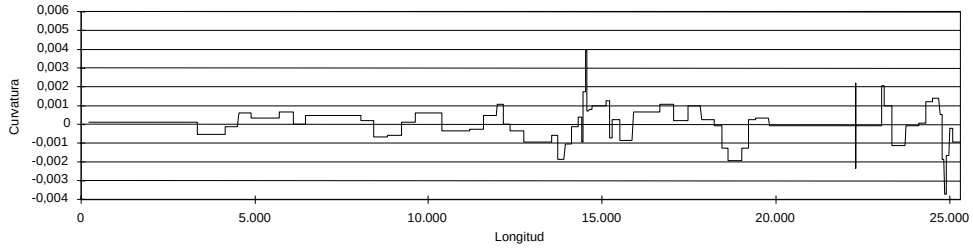
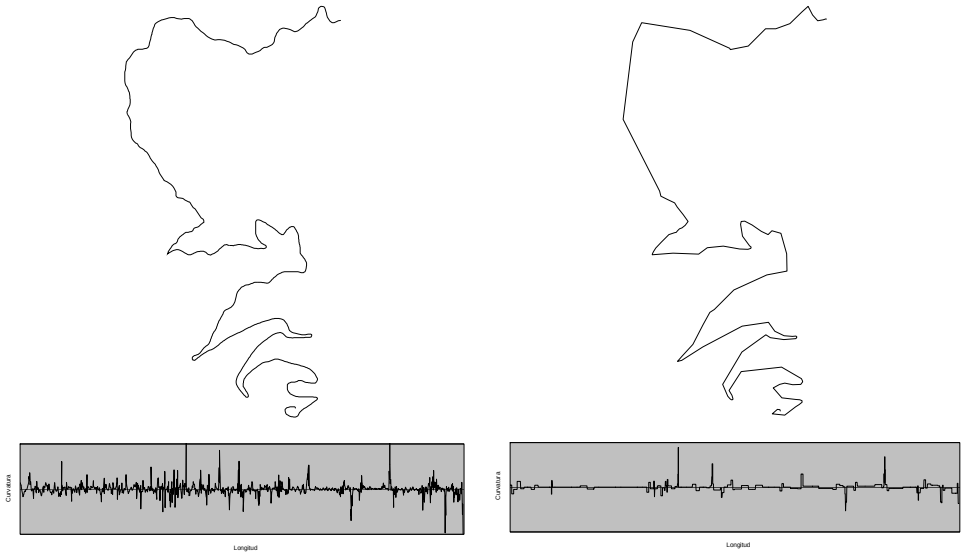


Figura II.40 - Espectro de frecuencia de la autovía tras la generalización wavelet (García y Ariza, 2000b).

f) Filtrado de las coordenadas y retorno al dominio espacial. Finalmente se opera con las coordenadas *x* e *y*. Para ello hay que efectuar algún tipo de operación sobre cada grupo de coordenadas consecutivas con el mismo valor de curvatura, obteniendo por fin la línea generalizada. La forma de operar sobre esas coordenadas (media aritmética, suavizado de McMaster, etc.) tiene una gran repercusión sobre el resultado final en la vuelta al dominio del espacio. En García y Ariza (2000b) se realiza una media aritmética con las coordenadas; un ejemplo de la generalización resultante se muestra en la Figura II.41.

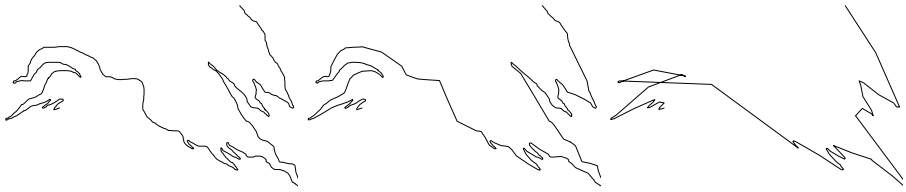
Los resultados obtenidos confirman la potencialidad que tienen las técnicas frecuenciales en el ámbito de la generalización cartográfica. Los principales aspectos a destacar de los resultados de García y Ariza (2000b) son los siguientes:

- A partir del análisis visual y de algunas medidas evaluadoras, se constata que se trata de una técnica que pretende la extracción de la tendencia principal de la línea, algo indicado para fuertes reducciones de escala, en las que ya no interesa mantener la línea fiel a su original.
- Los resultados han sido adecuados en ocasiones, sobre todo en líneas suaves y homogéneas como una autovía o una línea de ferrocarril, pero incorrectos en otras (p.e. 10% de coordenadas en Figura II.42). Se detectan problemas topológicos al cortarse algunas curvas consigo mismas en reducciones drásticas del número de coordenadas de la línea.
- La homogeneidad de la línea es una variable que condiciona los resultados. En caso de falta de homogeneidad, el filtrado concentra la generalización en las secciones más suaves, produciéndose una descompensación en el filtrado de la geometría de la línea. Esto puede ser positivo (p.e. en la Figura II.41), o puede provocar resultados inadecuados (ver ejemplo en la Figura II.42). Lamentablemente esto es difícilmente previsible, ya que dependerá de la propia geometría de la línea.
- El hecho de concentrar la generalización en secciones más suaves saca a relucir dos conclusiones: a) es conveniente segmentar la línea en secciones homogéneas antes de aplicar el filtrado wavelet, b) el propio filtrado wavelet es una técnica de potencial utilidad para las tareas de segmentación de elementos lineales, como se comentará con posterioridad en el apartado correspondiente de este documento.
- Futuras investigaciones deberán centrarse en perfeccionar este tipo de filtrado para ofrecer resultados con un verdadero aprovechamiento cartográfico. Así, existen procesos que deben ser investigados para mejorar los resultados obtenidos: procesado previo de la línea, métodos de paso al dominio de la frecuencia, intervalos de remuestreo de la curvatura, métodos de retorno al dominio espacial.



Original 10 % de coordenadas

Figura II.41 - Generalización de una pista de montaña mediante filtrado wavelet (García y Ariza, 2000b).



Original 50 % de coordenadas 10 % de coordenadas

Figura II.42 - Generalización de una pista de montaña mediante filtrado wavelet (García y Ariza, 2000b).

- Se observa en la Figura II.43 una tendencia exponencial en cuanto a la pérdida de información, conforme se eliminan vértices de la línea original mediante el filtrado. Empíricamente se ajusta a la función $y = 2.96766\ e^{0.0311063x}$. Las líneas más suaves tienen una evolución más moderada que las sinuosas. Éstas comienzan perdiendo menos información que las suaves, pero su evolución es más rápida
- Debido a la sensibilidad de le técnica a la sinuosidad y homogeneidad de la geometría de la línea, se ha observado su utilidad para establecer clasificaciones u ordenaciones automáticas de sinuosidad u homogeneidad de elementos lineales.

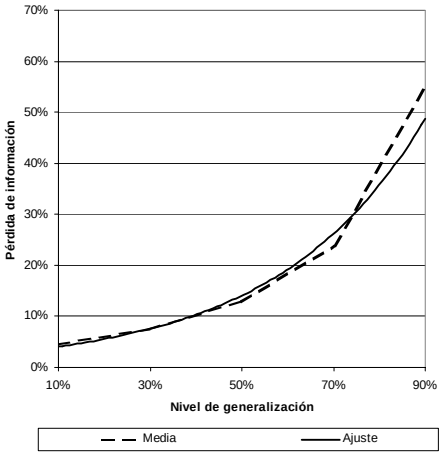


Figura II.43 - Promedio y ajuste exponencial de la evolución del porcentaje de pérdida de información en función del número de vértices eliminados (García y Ariza, 2000b).

II.5.5. Algoritmos de caricaturización

La caricaturización ha sido raramente tenida en cuenta en la investigación en generalización (Lecordix et.al, 1997). Este operador pretende agrandar o dilatar las formas de una línea para hacerlas perceptibles y legibles, por ejemplo evitando los conflictos internos de coalescencia que son provocados por la simbolización (Plazanet, 1996, pp. 34, 165). Por tanto se trata de un operador muy útil cuando la reducción de escala es fuerte (por ejemplo desde la escala 1:50 000 a la 1:200 000) y por tanto la generalización del elemento lineal va a ser muy drástica, tratando de ensalzar las principales formas de la línea. Podemos decir que el objetivo es conservar el mensaje que se pretende transmitir, aun cuando esto conlleve una pérdida de precisión geométrica del elemento lineal.

Según Plazanet (1996, p. 34), las líneas con curvas amplias y suaves, como las líneas de ferrocarril, autopistas y autovías, canales navegables, pueden soportar una fuerte reducción de escala sin necesitar caricaturización. En cambio, las líneas más sinuosas, como las carreteras, caminos, cursos de agua..., contienen numerosas curvas de pequeño tamaño que serían imperceptibles a escalas pequeñas, por lo que se deben conservar las más significativas, ampliando su tamaño de forma que se adapten a la simbolización y sean legibles.

Por otro lado, esta autora puntualiza el carácter local de la caricaturización, ya que este operador se aplica en función de unas características concretas de una determinada sección de la línea. Las operaciones más comunes a aplicar son la exageración de la dimensión de los objetos, y la ampliación o extensión de las curvas. En Lecordix et.al (1997) se presentan varios algoritmos de caricaturización, los cuales resumiremos brevemente a continuación:

- **Adaptación del algoritmo de Lowe**. Como se ha referido en el apartado de filtrado por convolución espacial, se trata de corregir el desplazamiento hacia el centro de curvatura que provoca el filtro gausiano, desplazando cada punto, para aproximarlo a la línea original, en función de la curvatura de la línea.
- **Algoritmo del acordeón**. Propuesto por Plazanet (1996), se aplica a una curva individual o a un conjunto de curvas consecutivas en el caso de que se produzca coalescencia debido a la simbolización. Esta técnica intenta "estirar" las curvas de forma parecida al estiramiento de un acordeón. Para definir el eje sobre el que se producirá el estiramiento, se procede a una detección de los puntos de inflexión de la serie de curvas para, a continuación, ajustar una recta de regresión (ver ejemplo en la Figura II.44).

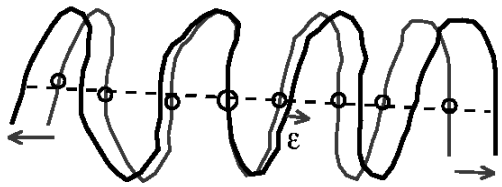


Figura II.44 - Diagrama del algoritmo del acordeón (Plazanet, 1996).

- **Algoritmo del globo**. Se aplica si la coalescencia se produce en los picos de las curvas. Aunque el algoritmo del acordeón podría mitigar la coalescencia en este caso, es preferible mantener la exactitud geométrica de los extremos de la curva y actuar directamente en la zona en conflicto. El nombre del algoritmo procede de la analogía existente con el inflado de un globo. La técnica consiste en desplazar cada punto de la línea en dirección perpendicular a la curva en dicho punto. Este desplazamiento será proporcional a la distancia hasta el pico de la curva, y por tanto será nulo en el

punto de inflexión y máximo en el propio pico (ver ejemplo en la Figura II.45).

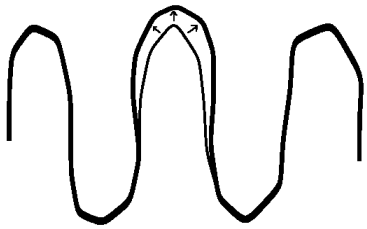


Figura II.45 - Diagrama del algoritmo del globo (Plazanet, 1996).

- **Algoritmo de esquematización**. Existen ocasiones en que la coalescencia es tan fuerte que no es conveniente que sea corregida por el algoritmo del acordeón o el del globo, para no provocar una excesiva alteración de la geometría de la línea original e incluso problemas con otras capas temáticas, como incoherencias entre las curvas de nivel y las carreteras. La esquematización pretende eliminar parte de las curvas de una serie consecutiva, de forma que permanezca el mensaje que se pretende transmitir (una serie de curvas consecutivas), pero sin coalescencia y manteniendo el inicio y final de la serie en su localización. El método pasaría por seleccionar automáticamente o interactivamente qué curvas se pretenden eliminar, y a continuación aplicar el algoritmo del acordeón para estirar las que permanecen (ver ejemplo en la Figura II.46).



Figura II.46 - Diagrama del algoritmo de esquematización (Plazanet, 1996).

La automatización de los algoritmos de caricaturización pasaría primero por la detección automática de los lugares donde se produce la coalescencia debido a la simbolización del elemento lineal. Una de las propuestas en este sentido podemos encontrarla en Mustière (1995), el cual evalúa la distancia de cada punto de la línea hasta el borde del símbolo que está más cerca. En caso de que esa dis-

tancia sea superior a la mitad del grosor del símbolo, más cierto margen de tolerancia, se considerará que existe un conflicto (ver Figura II.47)

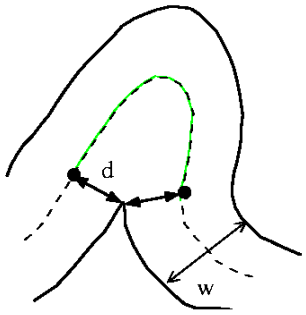


Figura II.47 - Ejemplo de detección de coalescencia en una curva (Lecordix et.al, 1997). La línea discontinua es el eje de la línea, la línea continua es el borde del símbolo. Cuando d > w/2 + tolerancia, se considera que existe conflicto.

II.5.6. Evaluación de la generalización

Dado que, como ya se ha comentado, las líneas son un elemento de gran importancia, al que se dedicaron los primeros esfuerzos investigadores en la automatización de su generalización, existen estudios específicos donde se han desarrollado parámetros o medidas evaluadoras de su generalización.

De todos estos trabajos destaca la obra de McMaster, que fue pionero en este tema. Las medidas señaladas por este autor constituyen un intento de evaluar objetivamente los resultados proporcionados por los clásicos algoritmos de generalización de elementos lineales, ya que el control visual es insuficiente y subjetivo. También destacan en este sentido los trabajos de Jasinski (1990). No obstante, se trata fundamentalmente de sencillas medidas geométricas, con total desconocimiento de otro tipo de medidas como las globales.

McMaster (1983, 1986) se centró en analizar qué medidas podrían ser susceptibles de proporcionar información suficiente para evaluar el resultado geométrico de la generalización, obteniendo valiosos resultados que es necesario comentar. Otros evaluaciones que advirtió, además de la geométrica, son las de tipo estético y computacional, que dejó como línea de investigación para el futuro.

Este autor seleccionó treinta y una líneas de distinto grado de complejidad sobre las que aplicó el algoritmo de Douglas-Peucker con dos valores de tolerancia distintos. Al mismo tiempo escogió y aplicó treinta medidas matemáticas (Tabla II.12) como potenciales medidas evaluadoras. Como éste es un número demasiado alto para un análisis, se hacía necesario reducirlo. Con los resultados de las treinta medidas analizó la redundancia presente entre las mismas, mediante un análisis estadístico basado en ACP, con lo que redujo su número a seis, siendo uno de los factores para elegir entre unas y otras su posible "utilidad cartográfica". De esta manera, son seis las medidas sugeridas por McMaster:

- *Porcentaje de cambio en el número de coordenadas, PCC*. Es el % de puntos que permanecen tras efectuar la simplificación, relacionando el número de coordenadas de la línea generalizada (*ns*) con el número de coordenadas de la línea original (*no*). Básicamente mide el grado de compactación de la información necesaria para representar la línea. Esta variable sirve para definir el nivel de generalización, imprescindible para comparar los resultados de distintos algoritmos.

$$PCC = \frac{ns}{no} \times 100$$

- *Porcentaje de cambio de la desviación típica del número de coordenadas por unidad, PCDT*. Se opera estableciendo una determinada unidad de longitud, que servirá para dividir la línea en secciones, en cada una de las cuales se observará el número de coordenadas que existen tanto en la línea original como en la simplificada. Acto seguido se calcularán las respectivas desviaciones típicas, σ_s y σ_o, que se relacionarán mediante un cociente y en %. Esta medida constituye un indicador de la homogeneidad de la reducción del número de coordenadas a lo largo de la línea. Evidentemente, si hay secciones de la línea con más puntos redundantes que otras, la simplificación será mayor en aquellas y el indicador se verá afectado, aumentando su valor.

$$PCDT = \frac{\sigma_s}{\sigma_o} \times 100$$

- *Porcentaje de cambio en la angularidad en valor absoluto, PCA*. Evalúa la capacidad de un algoritmo para mantener los ángulos de una línea. Se ob-

tiene determinando, para las líneas original y simplificada independientemente, la suma de los ángulos a_i que se forman en cada vértice, en valor absoluto, y relacionándolas en un cociente en %.

$$PCA = \frac{\sum_{i=2}^{n_s-1} |a_i|}{\sum_{j=2}^{n_o-1} |a_j|}$$

- *Vector total de desplazamiento por unidad de longitud, VTD*. Mide el desplazamiento que se ha producido en la localización de la línea a partir de la suma total de las distancias perpendiculares d_i que hay entre los vértices de la línea original y las correspondientes líneas bases integradas por cada dos puntos consecutivos de la línea simplificada. La suma se relaciona con la longitud total de la línea *L* y se expresa en %. Interesa que esta medida permanezca con el valor más bajo posible, ya que los efectos del desplazamiento son poco deseables.

$$VTD = \frac{\sum |d_i|}{L} \times 100$$

- *Área total de desplazamiento por unidad de longitud, ATD*. Análoga a la anterior, pero en esta ocasión se va computando la superficie a_i que media entre ambas líneas, también en valor absoluto. Es más robusta, ya que equivaldría a la anterior remuestreando el vector de desplazamiento con un intervalo infinitesimal.

$$ATD = \frac{\sum |a_i|}{L} \times 100$$

Tabla II.12 - Las treinta medidas evaluadoras del trabajo de McMaster (1986).

CATEGORÍA 1. MEDIDAS DE ATRIBUTO LINEAL.

Grupo A. Medidas de longitud.

1. Razón de cambio en la longitud de la línea.

Grupo B. Medidas sobre el número coordenadas.

2. Razón de cambio en el número de coordenadas.
3. Diferencia en la media del número de coordenadas por pulgada.
4. Razón de cambio en la desviación típica del número de coordenadas por pulgada.

Grupo C. Medidas de angularidad.

5. Razón de cambio en la angularidad (suma de ángulos entre vectores consecutivos).
6. Razón de cambio en la angularidad positiva (hacia la izquierda).
7. Razón de cambio en la angularidad negativa (hacia la derecha).
8. Diferencia en la angularidad media por pulgada.
9. Diferencia en la angularidad media por ángulo individual.
10. Razón de cambio en el número de ángulos positivos.
11. Razón de cambio en el número de ángulos negativos.
12. Diferencia en la angularidad media positiva por ángulo individual.
13. Diferencia en la angularidad media negativa por ángulo individual.

Grupo D. Medidas de curvilinearidad.

14. Razón de cambio en el número de segmentos curvilíneos.
15. Razón de cambio en la media estadística del número de segmentos curvilíneos.
16. Razón de cambio en la longitud media de un segmento curvilíneo.

7. Razón de cambio en la desviación típica de la longitud media de los segmentos curvilíneos.

CATEGORÍA 2. MEDIDAS DE DESPLAZAMIENTO LINEAL.

Grupo E. Medidas de vectores diferencia.

18. Longitud total de los vectores diferencia por pulgada.
19. Número de vectores diferencia positivos por pulgada.
20. Número de vectores diferencia negativos por pulgada.
21. Longitud total de los vectores diferencia positivos por pulgada.
22. Longitud total de los vectores diferencia negativos por pulgada.

Grupo F. Medidas de polígonos diferencia.

23. Diferencia areal total (suma de polígonos) por pulgada.
24. Número de polígonos areales positivos por pulgada.
25. Número de polígonos areales negativos por pulgada.
26. Diferencia areal total positiva por pulgada.
27. Diferencia areal total negativa por pulgada.

Grupo G. Medidas perimetrales.

28. Perímetro total de las diferencias por pulgada.
29. Perímetro total de las diferencias areales positivas por pulgada.
30. Perímetro total de las diferencias areales negativas por pulgada.

- *Porcentaje de cambio en el número de segmentos curvilíneos, PCSC*. Un segmento curvilíneo es aquel que media entre dos puntos de inflexión de la línea, es decir, está formado por aquellos segmentos cuyos ángulos poseen el mismo signo. Esta medida será el cociente entre los puntos de inflexión de las líneas original y simplificada, expresado en %. Se trata de

un buen indicador del grado de suavizado a que ha sido sometida una línea.

$$PCSC = \frac{nsc_s}{nsc_o} \times 100$$

Estas medidas, y otras similares, han sido empleadas a menudo para comparar cuantitativamente los resultados de diferentes métodos o niveles de generalización sobre diferentes tipos de líneas (Jansinski, 1990; Cromley y Campbell, 1990, 1992; Barber et.al, 1995; Reinoso, 1998; García, 1998; García y Ariza, 1999, 2000a, 2000b, García et.al, 1999, 2001; Reinoso et.al, 1999, 2001, etc.; Visvalingam y Brown, 1999). Sin embargo, hay que enfatizar dos grandes limitaciones de estas medidas evaluadoras. En primer lugar, están concebidas para algoritmos de eliminación de puntos, que ofrecen como resultado una polilínea, por lo que en la aproximación matemática se dificulta su aplicación, siendo incluso necesario recurrir a un muestreo, con la consiguiente pérdida de veracidad. En segundo lugar, estas medidas sólo sirven para medir el grado de semejanza de la línea generalizada respecto a la original, por lo que únicamente son útiles para aquellos casos en que es un objetivo que ambas sean lo más parecidas posible. Esto es apto para cambios de escala pequeños, pero es totalmente inadecuado para importantes saltos de escala, en los que se busca extraer la tendencia principal de la línea original y extraer los detalles más importantes. Las medidas de McMaster son útiles, por tanto, para el concepto de simplificación mínima del que habla Visvalingam (Visvalingam y Whyhatt, 1993), en el que despunta el algoritmo de Douglas-Peucker.

Otro problema, apuntado por Veregin (1999), es que empleando estas medidas se obtiene una indicación de la calidad de forma relativa, esto es, se puede concluir que Douglas-Peucker es mejor que otro algoritmo, pero no se cuantifica su bondad de forma absoluta, no se sabe lo lejos que está el resultado de aquel que pueda ser considerado óptimo.

Para Dutton (1999), que también cuestiona las medidas de McMaster, su empleo para seleccionar procedimientos o parámetros puede ser engañoso, ya que las medidas no están claramente correladas con la calidad visual. Es decir, una bue-

na generalización no tiene por qué ser aquella que minimiza las diferencias respecto a la línea original. No se puede descargar en ellas todo el control de la automatización de la generalización. Además subraya la importancia de evaluar la generalización a la escala deseada, de forma opuesta a la comparación directa con la línea original.

Así, en tanto no se conciban medidas más adecuadas de la calidad de la generalización, la evaluación deberá ser fundamentalmente realizada de forma subjetiva mediante el análisis visual.

II.6. SEGMENTACIÓN DE ELEMENTOS LINEALES

II.6.1. Necesidad de la segmentación

Según la R.A.E., segmentación es la "acción y efecto de segmentar", mientras segmentar es "cortar o partir en segmentos" y segmento es "porción o parte cortada o separada de una cosa, de un elemento geométrico o de un todo".

Diversos autores han señalado como esencial la segmentación de los elementos lineales de un mapa, en aras de la mejora de los resultados de la generalización de este tipo de elementos. El motivo es claro, pues la calidad de los resultados parece variar según las características de la línea (Buttenfield, 1991), y es usual que en un mapa aparezcan líneas cuyo trazado no sea uniforme en toda su longitud, evidenciando una clara predisposición a ser dividido en secciones más homogéneas.

Algunos comentarios acerca de la importancia del proceso de segmentación se pueden encontrar en Jasinski (1990), que señala como objetivo primordial la identificación de la estructura gráfica de la línea, Buttenfield (1991) y Dutton (1999), que proponen la división de una línea en partes homogéneas para una mejor selección de algoritmos y sus parámetros, Visvalingam y Williamson (1995), los cuales señalan la segmentación automática de líneas en sus partes constituyentes como un tema pendiente de investigar, o en Richardson y Macka-

ness (1999), que destacan la importancia de las técnicas de segmentación por la sensibilidad de los métodos de generalización a los diferentes tipos de líneas. Las palabras de Plazanet (1997) son aún más concluyentes: "la generalización requiere primero que el objeto bajo estudio sea segmentado, de forma que sus características locales puedan ser procesadas por algoritmos adecuados". E incluso la segmentación podría tener aplicación en otros ámbitos científicos, como puede ser le identificación de diferentes formas geomorfológicas en Geología (Skopeliti y Tsoulos, 1999).

La segmentación está íntimamente ligada a los conceptos de homogeneidad, sinuosidad y complejidad de una línea, a su vez relacionados con el de puntos críticos, definidos en este caso como aquellos que señalarán los lugares donde se produce un cambio que permitirá ir segmentándola. Estos puntos se pueden detectar, por ejemplo, evaluando los puntos de inflexión, los picos o fuertes cambios de dirección, o a través de un espectro de frecuencias. Para Müller (1986, p. 123) los cartógrafos siempre han tratado de preservar el grado relativo de complejidad de las diferentes secciones de línea que perciben.

Es evidente, por tanto, que hacen falta medidas que permitan evaluar automáticamente si una línea (p.e. la de la Figura II.48) es más o menos homogénea, más o menos compleja, para guiar al proceso de subdivisión en diferentes secciones. La segmentación, al igual que otro tipo de procesos como el filtrado de puntos o de curvatura, mantiene una dependencia con el conocimiento geométrico de la línea, si acaso de una forma aún más estrecha. Es de interés hacer referencia a un apartado previo incluido en este documento (apartado II.5.2), dedicado a este tipo de conocimiento y las posibles medidas caracterizadoras a emplear.

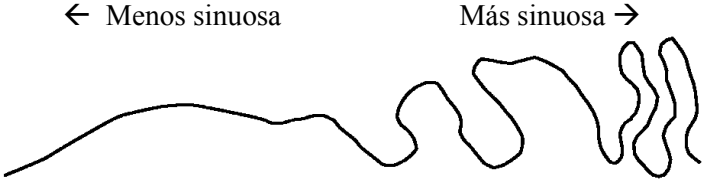


Figura II.48 - Ejemplo de línea no homogénea (Plazanet, 1996, p. 69).

Para Skopeliti y Tsoulos (1999, p. 60), la homogeneidad se refiere "a la conservación de ciertas características a lo largo de una sección de línea", y para realizar la segmentación pueden emplearse las mismas medidas empleadas para caracterizar la forma de una línea, definiendo los umbrales necesarios.

II.6.2. Segmentación mediante algoritmos de eliminación de puntos

Como ya se ha referido anteriormente, uno de los principales objetivos de la generalización es la utilización de bases de datos independientes de la escala para generar múltiples bases de datos a diferentes escalas mediante técnicas de generalización. Buttenfield (1991) mostró una metodología para localizar cuáles son las escalas en las que cambia sustancialmente la geometría del elemento lineal, evitando el ajuste manual de los parámetros de los algoritmos de generalización.

Aunque esta autora no habla expresamente del concepto de segmentación, su primer objetivo es la subdivisión de la línea en "porciones". Para ello se sirve del algoritmo de Douglas-Peucker, ya que puede ser empleado recursivamente para subdividir la línea y además es capaz de retener información relativa a su forma principal. Con este algoritmo subdivide la línea en 2^n secciones de forma jerárquica, siendo *n* el nivel de resolución, que toma valores de 3, 4, 5, etc... Cada sección se almacena en una estructura de datos en forma de árbol, un *striptree* (Ballard, 1981).

Sobre cada sección la autora calcula varias medidas geométricas elementales sobre su mínimo rectángulo encuadrante (MRE) (ver Figura II.49). Estas medidas son un refinamiento de las indicadas en Buttenfield (1986, 1989) y Jasinski (1990). Siendo *L* la longitud del MRE y la línea de anclaje aquella que une los puntos primero y último, se definen:

- *Ancho de banda*: A / L
- *Segmentación*: S / L

- *Varianza del error:* superficie entre la línea original y la de anclaje
- *Concurrencia:* nº de veces que la línea original se corta con la línea de anclaje dividido por el número de vértices de la línea original.

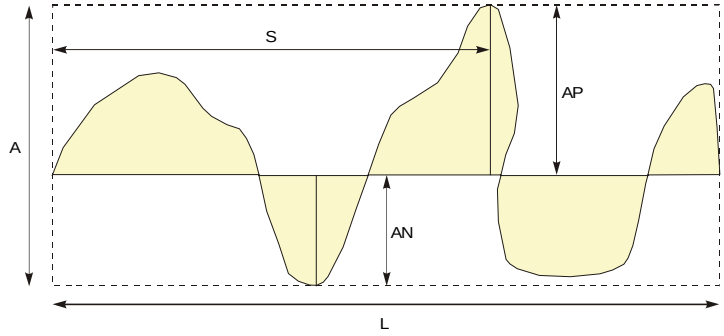


Figura II.49 - Medidas de Buttenfield (1991).

Luego calcula el promedio de cada medida sobre un determinado nivel de resolución, dando lugar finalmente a diferentes signaturas de cada medida a lo largo de los distintos niveles, una por cada parámetro. Sobre estas signaturas se podrían interpretar los cambios geométricos de cada línea, como por ejemplo, en la amplitud, angularidad y en la frecuencia del detalle. Esta información se emplearía para enriquecer cada línea de la base de datos, señalando qué valores de tolerancia son adecuados para preservar características geométricas específicas.

Los principales inconvenientes de este método se señalan en Plazanet (1996):

- Las medidas no son suficientemente finas localmente para apreciar la geometría y ser capaces de distinguir las formas.
- Todo el proceso de descripción está controlado por un mismo algoritmo: Douglas-Peucker.
- La segmentación se ha realizado en función de una desviación máxima (mediante Douglas-Peucker), cuando debería hacerse en función de unas propiedades geométricas de la línea.
- La estructura jerárquica propuesta se apoya en las transformaciones de la geometría a través de las diferentes generalizaciones, por lo que está fuer-

temente ligada a la escala o resolución. La jerarquía debería más bien mostrar una descripción cada vez más detallada del análisis de las líneas.

Van Oosterom (1995) y Zhao et.al (2001) también proponen el empleo del algoritmo de Douglas-Peucker para elaborar un *árbol binario de generalización de líneas* (*BLG-tree*, *binary line generalization–tree*), aplicando un parámetro cada vez menor. De esta forma se evitaría ejecutar el algoritmo cada vez que fuera necesario. Los nodos del árbol serían los índices de los puntos retenidos tras aplicar el algoritmo con un determinado parámetro.

Visvalingam y Williamson (1995) apuntaron la posibilidad de emplear el algoritmo de Visvalingam (Visvalingam y Whyhatt, 1993) en segmentación. La razón la justifican en tanto que el funcionamiento de este algoritmo se muestra capaz de ir eliminando progresivamente los detalles, partiendo de los más locales hasta los más globales, al ir aumentando su parámetro. Un ejemplo se puede observar en el filtrado aplicado sobre una muestra de calles a escala grande (Visvalingam y Herbert, 1999), que se presenta en la Figura II.50.

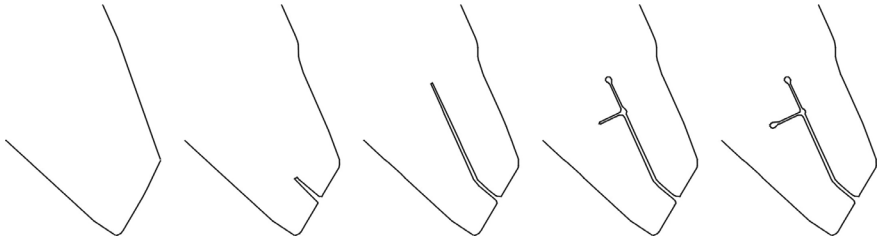


Figura II.50 - Evolución de un filtrado mediante el algoritmo de Visvalingam (Visvalingam y Herbert, 1999).

Esta forma de actuar ha sido corroborada posteriormente, como en Reinoso et.al (2001), en Visvalingam y Herbert (1999), o en van der Poorten y Jones (2002). Puede verse un ejemplo en la Figura II.51, donde se observa como los detalles de la línea de costa (rías, golfos, cabos, etc...) son eliminados gradualmente. Esto daría pie a estructurar la línea en un árbol de puntos o a detectar zonas homogéneas en cuanto a los valores de área efectiva de los puntos que las integran.

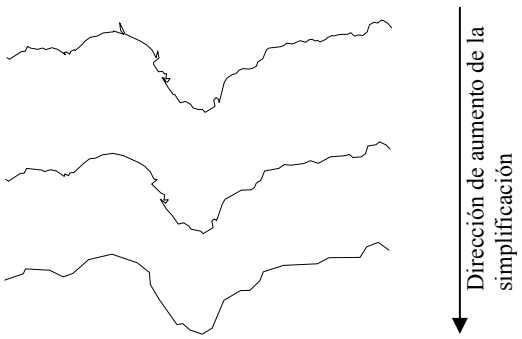


Figura II.51 - Filtrado con Visvalingam de la línea de costa de Andalucía (Reinoso et.al, 2001)

El algoritmo de Thapa (Thapa, 1989), modificado en el llamado Thapa Bidireccional Recursivo (TBR) en García et.al (2001), también ha sido señalado por estos últimos autores como potencialmente útil en segmentación, ya que los resultados del filtrado mediante este algoritmo se han observado muy sensibles a los cambios de sinuosidad a lo largo de la línea, con una fuerte tendencia a conservar puntos en tramos sinuosos y a eliminarlos en zonas suaves (ver ejemplo en Figura II.52). No obstante aún no ha sido ensayada esta posible capacidad de este algoritmo.

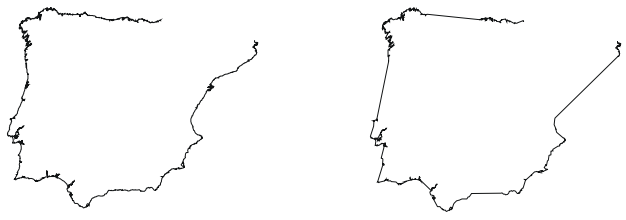


Figura II.52 - Filtrado de la Península Ibérica mediante TBR (García et.al, 2001)

II.6.3. Segmentación jerárquica mediante puntos de inflexión

Plazanet (Plazanet 1995, 1996, 1997; Plazanet et.al, 1995, 1998) propone un método de segmentación jerárquica de un elemento lineal. Este método tiene su punto de partida en los trabajos de Buttenfield (1986, 1991), que había ensaya-

do en años anteriores una estructura jerárquica de la línea, y en los trabajos en el campo de la visión artificial de Mokhtarian y Mackworth (1986, 1992), que plantearon la descripción multiescalar de una curva en función de su curvatura.

Plazanet establece la jerarquía considerando varios niveles de análisis, tratando de imitar la percepción humana de una línea (ver Figura II.53):

- *Nivel global*, correspondiente a la línea completa.
- *Niveles intermedios*, correspondientes a las secciones segmentadas de la línea.
- *Nivel local*, correspondiente a una curva.

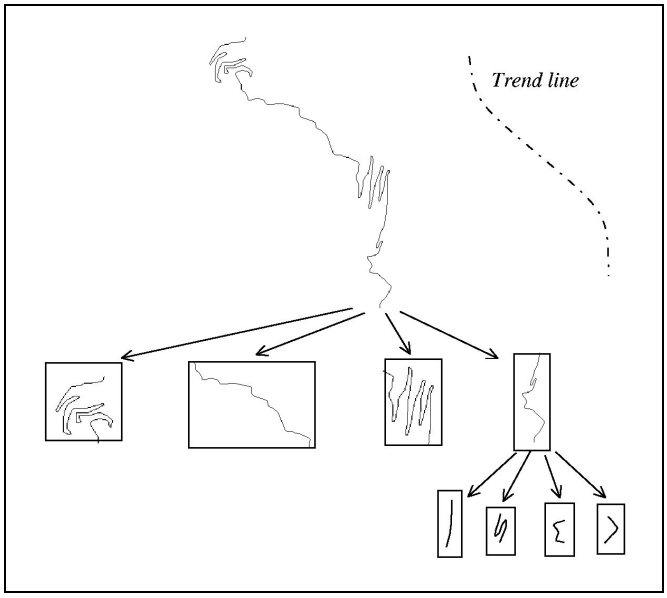


Figura II.53 - Ejemplo de segmentación manual (Plazanet et.al, 1995).

Este modelo descriptivo puede representarse mediante un árbol que sintetiza la estructura de la línea (ver Figura II.53) que se irá formando al analizar recursivamente la línea, o sección de la misma, en cuanto a su homogeneidad. Es decir, la construcción del árbol se basa en dos pasos recursivos:

- Segmentación en partes homogéneas
- Cálculo de medidas en cada parte, que permitan analizar la geometría y realizar una clasificación.

En suma, se procede desde el nivel global hasta el local segmentando la línea en el caso de que sea heterogénea. Si es homogénea se procederá a una fase de análisis para clasificarla detalladamente. De esta forma, los nodos corresponderán a las secciones de la línea y tendrán asociados una serie de atributos (sinuosidad, homogeneidad...). Las ramas que unirán los nodos serán las operaciones de segmentación. La raíz vendrá dada por la línea original mientras las hojas serán las secciones más homogéneas o de detalles individuales.

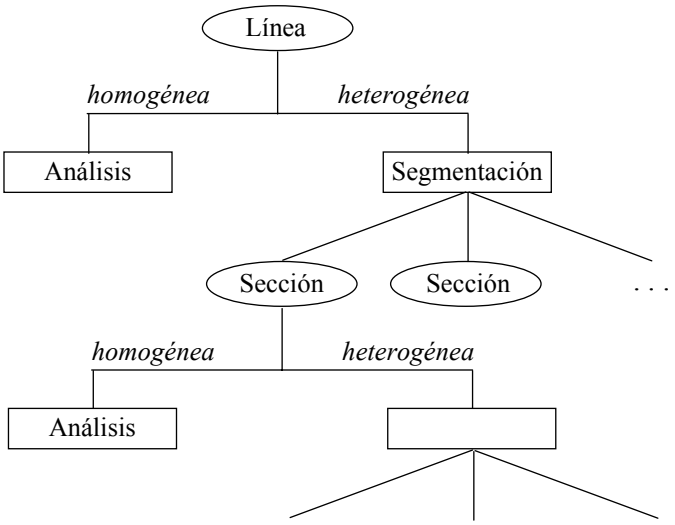


Figura II.54 - Árbol jerárquico de segmentación de líneas (Plazanet, 1996).

Según Plazanet (1997), "desde un punto de vista teórico, podemos considerar que este árbol proporciona una base de conocimiento a partir de la cual se pueden elegir las operaciones de generalización adecuadas".

Una vez fijado el modelo para describir la estructura de una línea, Plazanet realiza una propuesta concreta para la segmentación preliminar de una línea, es decir, para acometer la segmentación más global. La autora propone una definición de homogeneidad basada en el mantenimiento de la distancia entre los puntos de inflexión y en la búsqueda de puntos críticos.

Para ello se procede a extraer todos sus puntos de inflexión (PI), cuyo número variará según el nivel de análisis, y a calcular la distancia media *M* que existe entre dos PI consecutivos. Seguidamente se irán recorriendo todos los PI extraí-

dos, calculando la distancia de cada uno hasta el PI anterior, *d1*, y hasta el posterior, *d2*. Si (*d1<M y d2>M*) ó (*d1>M y d2<M*), entonces existe un punto crítico que distinguirá dos secciones diferentes.

Efectuar esta detección de puntos críticos es sencillo, pero falta relacionar el número de puntos de inflexión con cada nivel de análisis del árbol. Para Plazanet, sustentándose en los trabajos de Mokhtarian y Mackworth (1986, 1992), la clave está en el suavizado a que es sometida la línea previamente. El suavizado será capaz de eliminar los detalles que no son significativos a un determinado nivel (ver ejemplo en la Figura II.55). Esto lleva a suponer la existencia de una jerarquía en los puntos de inflexión de una línea.

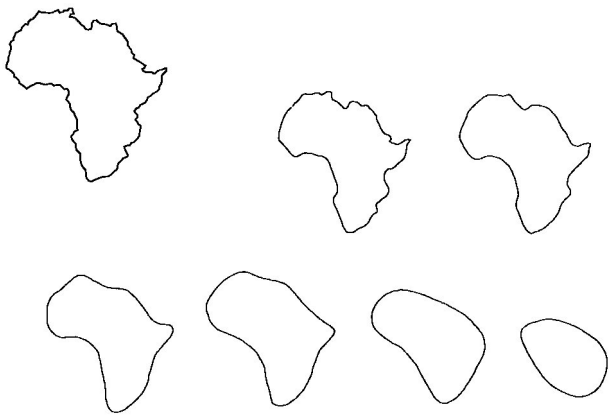


Figura II.55 - Evolución de la costa de África con un suavizado gausiano (Mokhtarian y Mackworth, 1992).

Como se deben detectar más puntos de inflexión al ir descendiendo en el árbol, desde la raíz hacia las hojas, el suavizado de la línea deberá ser cada vez menor: muy elevado para la línea al completo, para detectar sólo los puntos de inflexión más importantes, y poco o nada suavizada en secciones muy locales para detectar todos los puntos de inflexión. Esto concuerda con las palabras de Buttenfield (1986), para la que una línea está compuesta por una línea de tendencia principal y por detalles que se separan de ella. La línea de tendencia principal sería la "aproximación más suave posible", mientras los detalles vendrían dados por el resto de información.

El método de suavizado propuesto es el del filtro gausiano, en el que la variable que controla el nivel de suavizado es σ. Plazanet plantea el establecimiento de una regla empírica que automatice la elección del valor de σ; para ello elige interactivamente los valores que permiten conservar los puntos de inflexión más importantes sobre una muestra de líneas. De ese estudio deriva una regla empírica que establece que σ debe ser proporcional a la longitud *L* de la línea o sección, multiplicada por el logaritmo neperiano de la misma: $\sigma = k \times L \times ln(k \times L)$. El valor del *k* utilizado fue de 1/100 para la escala 1:50 000 (Plazanet, 1996, 1997). En la figuras II.56 y II.57 se presentan ejemplos de segmentaciones realizadas con esta regla empírica.

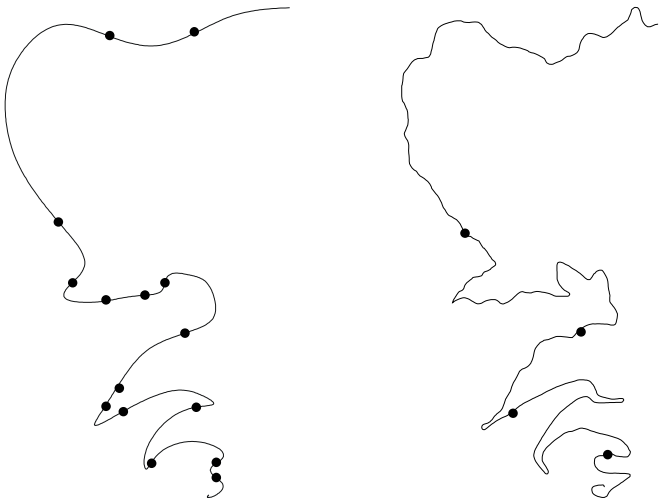


Figura II.56 - Ejemplo de segmentación mediante puntos de inflexión. A la izquierda, suavizada (σ = 16) y sus puntos de inflexión. A la derecha, original con los puntos de cambio de sección detectados.

No obstante, la propia autora advierte de que el parámetro *k* está en función de la complejidad de la línea (a mayor complejidad, mayor suavizado y por tanto, mayor σ) y que sería necesario un trabajo específico que estudiara la automatización del parámetro σ para los diferentes niveles de análisis del árbol.

Una vez una línea ha sido segmentada en secciones homogéneas para el nivel de análisis más global, separadas por los puntos críticos, Plazanet (Plazanet, 1995, 1996; Plazanet et.al, 1998) clasifica cada una de ellas en cuanto a su sinuosidad. Para ello selecciona dos medidas a calcular sobre cada sección,

- Ratio medio entre la altura y la línea base de una curva.
- Ratio medio entre la longitud curvilínea y la línea base de una curva.



Figura II.57 - Ejemplo de segmentación realizada por Plazanet (1996)

Con los resultados de estas medidas realiza un análisis cluster con el algoritmo de las K-medias. Prueba con 3 clases: 1 - casi rectilínea, 2 - sinuosa, 3 - muy sinuosa (Plazanet, 1995, 1997; Plazanet et.al, 1995) (ver Figura II.58) y con 4 clases: 1- menos sinuosas, 2 - baja sinuosidad, 3 - sinuosas, 4 - muy sinuosas (Plazanet et.al, 1998).

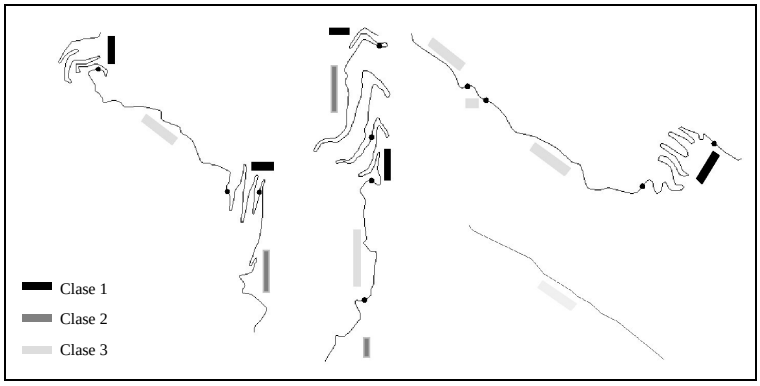


Figura II.58 - Clasificación de las secciones (Plazanet et.al, 1995; Plazanet, 1995, 1997).

Para Plazanet (1997), este proceso de segmentación y análisis, "no está relacionado con los algoritmos de generalización, sino con la percepción visual humana".

II.6.4. Segmentación a partir de cruces con la línea de tendencia

En Burghardt (2002) se presenta un método de segmentación concebido como paso previo al suavizado. La idea es detectar el número de veces en que la línea original se intersecta con la línea suavizada, ya que se presupone que un mayor número de intersecciones indica un aumento de la sinuosidad. Por tanto es necesario realizar un suavizado preliminar del elemento lineal para acometer esta técnica de segmentación.

El método puede resumirse en los siguientes pasos:

- Suavizar la línea original.
- Detectar las intersecciones entre la línea suavizada y la original.
- Realizar una segmentación preliminar, distinguiendo como sección sinuosa la comprendida entre dos intersecciones con distancia euclídea inferior a un umbral.
- Concatenar las secciones detectadas hasta que alcancen una longitud mínima. Comenzando por las más cortas, una sección se unirá a una contigua conservando el atributo de sinuosidad de la sección más larga.

Un resultado de este procedimiento puede observarse en la Figura II.59, en la que se advierte que sólo se distinguen dos categorías de sinuosidad. Sin embargo, el establecimiento de varios intervalos en lugar de un único umbral podría dar lugar al una categorización en de las secciones en varias clases.

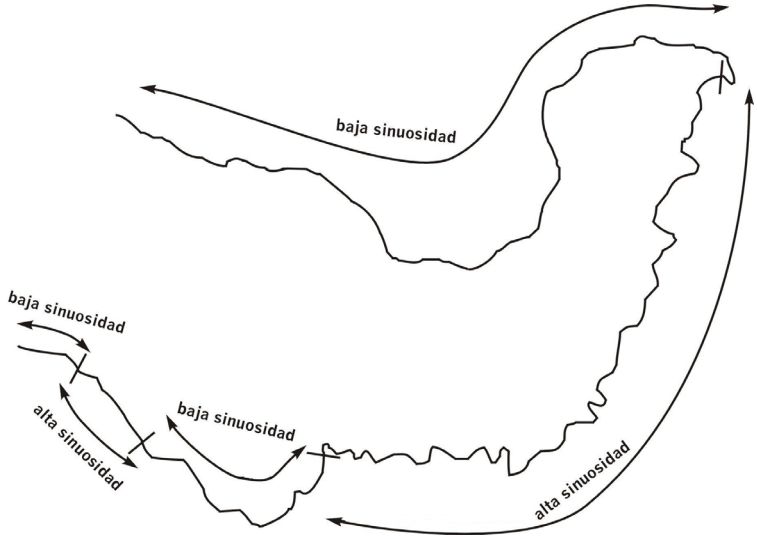


Figura II.59 - Ejemplo de resultado de la segmentación de una línea mediante cruces con la línea de tendencia (Burghardt, 2002).

II.6.5. Segmentación mediante la dimensión fractal

Plazanet (1996), tras emplear la dimensión fractal para realizar la clasificación de las secciones de un conjunto de líneas de carreteras (ver Figura II.60), considera los resultados poco satisfactorios. Aunque le parece una indicación de la cantidad de información que tiene un objeto o de la pérdida de información tras un cambio de resolución, no le parece satisfactoria para la caracterización de los elementos geográficos lineales.

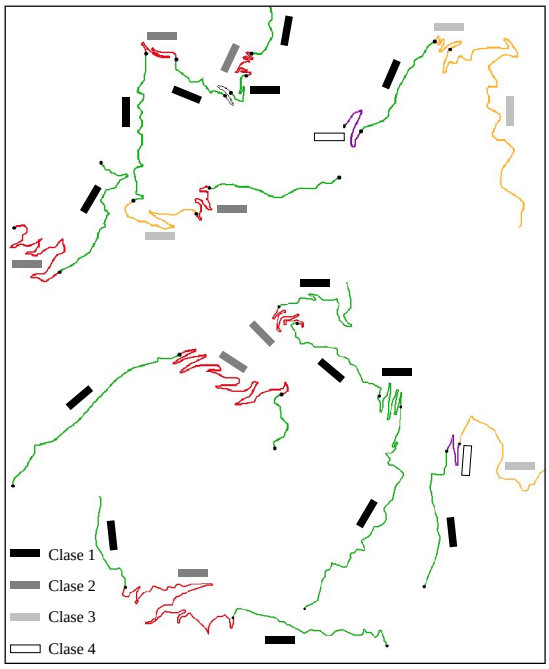


Figura II.60 - Clasificación de secciones de carreteras mediante la dimensión fractal (Plazanet, 1996).

Skopeliti y Tsoulos (1999) emplearon la dimensión fractal para acometer la segmentación de un conjunto de elementos lineales naturales. Señalan como principal ventaja del empleo de la dimensión fractal, a la hora de describir la complejidad de una línea, su globalidad, por definición, ya que no se deriva de una suma de medidas locales, como puede ser la angularidad media.

Para el cálculo de la dimensión fractal siguen una de las propuestas de Jasinski (1990), empleando como paso mínimo la distancia mínima que hay entre los vértices, doblando el paso en cada iteración hasta que alcanza uno tal que con sólo cinco de ellos se recorre toda la línea.

Su método pretende servirse de la capacidad de la dimensión fractal para describir la forma de una línea e identificar todas las secciones autosemejantes que existan, y la selección de aquellas que darán lugar a su partición en secciones de diferentes características. Las etapas sucesivas del método que proponen son las siguientes:

- *Identificación de secciones autosimilares*. Dado que la naturaleza de las líneas es conocida, se fija el valor crítico que implica un cambio en el carácter

de la línea (los autores no concretan más esta cuestión), que permitirá detectar los vértices inicio y final de una sección con dimensión fractal consistente. Para cada vértice de la línea se calculará una sección autosimilar y por tanto podrán existir vértices que pertenezcan a más de una de ellas.

- *Agrupamiento de secciones autosimilares.* En este paso se pretende identificar los grupos de diferente complejidad. Se ensayan dos alternativas para realizar este paso: a) utilización de valores característicos de la dimensión fractal y b) empleo del análisis cluster.

  La primera opción consiste en trazar el histograma de los valores de dimensión fractal calculados, para detectar los valores más característicos desde el punto de vista estadístico. El principal problema es que no tiene en cuenta la localización espacial de las secciones autosimilares a lo largo de la línea.

  La segunda opción sí considera la localización de las secciones autosimilares, ya que el análisis cluster se realiza con tres variables: vértice inicial, vértice final y dimensión fractal. El número de cluster se establece de forma empírica mediante el cociente entre la longitud total de la línea y la longitud del segmento autosimilar más pequeño.

- *Segmentación preliminar*. Se selecciona una sección representativa para cada cluster, que será aquel con dimensión fractal más próxima al valor medio del cluster. En caso de existir solape entre las secciones seleccionadas, se calculan una serie de medidas para categorizar la forma de cada una y a continuación se aplicarán varias reglas: 1) se unen las secciones que pertenecen a la misma categoría, 2) una sección que se solapa con dos secciones de diferente categoría es rechazada, 3) una sección que pertenece en parte a una sección de diferente categoría es rechazada.

- *Refinamiento de la segmentación.* Hasta ahora las secciones detectadas no garantizan una cobertura continua sobre la línea. Por ello se definen como nuevas secciones las fracciones de línea que han quedado en medio de dos secciones consecutivas. A continuación se categorizan mediante las mismas medidas que se han empleado en la segmentación preliminar, para unirlos a

las secciones contiguas en caso de resultar de la misma categoría. Finalmente se clasifican de nuevo todas las secciones.

Los autores señalan que los resultados obtenidos han sido calificados como "aceptables" por cartógrafos experimentados.

Como se puede advertir, en este trabajo tiene una importancia crucial la clasificación de las secciones detectadas. En este estudio se han empleado tres medidas, seleccionadas a partir de una Análisis de Componentes Principales (ACP), añadiendo cierto juicio cartográfico, de la serie de medidas de la Tabla II.13. Estas medidas son:

- Ratio entre la longitud de la línea y la longitud de la línea de anclaje
- Varianza del error
- Angularidad de magnitud media.

Tabla II.13 - Medidas empleadas en un ACP por Skopeliti y Tsoulos (1999)

Medidas propuestas por Buttenfield (1991)	**Medidas propuestas por Bernhardt (1992)**
• Dimensión fractal. • Ancho de banda. • Segmentación. • Varianza del error. • Concurrencia.	• Angularidad media. • Angularidad de magnitud media. • Curvilinearidad. • Desplazamiento vectorial medio. • Desplazamiento vectorial de magnitud media.
Otras medidas • Ratio entre la longitud de la línea y la línea de anclaje.	

Estas tres variables se calculan para cada sección y se aplica un análisis cluster, siguiendo los antecedentes de McMaster (1995), Plazanet (1996) o Reichenbacher (1995). Primeramente se efectúa un análisis cluster jerárquico, para identificar el número de clusters y sus centroides, para después aplicar un análisis cluster no jerárquico. Sus resultados dieron lugar al establecimiento de cuatro categorías: "muy suave" (grupo 1), "suave" (grupo 2), "sinuosa" (grupo 3) y "muy sinuosa con un gran arco" (grupo 4), cuyos resultados se pueden observar en la Figura II.61.

Por otro lado, la entropía podría ser útil para evaluar la calidad de una generalización, evaluando la cantidad de información que ha sido eliminada (McMaster, 1983).

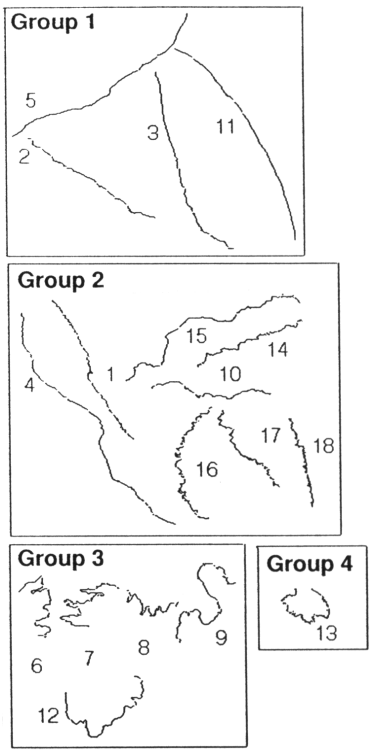


Figura II.61 - Clasificación efectuada por Skopeliti y Tsoulos (1999) sobre 18 líneas de costa escogidas de una base de datos 1:500 000.

II.6.6. Empleo de wavelets

Como ya se ha referido, el empleo de representaciones frecuenciales en generalización está plenamente justificado. En lo que a la segmentación respecta, las wavelets han sido señaladas como posibles herramientas para su aplicación sobre elementos lineales.

Plazanet y Fritsch (Plazanet et.al, 1995; Fritsch, 1997) comprobaron como una función *f* constituida por la suma local de los cuadrados de los coeficientes wavelet ofrecía una "muy buena descripción de la sinuosidad de la curva" (Plazanet et.al, 1995). La Figura II.62, "revela la relevancia de la representación wavelet para la segmentación de la línea".

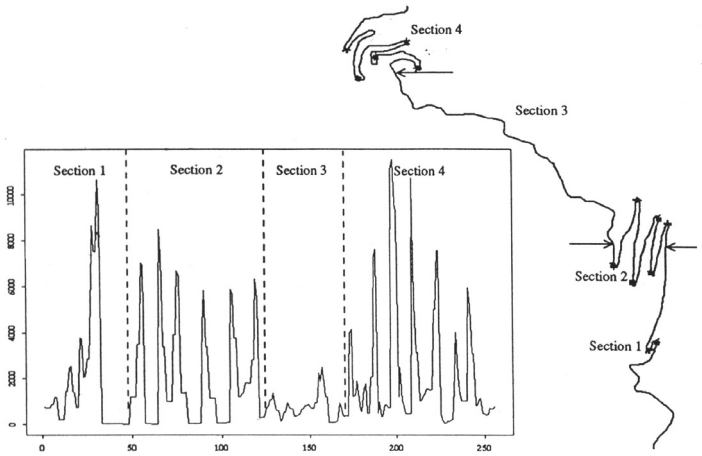


Figura II.62 - Detección de secciones mediante la función *f*.

García (García y Ariza, 2000b) emplea la representación wavelet para efectuar un filtrado de los elementos lineales en el dominio de la frecuencia, para después retornar a una representación en pares de coordenadas cartesianas. Los resultados que obtiene le llevan a afirmar que la técnica empleada es adecuada para la segmentación de una línea a partir de su falta de homogeneidad. Esto viene motivado por la descompensación que se produce en el filtrado al emplear esta técnica cuando una línea tiene secciones de distinta sinuosidad (ver Figura II.63)

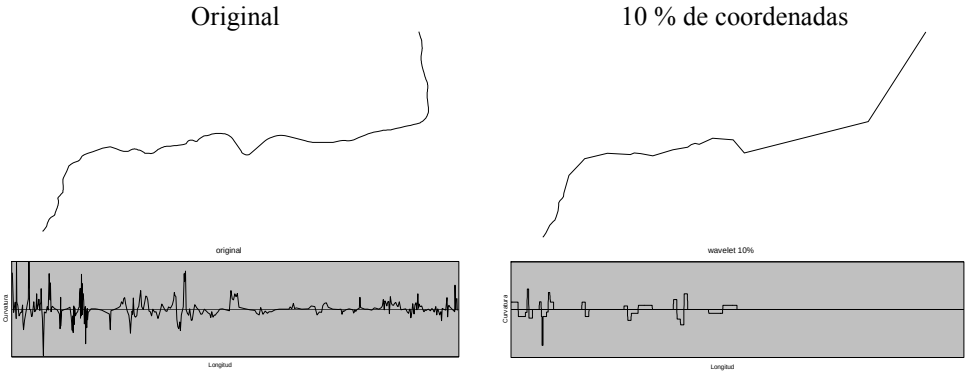


Figura II.63 - Descompensación de la generalización tras aplicar el filtrado wavelet: polilíneas y función de curvatura (García y Ariza, 2000b; García, 1998).

También ve factible realizar una clasificación de una muestra de líneas según su sinuosidad, analizando el parámetro de entrada empleado en el filtrado.

II.7. REDES NEURONALES

Ya se ha comentado la necesidad de formalizar el conocimiento cartográfico que aplican los expertos en generalización para tratar de facilitar la automatización del proceso. Una de las técnicas disponibles es la de las redes neuronales, dentro del campo de la Inteligencia Artificial, que se resumirá en este apartado.

Las herramientas de aprendizaje por computadora pueden dividirse según su aprendizaje sea supervisado o no supervisado (véase Plazanet, Bigolin y Ruas, 1998):

- El aprendizaje supervisado viene dado por un proceso en el que un agente externo, o profesor, define varias clases, proporcionando descripciones, usualmente vectores de atributos, de diferentes ejemplos de cada una. Tras el aprendizaje, el sistema debe ser capaz de pronosticar la clase de objetos diferentes a los ejemplos empleados para aprender. En otras palabras, el sistema debe aprender una función f, tal que $f(x_i) = y_i$, siendo x_i la descripción e y_i la clase. Existen diferentes herramientas de este tipo de aprendizaje: redes neuronales[2], redes semánticas, árboles de decisión, reglas de producción, etc.
- En el aprendizaje no supervisado, el sistema debe descubrir las clases por sí mismo, basándose en las propiedades comunes de los distintos objetos. Posteriormente habría que describir cada una de las clases formadas. Un ejemplo de este tipo de herramientas de aprendizaje es el de los algoritmos de agrupamiento (también llamado análisis cluster o clustering, del inglés "cluster" (grupo o conglomerado)).

Las redes neuronales forman parte del campo de la inteligencia artificial, concretamente de la rama denominada *redes de autoproceso*, definidas como (Hilera y Martínez, 1995) aquellas formadas por nodos en los que hay elementos procesadores de información de cuyas interacciones depende el comportamiento del conjunto del sistema. A su vez, las redes de autoproceso pueden dividirse en dos

categorías según sean de *procesamiento numérico* (se recibe directamente la señal de entrada desde el exterior y se opera sobre ella), que sería el caso de las redes neuronales, o simbólico. Centrando la atención en el procesamiento numérico, si la conexión entre nodos se realiza de forma global, se hablaría se *sistemas distribuidos*, denominando sistemas asociativos a la conexión realizada agrupando subredes (redes de redes). Dentro de los sistemas distribuidos, si se realizan agrupaciones locales de nodos para representar conceptos se habla de redes subsimbólicas, mientras si cada nodo funciona corporativamente, se tiene una *red neuronal*. Por tanto, la clasificación de la red neuronal en el campo de la inteligencia artificial viene dada por las siguientes categorías, de mayor a menor concreción: redes de autoproceso, procesamiento numérico, sistemas distribuidos, redes neuronales (ver figura II.64).

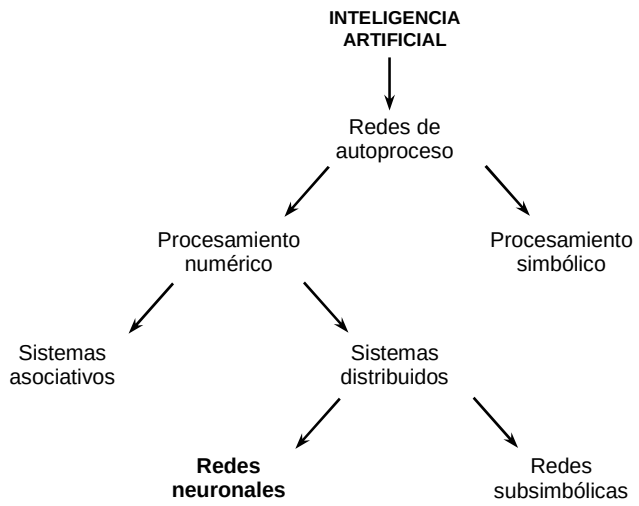


Figura II.64 - Situación de las redes neuronales en el campo de la inteligencia artificial (Hilera y Martínez, 1995).

La teoría y modelado de redes neuronales artificiales está inspirada en la estructura y funcionamiento de los sistemas nerviosos, donde la neurona es el elemento fundamental. Así, las redes neuronales son modelos simplificados que intentan reproducir el comportamiento del cerebro. Entre sus ventajas, debido a su semejanza con el cerebro humano, se encuentran las siguientes (Hilera y Martínez, 1995):

---

[2] No obstante, como se verá más adelante, existen modelos de redes neuronales de aprendizaje no supervisado.

- *Aprendizaje adaptativo*: las redes aprenden a realizar tareas mediante un entrenamiento con ejemplos ilustrativos. En el proceso de aprendizaje los enlaces ponderados de las neuronas se ajustan de forma que se obtengan unos resultados concretos, no necesitando un algoritmo para resolver un problema.
- *Autoorganización*: es la modificación de la red neuronal completa para llevar a cabo un objetivo específico. Esta autoorganización de la información provoca la generalización, esto es, la facultad para responder de forma apropiada cuando se presentan datos a los que no había sido expuesta con anterioridad. El sistema puede generalizar la entrada para obtener una respuesta.
- *Tolerancia a fallos*: frente a los sistemas computacionales tradicionales, que pierden la funcionalidad cuando sufren un error de memoria, las redes neuronales no sufren una caída repentina si se produce un fallo en un pequeño número de neuronas, aunque sí existirá una cierta degradación de su funcionamiento. Además, también muestran tolerancia a fallos respecto a los datos, pues aprenden a reconocer patrones con ruido, distorsionados o incompletos. Esta característica se derivada de la redundancia del almacenamiento de información a través de las conexiones entre neuronas.
- *Operación en tiempo real*: gracias a su implementación paralela, las redes neuronales pueden realizar grandes procesos con datos de forma muy rápida, con una necesidad mínima de cambio en los pesos de las conexiones.
- *Fácil inserción en la tecnología existente*: una red puede ser rápidamente entrenada, comprobada, verificada y trasladada a una implementación hardware de bajo coste, por lo que es fácil insertar redes neuronales para aplicaciones específicas en sistemas existentes.

En general, las redes neuronales se aplican cada vez más para la resolución de múltiples problemas de la vida real que son de considerable complejidad y cuya solución no puede o es difícil de alcanzar mediante computación de tipo algorítmico.

II.7.1. Conceptos de Neurona y Neurona Artificial

II.7.1.1. La neurona biológica

Una neurona es una célula viva, que contiene los mismos elementos que forman parte de todas las células biológicas, pero además, contiene elementos característicos que las diferencian, ya que se trata de células con capacidad de comunicarse (véase la Figura II.65). De su cuerpo celular, más o menos esférico, se originan una rama principal, el *axón*, y varias ramas más cortas, las *dendritas*. De forma general, las dendritas y el cuerpo celular reciben señales de entrada. El cuerpo celular combina e integra estas señales, y emite señales de salida a través del axón hacia un conjunto de neuronas. Una neurona suele recibir información de miles de otras neuronas, y a su vez enviar información a miles de neuronas más. Se calcula que en el cerebro humano existen del orden de 10^{15} conexiones.

Las señales que se utilizan son de dos tipos: eléctricas y químicas. La señal generada por la neurona y transportada a lo largo del axón es un impulso eléctrico. La señal que se transmite en las *sinapsis* (los contactos especiales entre los terminales axónicos de una neurona y las dendritas de las neuronas siguientes) es de origen químico, realizada mediante moléculas de sustancias transmisoras, neurotransmisores.

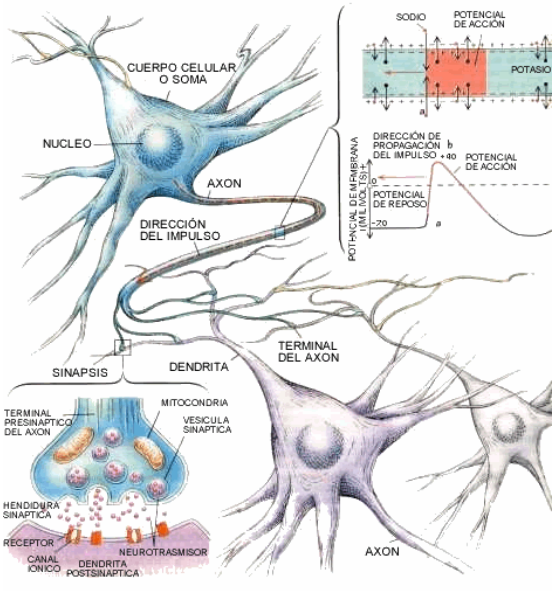


Figura II.65 - Esquema de la comunicación entre neuronas biológicas.

La generación de las señales eléctricas está relacionada con la composición de la membrana celular, y de forma simplificada se puede describir del siguiente modo: Una neurona tiene una diferencia de potencial de aproximadamente 70 milivoltios respecto al líquido exterior, gracias a la diferente concentración de iones sodio (mayor en el líquido exterior) y potasio (mayor en el interior de la neurona), que es lo que se llama *potencial de reposo*. La llegada de señales procedentes de otras neuronas a través de las dendritas actúa acumulativamente, bajando el valor del potencial de reposo hasta que la membrana se hace permeable a los iones sodio y se invierte la polaridad del interior de la membrana, inversión conocida como *potencial de acción*, que se transmite a lo largo del axón. Esta inversión cierra el paso a los iones sodio y abre el paso a los iones potasio hasta que se restablece el equilibrio de reposo.

Las sinapsis pueden ser de dos tipos: excitadoras e inhibidoras. Casi todas las neuronas reciben entradas procedentes de sinapsis de ambos tipos. Las primeras provocan disminuciones de potencial en la membrana de la célula postsinápitca, facilitando la generación de impulsos, y las segundas estabilizan el potencial de la membrana, dificultando la generación de impulsos. La suma de los efectos excitadores e inhibidores determina si la célula será o no estimulada.

II.7.1.2. La neurona artificial

La neurona artificial pretende mimetizar las características más importantes de las neuronas biológicas. Su trabajo es muy sencillo, consistente en recibir las entradas de las neuronas vecinas y calcular un valor de salida, que es enviado a todas las células restantes. Se pueden plantear las siguientes analogías entre la neurona biológica y la artificial: Las señales que llegan a la sinapsis son las entradas a la neurona; éstas son ponderadas, atenuadas o amplificadas, a través de un parámetro, que se denominará *peso*, asociado a la sinapsis correspondiente. Estas señales de entrada pueden excitar a la neurona, si la sinapsis es de peso positivo, o inhibirla, si es de peso negativo. El efecto es la suma de las entradas ponderadas. Si la suma es igual o mayor que el umbral de la neurona, entonces ésta se activa y provoca una salida.

Así, cada neurona i-ésima U_i está caracterizada en cualquier instante *t* por un valor numérico denominado *estado de activación* $a_i(t)$; éste es transformado en una *señal de salida* y_i mediante una *función de salida* o *función de transferencia* f_i:

$$y_i(t) = f_i(a_i(t))$$

Existen cuatro funciones de transferencia típicas que determinan distintos tipos de neuronas (véase la Figura II.66):

- Función escalón. Se considera que la activación de la neurona es binaria. Si la suma de las entradas es mayor o igual que el umbral de la neurona, la activación es 1; si es menor, la activación es 0 (ó -1).
- Función lineal y mixta. La función lineal responde a la expresión $f(x) = x$. En las neuronas con función mixta, si la suma de las señales de entrada es menor que un límite inferior, la activación es 0 (ó -1). Si la suma es mayor o igual que el límite superior, entonces la activación es 1.
- Función sigmoidal. Definida como $f(x) = 1 / (1 + e^{-ax})$, para la mayoría de los valores de entrada, el valor dado por esta función es cercano a uno de sus dos valores asintóticos. El parámetro *a* permite asemejarla a la función

escalón tanto como se quiera. Su importancia radica en el hecho de que su derivada está definida en todo el intervalo, es siempre positiva, y es cercana a cero para los valores grandes, positivos o negativos, lo cual es imprescindible para los métodos de aprendizaje en los cuales se usan derivadas.

- Función gaussiana. Definida como $f(x) = ce^{-axx}$, es más adaptativa que la función sigmoidal, ya que su centro y anchura puede ser adaptado.

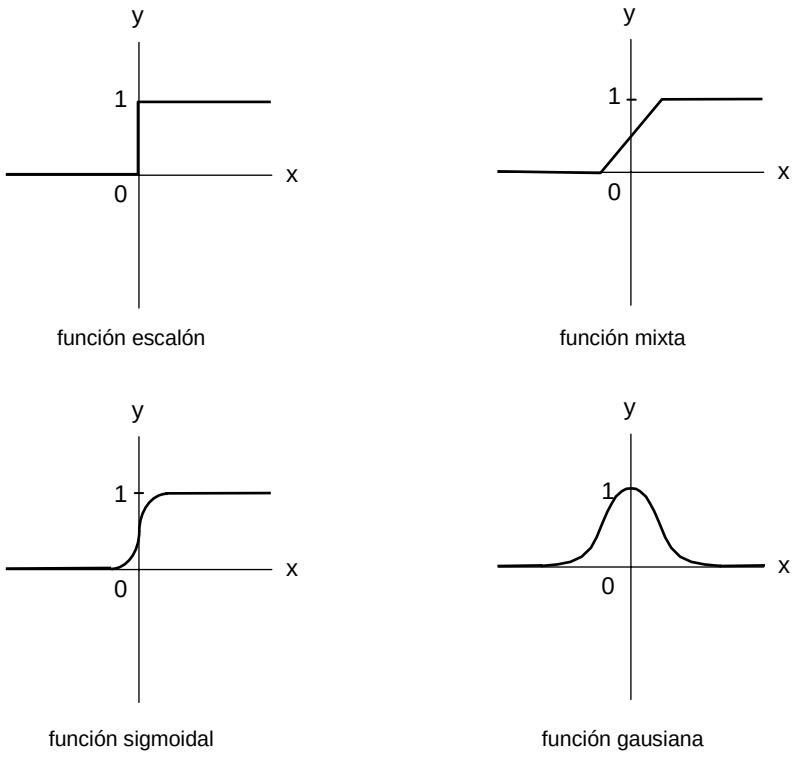


Figura II.66 - Funciones de salida (tipos de neuronas).

La señal de salida es enviada a otras neuronas de la red y es modificada según el peso w_{ji}. Se suele considerar que el efecto de cada señal es aditivo, de tal forma que la entrada neta que recibe una neurona es la suma del producto de cada señal individual por el valor del peso o sinapsis que conecta ambas neuronas. Así, al combinarse las señales que llegan a una neurona j-ésima U_j, se genera la *entrada total* Net_j:

$$Net_j = \sum_i y_i w_{ji}$$

Seguidamente la función *F*, denominada *función de activación*, produce un nuevo estado de activación en la neurona U_j a partir del estado a_j que tenía y la combinación de las entradas con los pesos de las conexiones Net_j:

$$a_j(t+1) = F(a_j(t), Net_j)$$

En la mayoría de casos *F* es la función identidad, por lo que estado de activación de una neurona en el instante *t+1* coincide con la entrada total *Net* en el instante *t*:

$$a_j(t+1) = Net_j$$

En este caso, la función de transferencia o de salida de la neurona U_j sólo dependería del valor Net_j:

$$y_j(t+1) = f(Net_j) = f(\sum_i y_j(t) w_{ij})$$

Si además se considera un umbral de activación de la neurona U_j, que se suele denotar como θ_j, la función de transferencia no estará centrada en el origen del eje que representa el valor de la entrada neta. La Figura II.67 muestra un esquema de las entradas y salidas de una neurona de este tipo, quedando la función de transferencia como sigue:

$$y_j(t+1) = f(Net_j - \theta_j) = f(\sum_i y_j(t) w_{ij} - \theta_j)$$

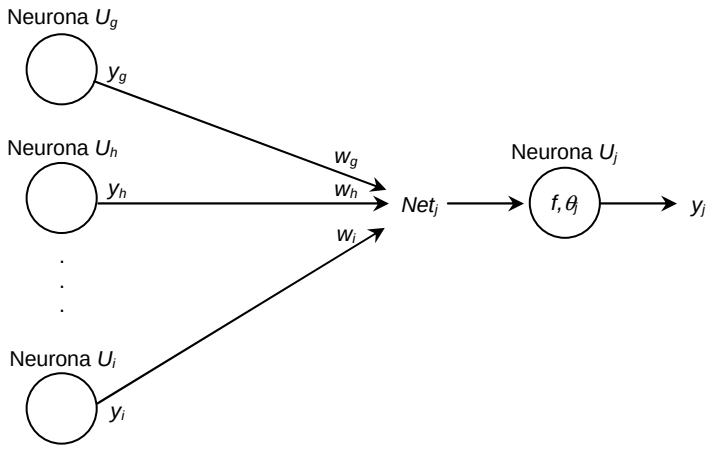


Figura II.67 - Entrada y salida de una neurona U_j, con función de activación identidad y con umbral de activación $\square_j$.

II.7.2. Características de una Red Neuronal Artificial

Para caracterizar completamente una red neuronal artificial, se deben conocer los siguientes aspectos de la misma: topología, el mecanismo de aprendizaje, el tipo de asociación realizada entre la información de entrada y la de salida, así como la forma de representación de estas informaciones.

II.7.2.1. Topología o arquitectura

La distribución de neuronas dentro de la red se realiza formando niveles o capas de un número determinado de neuronas cada una. Así, se llama *capa* al conjunto de neuronas cuyas entradas provienen de la misma fuente, que puede ser otra capa de neuronas, y cuyas salidas se dirigen al mismo destino, que también puede ser otra capa. Las capas suelen clasificarse en tres tipos:

- Capa de entrada: recoge señales desde el entorno y sus neuronas reciben, por tanto, las entradas a la red. Las señales pueden proceder de sensores o de otros sectores del sistema.
- Capa de salida: envía la señal fuera del sistema y las salidas de sus neuronas son, por tanto, las salidas de la red.
- Capas ocultas: son internas a la red y no tienen contacto directo con el entorno exterior. Las neuronas pueden estar interconectadas de distintas maneras, dando lugar a las distintas tipologías de redes neuronales.

Las conexiones entre las capas pueden ser de distinto tipo. Se habla de conexión autorrecurrente cuando la salida de un nodo es una entrada de sí mismo. Una conexión lateral es la realizada entre neuronas de la misma capa. Una red de propagación hacia delante es aquella en la que ninguna salida de las neuronas es entrada de neuronas del mismo nivel, o capa, ni de niveles precedentes. En caso contrario se estará ante una red de propagación hacia atrás. En la Figura II.68 se muestra un ejemplo de estructura de red neuronal de 4 capas: capa de entrada, 2 capas ocultas (A y B) y capa de salida, con todas las conexiones hacia delante.

Por tanto, para conocer cómo está organizada una red neuronal artificial, se deberán conocer los siguientes parámetros: número de niveles o capas, numero de neuronas por nivel, grado de conectividad y tipo de conexiones entre neuronas.

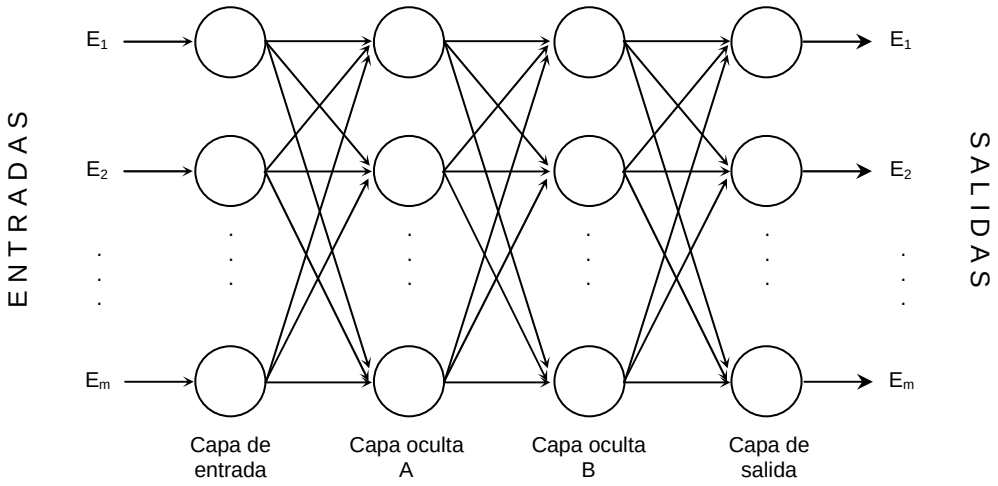


Figura II.68 - Estructura de una red multicapa de dos capas ocultas, con todas las conexiones hacia delante.

II.7.2.2. Mecanismo de aprendizaje

El mecanismo de aprendizaje es el proceso por el cual la red neuronal modifica sus pesos en respuesta a una información de entrada. Los cambios que se producen durante el aprendizaje pueden ser la creación, destrucción (peso nulo) y modificación de conexiones entre las neuronas.

Se distinguen redes neuronales con *aprendizaje supervisado* y *no supervisado*. La diferencia fundamental entre ambas reside en la existencia o no de un agente externo (supervisor) que controle el proceso de aprendizaje de la red. Este supervisor conoce la respuesta que debería dar la red a una entrada determinada, y los pesos se modifican para que la salida se aproxime lo mejor posible a esta respuesta.

Entre las redes de aprendizaje supervisado se distinguen los siguientes tipos de aprendizaje:

- Aprendizaje por corrección de error. Se calcula el error de la salida de la red a partir de la diferencia entre los valores esperados y los obtenidos. Seguidamente se modifican los pesos de conexión entre las neuronas para minimizar, normalmente, una determinada función de error global. Ejemplos de modelos de red de esta categoría son: *Perceptron*, *Adaline/Madaline*, *Backpropagation*, *Brain-state-in-a-box* o *Counterpropagation*.
- Aprendizaje por refuerzo. En este caso el supervisor actúa como juez, o crítico, y califica si la salida ha sido un éxito o un fracaso, reajustándose los pesos según un mecanismo de probabilidades. El aprendizaje es más lento que en los modelos por corrección de error, ya que durante el entrenamiento nunca se indica cuál debe ser la salida exacta que debería resultar en función de la entrada. Ejemplos de modelos de red en esta categoría son: *Linear reward penalty*, *Associative reward penalty* o *Adaptative heuristic critic*.
- Aprendizaje estocástico. En este tipo de redes se realizan modificaciones aleatorias de los pesos de las conexiones, examinando en cada una de ellas el grado de estabilidad de la red, al que también se suele denominar *energía de la red*, realizando un símil termodinámico. Se busca la mínima energía de la red, que tiene lugar cuando la salida se ajusta lo más posible a la deseada, por lo que se aceptan los cambios realizados sobre los pesos cuando se ha reducido la energía de la red, aceptándose tras un aumento en función de una distribución de probabilidades. Ejemplos de modelos de red de este tipo son: *Boltzmann machine*, *Cauchy machine*.

En las redes con aprendizaje no supervisado es la propia red la que debe encontrar regularidades, características, etc., en los datos de entrada. Un ejemplo podría ser la realización de un agrupamiento de los datos por categorías. Se suelen considerar dos tipos de aprendizaje:

- Aprendizaje hebbiano. Se basa en la correlación existente entre los valores de activación de dos neuronas conectadas entre sí. Las conexiones son reforzadas entre neuronas con valores positivos y son debilitadas entre neuronas con valor de diferente signo. Ejemplos de modelos de red de este tipo

son: *Hopfield*, *Learning matrix*, *Bidirectional associative memory (BAM)*, etc.

- Aprendizaje competitivo y cooperativo. En este caso las neuronas compiten por activarse en cada una de las capas, existiendo conexiones entre las neuronas de la misma capa, que serán de excitación si el aprendizaje es cooperativo y de inhibición si el aprendizaje es competitivo. Este tipo de red es capaz de realizar un clustering de los datos de entrada, creando de forma automática las clases a partir de las correlaciones de éstos, según la neurona de la capa de salida que permanezca activa. Ejemplos de modelos de red de este tipo son: *Learning vector quantizer*, *Cognitron/Neocognitron*, *Topology preserving map*, *Adaptative resonance theory (ART)*.

Otra diferenciación que se puede realizar es la relativa al momento en que se produce el aprendizaje de la red. Si la red va aprendiendo durante su funcionamiento habitual, se trata de una red *on line*. Si necesita ser desconectada para su aprendizaje, se trata de una red *off line*. Por tanto, en este último tipo de redes se habla de fase de aprendizaje, o entrenamiento, y fase de funcionamiento. En una red on line los pesos van cambiando sucesivamente al presentar nueva información al sistema, con posibles problemas de estabilidad, mientras en una red off line los pesos permanecen fijos tras la fase de entrenamiento y durante toda la fase de funcionamiento. Cada uno de los ejemplos de red citados será de uno de estos dos tipos.

II.7.2.3. Tipo de asociación realizada entre la información de entrada y la de salida

Existen dos formas fundamentales de relacionar las informaciones de entrada y salida:

- Heteroasociación. Da lugar a redes heteroasociativas, que aprenden a asociar parejas de conjuntos de datos. Es decir, la red aprende a presentar una salida determinada cuando se le presenta una entrada concreta. Necesitan al menos 2 capas, para poder mantener las informaciones de entrada y de salida.

- Autoasociación. Da lugar a redes autoasociativas, que almacenan varios tipos de salidas, de forma que ante una determinada entrada, por correlación buscan la más parecida a la de entrada. Pueden ser útiles para reconstruir información degradada, buscar relaciones entre conjuntos de información similares, etc. Pueden implementarse con una sola capa.

II.7.2.4. Forma de representación de las informaciones de entrada y de salida

La información reflejada en los datos de entrada y de salida puede ser de dos tipos, analógica o binaria, dando lugar a los siguientes tipos de redes.

- Analógicas. En este caso los datos vienen dados por números reales continuos, que suelen estar normalizados con valor absoluto menor a la unidad. Este tipo de representación necesariamente debe ir asociada a funciones de activación de las neuronas de carácter continuo, bien de tipo lineal o sigmoidal.
- Binarias. Los datos solo admiten dos valores, 0 y 1, con funciones de activación del tipo escalón.
- Híbridas. Los datos de entrada son de tipo analógico, mientras las salidas son de carácter binario.

II.7.3. La red Backpropagation

Esta modelo de red se ideó buscando un aprendizaje que fuera capaz de asociar un conjunto de patrones de entrada con una determinada clasificación de éstos. Se estructura en torno a una, o más, capas ocultas, en cuyas conexiones se almacena el conocimiento adquirido (véase la Tabla II.14 donde se presenta el resto de sus características). Los pesos se actualizan de forma proporcional a la denominada *regla delta generalizada*.

Tabla II.14 - Características de la red Backpropagation

Tipo de neuronas	Con función de transferencia diferenciable, usualmente de tipo sigmoidal
Topología	Multicapa (> 2 capas), propagación hacia delante
Aprendizaje	Off-line, supervisado, por corrección del error
Tipo de asociación	Heteroasociativa
Representación de la información	Analógica
Autores	Rumelhart, Hinton y Williams (1986)

II.7.3.1. Funcionamiento de la red Backpropagation

Su nombre, Backpropagation (BPN), propagación hacia atrás, o retropropagación, da idea de su funcionamiento, basado en una transmisión, desde atrás hacia delante, del error alcanzado en cada una de las neuronas de salida, que se puede resumir en los siguientes pasos:

a) Se presenta un patrón en la capa de entrada, que se transmite por la red a través de las capas ocultas hasta alcanzar la capa de salida. Los pesos de las conexiones se pueden generar de forma aleatoria.

b) Se comparan los valores obtenidos en las neuronas de salida con los valores que se deseaban y se calcula un error para cada una de las neuronas de salida.

c) Se transmite el error hacia atrás, para asignar un porcentaje de error de cada neurona de salida a cada neurona de la capa oculta. Se repite este proceso para todas las capas hasta llegar a la capa de entrada, de forma que cada neurona tendrá un porcentaje de participación en el error total.

d) Se reajustan los pesos de la red en función de su participación en el error total, de forma que la salida sea más parecida a la deseada la próxima vez que se presente el mismo patrón.

e) Se repite el proceso desde el paso (a) hasta que la función de error global alcanzada en la salida sea inferior a un umbral prefijado o bien se alcance el mínimo.

La regla delta generalizada utilizada en una red Backpropagation establece que la actualización de los pesos se realiza según la siguiente expresión:

$$\Delta w_{ij}(t+1) = \alpha \delta_{pj} y_{pi}$$

donde:

- Δw_{ji} es el cambio que se produce en el peso w_{ij} entre las neuronas U_i y U_j.
- α es la tasa de aprendizaje, que regula cuánto se modifican los pesos en cada iteración.
- δ_{pj} es el término del error que se produce en la neurona U_j, tras aplicar el patrón de aprendizaje p.
- y_{pi} es la salida de la neurona U_i, tras aplicar el patrón de aprendizaje p.

El valor del término del error δ_{pj}, es diferente según se trate de una neurona de salida u otro tipo de neurona. En el caso de una neurona de salida se tiene que:

$$\delta_{pj} = (d_{pj} - y_{pj}) \cdot f'(net_j)$$

siendo:

- d_{pj} la salida deseada de la neurona U_j para el patrón p.
- y_{pj} la salida real de la neurona U_j para el patrón p.
- net_j es la entrada neta que recibe la neurona U_j.
- f' es la derivada de la función de transferencia.

Si se tiene una neurona que no sea de salida, el término del error se obtendría de la siguiente manera:

$$\delta_{pj} = (\sum_k \delta_{pk} w_{jk}) \cdot f'(net_j)$$

donde k recorre todas las neuronas a las que está conectada la salida de la neurona U_j. Como se puede observar, el error de la neurona está en este caso en función de la suma de los productos de los errores de las neuronas a las que está conectada por el peso de estas conexiones.

Por tanto, el control del ritmo de aprendizaje de la red y la convergencia se realiza con el citado parámetro α o tasa de aprendizaje. A mayor tasa, mayor es la modificación realizada sobre los pesos en cada iteración, lo que permite un aprendizaje más rápido, pero también una mayor cantidad de oscilaciones que pueden impedir que se alcance el mínimo del error. Se recomienda emplear un valor pequeño para la tasa de aprendizaje α, entre 0,05 y 0,25, para facilitar que la red converja hacia una solución, aunque al mismo tiempo conlleve un mayor número de iteraciones.

Rumelhart, Hinton y Williams (1986) proponen una modificación a la regla delta, consistente en agregarle un momento que añade una fracción β del cambio de pesos en el instante *t* cuando se calcula el cambio de pesos en el instante *t+1*, lo que ayuda a mantener los cambios realizados sobre el peso en la misma dirección. Esta modificación permite la convergencia de la red en un menor número de iteraciones. De esta forma la modificación de los pesos finalmente seguirá la siguiente expresión, en la que se ha añadido el término β:

$$\Delta w_{ij}(t+1) = \alpha \delta_{pj} y_{pi} + \beta \Delta w_{ij}(t)$$

Existen una serie de recomendaciones generales en cuanto al empleo de la red Backpropagation. No pueden hacerse recomendaciones concretas, pues cada aplicación requiere un estudio específico:

- **Número de capas**. Suelen ser suficientes 3 capas: de entrada, oculta y de salida. No obstante, en ocasiones se acelera la convergencia con más de una capa oculta .
- **Número de neuronas**. El número de neuronas de entrada y de salida suelen venir dadas por la aplicación concreta de la red, residiendo el mayor problema a la hora de dimensionar las capas ocultas. La importancia de esta decisión es importante, porque del número de neuronas ocultas depende la capacidad de aprendizaje y de generalización de la red. En redes simuladas por software, suelen realizarse diferentes ensayos, escogiendo el que ofrece resultados aceptables con el menor número de neuronas ocultas. Respecto a la capacidad de aprendizaje, durante los ensayos se va reduciendo el nú-

mero de neuronas si la red va convergiendo sin problemas, aumentándolo en caso de que no converja. Respecto a la capacidad de generalización, una red poco compleja (menor número de neuronas ocultas) puede fallar a la hora de trabajar con un conjunto de datos complejo, mientras una red muy compleja (mayor número de neuronas ocultas) puede ajustar incluso hasta el ruido, memorizando el patrón, dando lugar a lo que se viene a llamar *sobreentrenamiento* de la red. También puede producirse sobreentrenamiento si el número de variables de entrada (neuronas de entrada) es muy elevado respecto al número de casos del patrón de entrenamiento. Evidentemente, cuanto mayor sea el número de casos del patrón de entrenamiento, más difícil es que se produzca un sobreeentrenamiento. Si se tiene un patrón muy pequeño, puede optarse por simplificar la red y por controlar el error que se produce en el patrón de validación, para finalizar el entrenamiento en cuanto comience a aumentar.

- **Umbrales de las neuronas**. Usualmente, el umbral que posee cada neurona y que se aplica sobre la función de transferencia, es considerado como un peso más, correspondiente a la conexión con una neurona ficticia de la capa precedente, cuya salida siempre vale la unidad. Por tanto, en el proceso de aprendizaje el umbral es considerado como un peso más.
- **Inicialización de la red**. Lógicamente, lo más adecuado sería inicializar la red con pesos que den lugar a un error en la red que de entrada sea reducido y próximo a la solución buscada. No obstante, esto es imposible, dado que no se tiene conocimiento a priori sobre la solución final. La solución que se suele adoptar es la de la generación de pesos aleatorios de pequeño valor. En ocasiones, en una red que no converge se soluciona el problema simplemente inicializando la red con valores diferentes.

Las aplicaciones de las redes en general, y en concreto de la red Backpropagation, son de carácter muy diverso, ya que este modelo de red se adapta a la resolución de multitud de problemas. Entre las aplicaciones más empleadas se pueden citar la codificación de la información, la compresión/descompresión de datos, el filtrado de información, la clasificación de datos, el reconocimiento de patrones, etc.

Capítulo III
Material y Metodología

III.1. INTRODUCCIÓN

Como se ha comentado en el capítulo de antecedentes, existe común acuerdo en la comunidad científica acerca de la necesidad de disponer de una metodología adecuada para la segmentación y el enriquecimiento de los elementos lineales para potenciar y mejorar su posterior generalización.

Por ejemplo, en la Figura III.1 se muestra un elemento lineal correspondiente a una pista de montaña de la hoja 947-III del MTN25 (Instituto Geográfico Nacional, 1996b) que asciende desde una zona de campiña hasta un pico montañoso. Este elemento puede ser clasificado como un elemento complejo, de geometría no homogénea, ya que se observa que la sinuosidad no es constante a lo largo de toda su longitud. En este caso la geometría de la línea está muy condicionada por la topografía del terreno: las zonas más suaves se corresponden con tramos con menos pendiente, más paralelos a las curvas de nivel, mientras los tramos más sinuosos son los que salvan mayores desniveles, observándose el clásico zigzagueo propio de las carreteras de montaña.

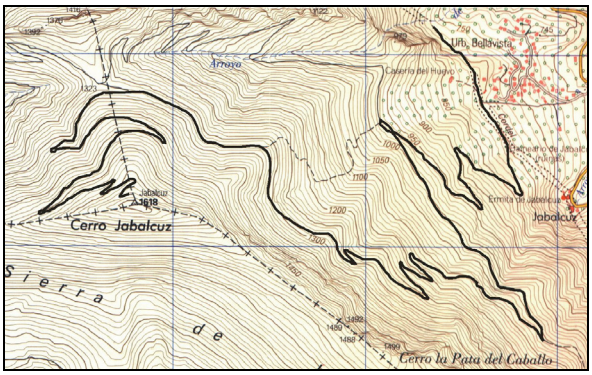


Figura III.1 - Pista de montaña en la hoja 947-III del MTN25 (Instituto Geográfico Nacional, 1996b).

Una segmentación de la línea de la Figura III.1 en secciones más homogéneas, realizada manualmente a partir de un análisis visual, podría ser la que se presenta en la Figura III.2, en la que se han establecido cinco secciones. Cada sección debería ser enriquecida y clasificada para permitir una elección de los operadores, algoritmos y parámetros a aplicar más adecuados, elección que, por supuesto, también vendrá condicionada por la escala, uso y usuario finales del producto derivado del proceso de generalización.

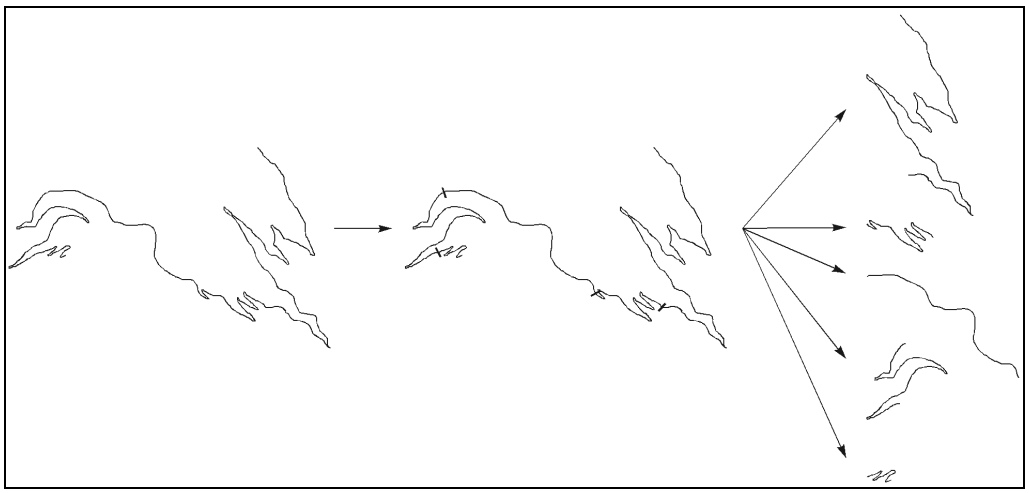


Figura III.2 - Ejemplo de segmentación manual de la línea de la Figura III.1. en cinco secciones.

Esta segmentación previa a la generalización, si bien no era realizada explícitamente por los cartógrafos cuando acometían la generalización manual de un elemento lineal, sí era realizada de forma implícita en la medida en que alteraban la forma en que aplicaban la generalización en función de los cambios que experimentaba la geometría del elemento, supuesto éste con suficiente longitud. Como se puede pensar, esta segmentación es totalmente subjetiva, supeditada sobre todo a la experiencia y conocimientos cartográficos y geográficos del cartógrafo, y totalmente carente de repetitividad.

Hoy en día, momento en que las tareas de generalización se realizan mediante programas informáticos, que trabajan de forma autónoma o supervisada, la falta

de técnicas automatizadas de segmentación y clasificación de elementos lineales lastran la mejora de los métodos que pretenden una generalización totalmente automatizada de un mapa o base de datos. Por tanto, esa falta puede ser considerada un objetivo prioritario, que dará razón de ser a este trabajo.

Así, en tanto que los procesos y algoritmos se adecuan mejor a unas determinadas tipologías de elementos lineales, la búsqueda de una óptima metodología de segmentación y clasificación sería una primera meta a alcanzar, que daría lugar a una segunda en la que habría que indagar sobre qué algoritmos y parámetros se acomodan mejor a cada tipo de línea, escala final, uso y usuario. Por tanto, podemos fijar dos objetivos en la segmentación y enriquecimiento de elementos lineales:

- Hallar un método automático que sea capaz de dividir la línea en varias secciones intrínsecamente homogéneas. En palabras de Skopeliti y Tsoulos (1999, p. 59), se trata de un prerequisito para la posterior clasificación, que debe diferenciar las partes con diferente grado de complejidad.
- Automatizar la clasificación de cada sección a partir de determinadas medidas (las que en el capítulo II se han denominado "medidas caracterizadoras") para facilitar la ulterior toma de decisiones en cuanto a la elección de técnicas de generalización y sus correspondientes parámetros.

El resto del presente capítulo será dividido en cuatro grandes apartados:

- III.2. Muestra de elementos lineales. Este primer apartado estará dedicado a la selección razonada de la muestra que permitirá realizar diferentes pruebas, experimentos y tanteos, que deberá dar solidez a los posibles resultados y conclusiones.
- III.3. Segmentación mediante algoritmos. Partiendo de la exposición de antecedentes en segmentación del capítulo II, se expondrán las técnicas de segmentación propuestas para su experimentación y basadas en algoritmos.
- III.4. Clasificación automática de secciones. Se expondrá la metodología para clasificar automáticamente las secciones detectadas mediante el uso de una

red neuronal artificial, para lo cual se necesita una muestra de secciones y un conjunto de medidas que enriquezcan la información de cada una de ellas.

- III.5. Segmentación mediante la red neuronal. Se plantea un método para la utilización de la red neuronal, creada para clasificar secciones, en la operación de segmentación
- III.6. Evaluación visual de los resultados. Se expone la metodología para someter los resultados a evaluación visual, distinguiendo la evaluación realizada por el doctorando durante el desarrollo de los trabajos, de aquella evaluación final realizada por expertos en la disciplina.

En la Figura III.3 se presenta el método de trabajo seguido, adelantando de forma resumida las operaciones que se explicarán en apartados posteriores. Como se puede observar, partiendo de los tres recuadros de la izquierda, se persigue formalizar tres líneas de flujo que siguen el siguiente proceso: análisis de parámetros que controlan la segmentación, segmentación automática, enriquecimiento de las secciones y clasificación automática por la red neuronal. Cada línea de flujo se corresponde con una técnica de segmentación a ensayar, esto es: segmentación mediante red neuronal artificial (segmentación 1, apartado III.5), segmentación mediante áreas efectivas (segmentación 2, detallada en el apartado III.3.1) y segmentación mediante wavelets (segmentación 3, detallada en el apartado III.3.3).

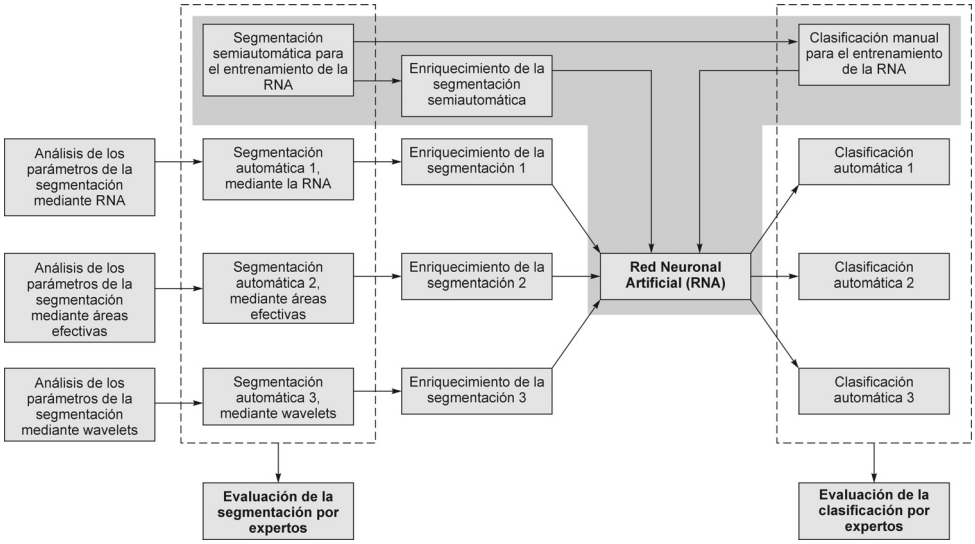


Figura III.3 - Esquema general del método de trabajo seguido.

Siguiendo con la Figura III.3, se puede observar que la clasificación de cualquier sección de una línea será realizada por una red neuronal artificial. Todo lo relativo al proceso de creación de esta red se explica en el apartado III.4. Como toda red neuronal, la empleada en este trabajo necesita unas entradas, definidas por el enriquecimiento de las secciones (apartado III.4.3.1) y proporciona una salida, que es la propia clasificación (apartado III.4.3.3). En la figura se ha resaltado la parte del proceso dedicada a entrenar la red neuronal para que aprenda a efectuar la clasificación, y que se sustenta en una segmentación semiautomática (apartado III.4.1.1) y en la posterior clasificación manual de estas secciones (apartado III.4.1.2). En la Figura III.19 se esquematiza con mayor detalle el proceso seguido hasta la definición de la red neuronal definitiva.

Como se puede observar en los recuadros de línea discontinua de la Figura III.3, tanto las tres alternativas de segmentación como sus respectivas clasificaciones automáticas, además de la segmentación semiautomática y la clasificación manual con las que se ha entrenado la red neuronal, serán sometidas a una evaluación externa por parte de un panel de expertos (apartado III.6.2).

III.2. MUESTRA DE ELEMENTOS LINEALES

III.2.1. Selección de la fuente

Como se ha referido en los objetivos de este trabajo, se pretende el desarrollo de técnicas de segmentación y clasificación previas a la generalización de la serie del MTN25 del IGN para derivar escalas menores.

La elección de esta cartografía no es arbitraria, siendo varias las razones que han inducido hacia ella:

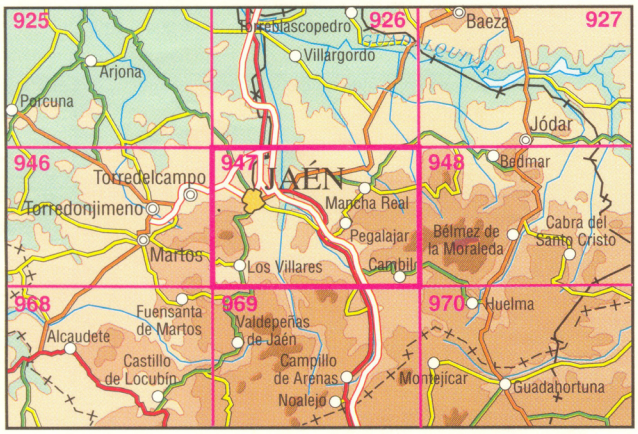
- No es una cartografía derivada de una escala mayor por procesos de generalización, sino que sus datos proceden directamente de observaciones topográficas, geodésicas y fotogramétricas. Esto constituye un punto fundamental para evitar los sesgos que se podrían introducir con cualquier proceso de generalización.
- Es la serie cartográfica de mayor escala que da cobertura a todo el territorio español[1]. En el futuro podría constituir la base de datos de partida para la derivación de todas las series cartográficas a escalas menores y de cobertura nacional. La nueva edición del MTN50 se está realizando por derivación del MTN25 mediante tareas de generalización, lo que evidencia la utilidad de los procesos de generalización sobre esta serie para derivar cartografías a escalas inferiores.
- La existencia de hojas a escala 1:50 000 derivadas por generalización permite contrastar los resultados que se obtengan de este estudio con una producción cartográfica real puesta a la venta en el mercado.

Una vez fijada la serie del MTN25 como fuente de los datos a emplear, se decidió extraer la muestra de elementos lineales de los cuatro cuartos que integrasen

[1] "El Mapa Topográfico Nacional a escala 1:25 000 constituye la serie básica de la Cartografía Oficial de España, ofreciendo una representación detallada y precisa del territorio en sus aspectos morfológicos, en los derivados de la presencia del hombre y sus acciones y en los del medio natural. Consta de 4123 hojas de 10' latitud x 15' longitud lo que corresponde, de forma más o menos aproximada según la zona, a unas 12 500 ha. Además, como consecuencia de su proceso productivo, completamente informatizado, constituye una base digital vectorial homogénea y continua de todo el territorio nacional útil para múltiples propósitos" (http://www.fomento.es/).

una hoja del MTN50, ya que el flujo de generalización es realizado por el IGN precisamente según esa razón de cuatro a uno. La hoja seleccionada fue la 947 (Jaén) (ver Figura III.4), y por tanto sus cuatro cuartos de la serie MTN25: 947-I (Jaén), 947-II (Mancha Real), 947-III (Los Villares) y 947-IV (Cambil) (Instituto Geográfico Nacional 1996a, 1996b, 1996c y 1997). La elección de la hoja 947 se justifica por:

- La proximidad geográfica de sus elementos lineales al centro de trabajo, que facilita las comprobaciones en campo, en caso de presentarse conflictos, y las consultas a la delegación provincial del IGN.
- La variabilidad geomorfológica del territorio representado: campiña con lomas suaves al norte, terreno montañoso al sur (ver Figura III.5). Esto permite introducir variabilidad en la sinuosidad y complejidad de las líneas de la muestra, ya que el relieve está correlacionado con la geometría de las vías de comunicación (Plazanet, 1996, p. 56).
- La existencia de vías de comunicación en todas las categorías administrativas, con diversa titularidad (Estado, Junta de Andalucía y Diputación Provincial), y además con presencia de vías tanto de alta capacidad (autovías) como convencionales (resto de vías).



PORCUNA 925	MENGÍBAR 926	BAEZA 927
MARTOS 946	JAÉN 947	TORRES 948
ALCAUDETE 968	VALDEPEÑAS DE JAÉN 969	HUELMA 970

Figura III.4 - Situación de la hoja 947 en la serie MTN50.

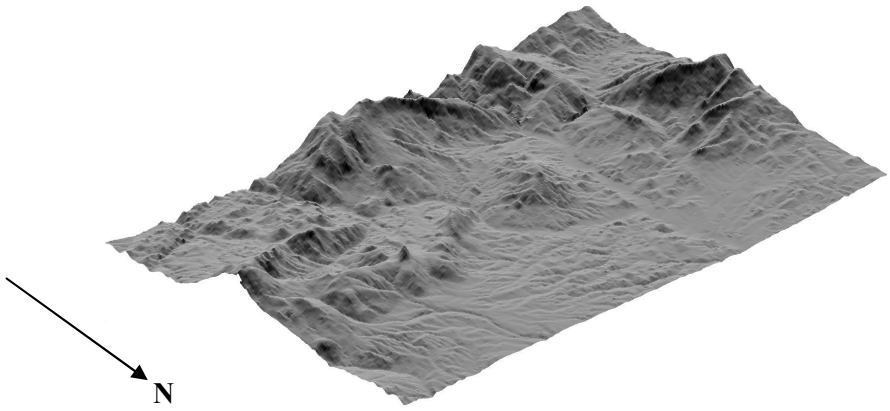


Figura III.5 - Representación de un modelo digital de elevaciones de la hoja 947.

III.2.2. Selección de la muestra

La selección de la muestra de elementos lineales de las hojas 947 debe realizarse cuidadosamente para que el estudio sea lo más fructuoso posible. Así, se siguieron los siguientes criterios (resumidos en la Tabla III.1):

- Los elementos lineales deben ser de captura inequívoca y fáciles de confrontar en el terreno. Las vías de comunicación son objetos que cumplen estas premisas y su captura es relativamente sencilla (p.e., mediante una observación GPS cinemática). Por el contrario, las curvas de nivel son entelequias que no tiene representación real sobre el terreno, al igual que ocurre con los límites administrativos, y además se tiende a efectuar su generalización filtrando el modelo digital de elevaciones que permite interpolarlas, en lugar de filtrarlas como un elemento lineal propiamente dicho. Las líneas que representan la red hidrográfica también presentan ciertos problemas, ya que su captura es dificultosa (problemas de ocultación tras la vegetación en la restitución fotogramétrica, modificación relativamente rápida de los cursos de agua, problemas para establecer el eje del curso, etc.), y su generalización también viene muy marcada por la del modelo digital de elevaciones. Es por todo esto por lo que se decide formar la muestra a partir de las vías de comunicación. Además, en todo mapa (topográfico, de carreteras, turístico, etc.) éstas muestran un gran interés, dado su intenso uso por parte de toda la población; la capacidad comunicativa de un mapa respecto a su red de carreteras es esencial, por lo que las tareas de generalización a realizar sobre ellas han de procurar el mantenimiento de esta capacidad..
- Las líneas seleccionadas deben pertenecer al mayor número de categorías posible (categorías administrativas, directrices de diseño, etc.) para que el estudio sea más general y cercano al caso real de ejecución sobre toda la población de líneas de una hoja cualquiera de la serie del MTN25. Esto permitirá, además, diferenciar comportamientos y características en función del tipo de línea.
- Por razones análogas a las del punto anterior, dentro de cada categoría debe existir, en la medida de lo posible, variabilidad en el trazado. Esto es más fácil de lograr en categorías relativas a carreteras locales y en el caso de pistas y caminos, ya que es más fácil encontrar variaciones de sinuosidad y complejidad, debido al menor número de restricciones impuestas en su diseño planimétrico y altimétrico.
- La longitud de los elementos seleccionados debe superar cierto umbral. Esto viene motivado, por un lado, por razones metodológicas, ya que una línea de

escasa longitud presenta menos ocasiones de segmentación y generalización. Por otro lado, las líneas de menor longitud (normalmente pertenecientes a la población de pistas o caminos) son las primeras en ser sometidas al operador *eliminación* al disminuir la escala de representación. No es común encontrar información acerca de la longitud de los elementos de la muestra en trabajos de investigación en generalización, por lo que no es posible presentar un estudio de antecedentes al respecto. En el presente trabajo, se desecharán de la muestra los elementos lineales de escasa longitud, estableciéndose el umbral de 5000 metros.

- El tamaño de la muestra no ha de condicionar y restringir los resultados del trabajo, por lo que deberá ser lo suficientemente amplia. En la Tabla III.2 se resume información referente a los tamaños muestrales de investigaciones previas realizadas sobre generalización de elementos lineales. Como se puede apreciar, existe gran variabilidad en el tamaño muestral de los distintos trabajos, y ninguno de ellos alude a ningún criterio estadístico. El número mínimo suele ser el de cuatro elementos (Jasinski, 1990; Barber et.al, 1995; Zhan y Buttenfield, 1996; Dutton, 1999) si bien también hay numerosos trabajos que escogen un amplio conjunto de elementos de un ámbito geográfico determinado, sin concretar su cantidad (Visvalingam y Williamson, 1996; Plazanet, 1996; Lecordix et.al, 1997; Plazanet et.al, 1998; Wang y Müller, 1998; Veregin, 1999; Li y Sui, 2000). Esta última opción parece más acertada, en primer lugar, porque el aumento del tamaño muestral robustece la validez de los resultados, si bien también supone un mayor esfuerzo, pero además porque se acerca más al caso real de las operaciones a realizar sobre los elementos de un producto cartográfico (como pueden ser, p.e., los elementos del MTN50 en el ámbito de la hoja 947).

Tabla III.1 - Resumen de criterios de selección de la muestra.

Tipo de elementos lineales	captura inequívoca, fáciles de confrontar
Categorías	mayor número posible
Sinuosidad	mayor variabilidad posible
Longitud mínima	5000 metros
Tamaño de la muestra	Amplia: la población de un ámbito geográfico

A la vista de los criterios expuestos y de las categorías de vías de comunicación establecidas en el MTN25 (ver Figura III.6), en este trabajo se optará por incluir en la muestra todas las vías de comunicación asfaltadas y pistas de las hojas 947 del MTN25 que superen una longitud de 5000 metros. Los caminos no se incluyen por su menor interés, dado que son de reducida longitud y su generalización se puede reducir a un mero operador de eliminación. En la Tabla III.3 se resume la muestra de vías escogida y en la Figura III.7 se representa su trazado en la hoja 947.

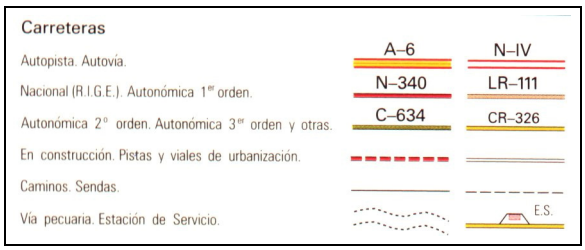


Figura III.6 - Leyenda sobre carreteras en las hojas 947 del MTN25.

Tabla III.2 - Tamaños de muestra empleados en investigación sobre generalización de elementos lineales (orden cronológico).

Referencia	Muestra	Tema de investigación
McMaster (1986)	12 curvas de nivel, 10 cursos de agua y 9 líneas de costa, a escala 1:25 000 ó 1:62 500.	Análisis estadístico de medidas evaluadoras en la simplificación de líneas
Jasinski (1990)	1 línea de costa de una isla y 1 sección de carretera, a escala 1:50 000. 1 sección de río y 1 sección de autopista, a escala 1:62 500	Comparación de medidas de complejidad
Barber, Cromely y Andrle (1995)	2 líneas de costa, 1 río y 1 curva de nivel, a escala 1:24 000	Comparación de los algoritmos de Douglas-Peucker jerárquico y no jerárquico
Visvalingam y Williamson(1995)	Conjunto de carreteras de una hoja de 500 x 500 m a escala 1:1 250	Comparación entre los algoritmos de Douglas-Peucker y Visvalingam
Plazanet (1996)	Conjunto de líneas de carretera de una base de datos a escala 1:50 000 (no concreta número)	Segmentación y clasificación
Zhan y Buttenfield (1996)	2 líneas de costa y 2 ríos	Método de generalización multi-escalar
Lecordix, Plazanet y Lagrange (1997)	Conjunto de líneas de carretera de una base de datos a escala 1:50 000 (no conreta número)	Plataforma para la investigación sobre operaciones de caricaturización
García (1998)	6 vías de comunicación, a escala 1:25 000	Algoritmos de eliminación de puntos y de filtrado de curvatura
Plazanet, Bigolin y Ruas (1998)	Conjunto de líneas de carretera de una base de datos a escala 1:100 000 (no concreta número)	Enriquecimiento y clasificación de elementos lineales
Reinoso (1998)	6 vías de comunicación, a escala 1:25 000	Algoritmos de eliminación de puntos y de filtrado de curvatura
Wang y Müller (1998)	Varias muestras: (a) todas las líneas de un mapa de tipos de suelo; (b) todos los límites de un mapa político de Estados Unidos; (c) 2 líneas de costa y 1 orilla de un lago	Generalización basada en el análisis de formas
Christensen (1999)	1 sección de línea de costa e islas adyacentes, a escala 1:100 000; 1 sección de costa y ríos que desembocan, a escala 1:100 000; líneas de costa e islas de un grán área de Grecia y el Mar Egeo, a escala 1:1 000 000	Método de generalización de líneas de costa, fundamentado en la transformación de eje medio
Dutton (1999)	2 líneas de costa de dos islas a dos escalas: 1:80 000 y 1:250 000.	Método de generalización, basado en una red de triánguos cuaternarios
Skopelliti y Tsoulos (1999)	1 línea de costa para segmentación, 56 secciones de costa para clasificación, a escala 1:500 000	Segmentación y clasificación
Veregin (1999)	Conjunto de líneas de carretera y cursos de agua de 30 octetos elegidos al azar, a escala 1:100 000	Estudio del error introducido en la simplificación de líneas
Christensen (2000)	1 línea de costa a escala 1:24 000 de una isla muy compleja	Método de generalización de líneas de costa, fundamentado en la transformación de eje medio
Li y Sui (2000)	2 mapas de curvas de nivel a escala 1:10 000	Método de generalización de curvas de nivel

Tabla III.3 - Muestra de los 24 elementos lineales empleados en el presente trabajo.

Red de Carreteras	Subred1	Subred2	Tipo de vía	Cantidad	Nomenclatura de las vías
Red de Carreteras del Estado	-	-	autovía	1	*A-44*[2]
	-	-	convencional	1	*N-323*
Red de Carreteras de Andalucía[3]	Red Autonómica	Red Básica	autovía	1	*A-316A*[4]
			convencional	1	*A-316*
		Red Intercomarcal	convencional	3	*A-311*, *A-320*, *A-324*
		Red Complementaria	convencional	1	*A-1102*
	Red Provincial	Red Comarcal	convencional	9	*JV-2222*, *JV-2223*, *JV-2224*, *JV-2225*, *JV-2226*, *JV-3012*, *JV-3241*, *JV-3242*, *JP-2332*
Otras[5]	-	-	pista	7	*P-CaminoAncho, P-CaminoAzadillas, P-CerroAlmadén, P-CerroJabalcuz, P-CerroSantín, P-Pegalajar-Central, P-SierraPeñaDelÁguila*

Nota: Los nombres de las pistas se han establecido de forma arbitraria comenzando por la letra "P", seguida por un guión ("-"), y continuando con un nombre propio. Éste se ha fijado, de estar presente, a partir del topónimo que figura en el mapa para la pista, y en su defecto, se ha establecido a partir de los topónimos rotulados en su entorno o de los lugares de inicio y fin de la pista.

[2] "A-44" es la nomenclatura actualizada de la autovía anteriormente denominada "N-323", según el Real Decreto 1231/03, de 26 de septiembre, por el que se modifica la nomenclatura y el catalogo de las autopistas y autovías de la Red de Carreteras del Estado.

[3] La clasificación de la red de carreteras indicada en la leyenda del MTN25 no es la vigente respecto a las vías de titularidad autonómica. En la Comunidad Autónoma de Andalucía, la clasificación está especificada en el artículo 2 de la Ley 8/2001, de 12 de julio, de Carreteras de Andalucía, (BOJA 85/2001, de 26 de julio de 2001), modificada por la Ley 2/03, de 12 de mayo, de Ordenación de los Transportes Urbanos y Metropolitanos de Viajeros en Andalucía: "La red de carreteras de Andalucía está formada por las siguientes categorías: a) La red autonómica, que comprende la red básica, la red intercomarcal y la red complementaria. b) La red provincial, compuesta por la red comarcal y la red local." Según el artículo 5 de la misma ley, la titularidad del dominio público viario de las primeras corresponde a la Comunidad Autónoma de Andalucía, y la de las segundas a las Diputaciones Provinciales en sus respectivos ámbitos territoriales.

[4] Aunque el nombre real de la autovía es "A-316", en este trabajo es referido como "A-316A" para distinguirlo del tramo de carretera convencional del mismo nombre.

[5] Dentro de esta categoría se incluirán todos los demás elementos lineales que en el mapa figuran como "pistas" y que pueden pertenecer a diferentes organismos, como ayuntamientos, la Consejería de Medio Ambiente, etc.

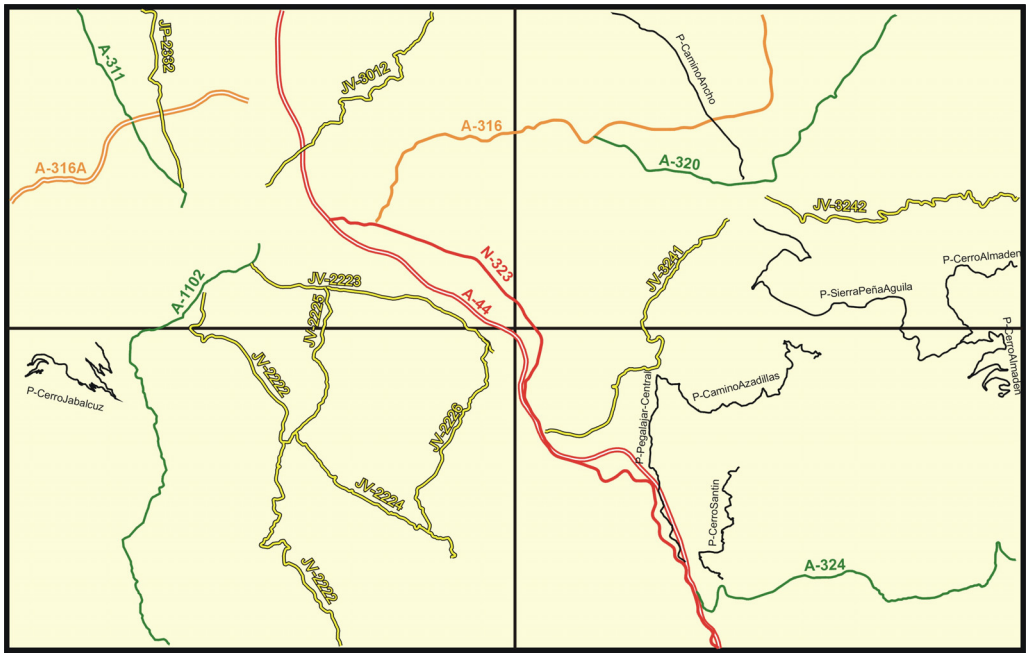


Figura III.7 - Representación de la muestra de líneas seleccionada en las hojas 947 del MTN25 (no está a escala).

III.2.2.1. Normativas de diseño de las vías de comunicación

No debe pensarse que las diferentes categorías señaladas en la Tabla III.3 pueden corresponderse directamente con diferentes tipologías en cuanto al trazado geométrico del elemento lineal; por ejemplo, distintas categorías administrativas pueden compartir criterios de diseño de la vía, y la homogeneidad en la topografía de una zona puede dar lugar al aumento de homogeneidad del trazado de las vías que discurren por ella.

Así pues, queda claro que la variabilidad en las categorías administrativas de una muestra no implica variabilidad en la geometría, si bien ambas no son completamente independientes por la existencia de una legislación que regula los criterios de diseño. También puede darse el caso de que una vía proceda de leves reformas y mejoras de un antiguo camino de herradura, con lo que su trazado no tiene por qué adecuarse exactamente a criterios legales, primando la adaptación a la topografía del terreno.

Por tanto, es interesante conocer la normativa aplicada, si es el caso, en el diseño de cada elemento lineal de la muestra, pues puede aportar conocimiento a

priori sobre su comportamiento geométrico. En el Anexo F se resumen las sucesivas normativas aprobadas, tanto estatales como autonómicas.

La medida en que las vías de la muestra constan de un trazado diseñado bajo las diferentes normativas puede comprobarse en el documento relativo a la memoria de los diferentes proyectos de actuación. En dicho documento siempre ha de existir un anejo dedicado al diseño del trazado, tanto planimétrico como altimétrico, en el que se especifican sus parámetros principales.

Para acceder a esta información se decidió contactar y mantener una entrevista con los responsables del área de carreteras de las diferentes administraciones a las que les corresponde la titularidad de las vías de comunicación, obteniendo las siguientes conclusiones:

- Los criterios de diseño de las diferentes vías de los organismos competentes no están incluidos en ningún inventario ni catálogo, ni siquiera la categoría a la que pertenece cada una de ellas, o cada uno de sus tramos, según la norma 3.1-IC (Dirección General de Carreteras, 2000) o el Plan General de Carreteras de Andalucía (PGCA).
- No se tiene catalogado el grado de cumplimiento del trazado real de las vías respecto al trazado teórico que plantea la normativa.
- Por los dos motivos anteriores, para obtener información sobre los parámetros principales del trazado es necesario buscar y leer los documentos del proyecto de diseño de cada una de ellas. Esto es problemático para los proyectos más antiguos, que pueden no estar disponibles en la actualidad.
- Las autovías de la Red de Carreteras del Estado, dependientes del Ministerio de Fomento (o equivalente, según la legislatura), han sido creadas, como es el caso de la autovía A-44, siguiendo la normativa estatal. Las carreteras convencionales han sido reformadas parcialmente por tramos, atendiendo a la normativa estatal. No obstante, existen casos de vías, como el de la antigua N-323, que únicamente han sido sometidas a reparaciones y refuerzos del firme, por lo que su diseño es antiguo y no responde a la normativa estatal.

- Las carreteras de la Red Autonómica, dependientes de la Consejería de Obras Públicas y Transportes de la Junta de Andalucía, han sido reformadas parcialmente, por tramos, desde la transferencia de las competencias sobre carreteras, atendiendo a las normativas estatal y autonómica.
- Las carreteras de la Red Provincial, dependientes de la Diputación Provincial de Jaén, únicamente suelen ser sometidas a reparaciones y a refuerzos del firme, por lo que su diseño es muy antiguo y no atiende a ninguna normativa estatal. Este hecho queda corroborado mediante la comparación visual de las carreteras de esta red en las hojas 947 del MTN50 en sus ediciones de 1971 y 1999 (Instituto Geográfico y Catastral, 1971; Instituto Geográfico Nacional 1999). En ambas hojas el trazado planimétrico de las líneas es prácticamente el mismo.

En la Tabla III.4 se resumen los criterios de diseño que se han encontrado en los documentos de memoria de diferentes proyectos de actuación sobre algunas de las líneas de la muestra, indicando: nombre de la vía, fecha de la actuación, nombre de la actuación, clave, organismo, así como las principales especificaciones del trazado planimétrico. Como se puede observar, en acorde con lo ya comentado, se trata de vías de comunicación pertenecientes a la Red de Carreteras del Estado y a la Red Autonómica de la Red de Carreteras de Andalucía, cuyas actuaciones se han ejecutado en los últimos veinte años.

Tabla III.4 - Proyectos de construcción o reforma del trazado de las vías de la muestra.

Vía	Fecha	**Actuación** (nombre, clave, organismo)	**Especificaciones del trazado**
A-44	08/1993	Proyecto de construcción "Autovía Bailén - Granada. N-323 de Bailén a Motril. Tramo: Jaén (norte) - Enlace de La Guardia." Documento nº1 - Memoria y Anejos. Tomo 1. Clave: 12-J-2650. Ministerio de Obras Públicas y Transportes. Dirección General de Carreteras.	• Velocidad del proyecto: 120 km/h • Grupo AV-120 del borrador de 1990 de la Norma 3.1-IC (borrador de la Norma del 2000) • Radio mín: 800 m.
A-316A	10/1988	"Duplicación de calzada Jaén - Torredonjimeno". Tomo I.- Memoria y Anejos. Clave: JA-1-J-133. Consejería de Obras Públicas y Transportes. Dirección General de Carreteras. Junta de Andalucía.	• Velocidad del proyecto: 100 km/h • Grupo 64 de la Norma 3.1-IC (1964) • Radio mín: 450 m. • Radio máx: 1000 m. • Radio mín (excepcional): 250 m.

Tabla III.4 - Proyectos de construcción o reforma del trazado de las vías de la muestra.

Vía	Fecha	**Actuación** (nombre, clave, organismo)	**Especificaciones del trazado**
	09/1991	Proyecto de construcción "Carretera de conexión entre la CN-323 y la CN-321, variante noroeste de Jaén". Memoria (I). Clave: I-J-191. Consejería de Obras Públicas y Transportes. Dirección General de Carreteras. Junta de Andalucía.	• Norma 3-1-IC (1964). • Grupo B-12 del PGCA. • Velocidad específica: 100 km/h. • Radio mín: 450 m. • Radio máx: 2000 m. • Sin tramos rectos. • Con clotoides de transición. • Clotoide mín en planta: 150 m.
A-316	09/1985	"Acondicionamiento de la CN-321 de Úbeda a Málaga por Jaén. Tramo Baeza - Jaén. P.K. 33,780 al P.K. 42,160". Memoria y Anejos. Clave: I-J-108.2. Consejería de Política Territorial. Dirección General de Obras Públicas. Servicio de Carreteras. Junta de Andalucía.	• Radio mín: 180 m. • Radio máx: 1000 m. • Con clotoides de transición
A-316	07/1988	"Acondicionamineto de la CN-321 de Úbeda a Málaga por Jaén. Tramo: Mancha Real a la intersección con la CN-323. P.K. 42,1 al P.K. 50,4". Memoria. Clave: JA-1-J-136. Consejería de Obras Públicas y Transportes. Dirección General de Carreteras. Junta de Andalucía.	• Grupo B-12 del PGCA. • Radio mín zonas accidentadas:250m. • Con clotoides de transición
A-1102	03/1988	"Acondicionamiento de la C.C. 3221 de Jaén a Alcalá La Real. Tramo Jaén - Los Villares. P.K. 10,650 AL 12,200". Memoria. Clave: 3-J-179. Consejería de Obras Públicas y Transportes. Dirección General de Carreteras. Junta de Andalucía.	• 2 curvas, de radios 145 y 200 m • Con clotoides de transición
	03/1990	"Proyecto de construcción. Variante Sur de Jaén". Tomo I - Memoria y Anejos. Clave: 5-J-177. Junta de Andalucía. Ayuntamiento de Jaén.	• Variante sur. - Zona de tipo urbano. - Radio mín: 100 m. - Sin clotoides. • Carretera Jaén - Los Villares - Radio mín: 120 m. - Con clotoides. - Hay 2 curvas de radio 1000 m sin clotoides (no caben).
A-324	04/1989	"Acondicionamiento de la N-324. Tramo intersección N-323 a Cambil". Memoria. Clave: JA-2-J-151(277). Consejería de Obras Públicas y Transportes. Dirección General de Carreteras. Junta de Andalucía.	• Velocidad específica: 50 km/h • Grupo I-33 del PGCA. • Radio mín: 60 m. • Radio máx: 600 m. • Radio mín (excepcional): 40 m. • Con clotoides de transición
	06/1989	Acondicionamiento de la carretera N-324 de Cambil a Huelma". Tomo I: Memoria y Anejos. Clave: JA-2-J-163. Consejería de Obras Públicas y Transportes. Dirección General de Carreteras. Junta de Andalucía.	• Grupo I-33 del PGCA. • Radio mín: 75 m. • Radio máx: 1500 m.

Tabla III.4 - Proyectos de construcción o reforma del trazado de las vías de la muestra.

Vía	Fecha	**Actuación** (nombre, clave, organismo)	Especificaciones del trazado
A-320	06/1988	"Acondicionamiento de la C.C. 328 de Mancha Real a Cazorla. P.K. 0,000 al 21,500. Tramo Mancha Real - Jimena". Memoria. Clave: JA-2-J-138. Consejería de Obras Públicas y Transportes. Dirección General de Carreteras. Junta de Andalucía.	• Grupo I-32 del PGCA. • Radio mín: 120 m. • Curva de transición mín: 40 m. • Con clotoides de transición

En la Tabla III.5 se presentan, para su confrontación, los principales datos del trazado en planta de las vías de comunicación de la Tabla III.4. Se trata de reformas efectuadas sobre vías de comunicación entre los años 1985 y 1993. En general se suele tener en cuenta alguna normativa (la Norma 3.1-IC o la del PGCA), si bien esto no sucede cuando se trata de reformas de poca extensión o bien casos particulares que afectan a zonas urbanas. La velocidad específica oscila entre los 50 km/h de las carreteras autonómicas de la categoría I-33 del PGCA y los 120 km/h de la autovía A-44, los radios mínimos entre los 60 m de la A-324 (por debajo de lo que especifica el PGCA, que sería 75 m para la categoría I-33). Los radios máximos no siempre se especifican (tampoco en las normas de diseño), pero los datos que se concretan varían entre 600 y 2000 m.

Lamentablemente sólo se dispone de información acerca de 6 vías de la muestra, lo que no permite un análisis más exhaustivo acerca de la variabilidad en la definición de los trazados, ni tampoco acerca de la sinuosidad esperada en cada una.

Tabla III.5 - Resumen de características del trazado de las vías de la muestra

Vía	Año	Norma	Velocidad [km/h]	Rad. mín [m]	Rad. máx [m]	Observaciones
A-44	1993	Borrador Norma 3.1-IC de 1990 (AV-120)	120	800	-	-
A-316A	1988	Norma 3.1-IC de 1964 (grupo 64)	100	450	1000	-
A-316A	1991	Norma 3.1-IC de 1964 PGCA (B-12)	100	450	2000	-
A-316	1985	-	-	180	1000	-
A-316	1988	PGCA (B-12)	100	250	-	-
A-1102	1988	-	-	145	200	Reforma de zona sinuosa
A-1102	1990	-	50	100	1000	Incluye zona urbana
A-324	1989	PGCA (I-33)	50	60	600	-
A-324	1989	PGCA (I-33)	50	75	1500	-
A-320	1988	PGCA (I-32)	60	120	-	-

III.2.3. Tratamiento previo

Las hojas del MTN25 digital se encuentran almacenadas vectorialmente en ficheros *dgn*, formato vectorial de Bentley Systems, Inc. Las líneas de la muestra se encuentran en diferentes capas temáticas en forma de polilíneas en coordenadas UTM y es necesario someterlas a un proceso de depuración que consistirá en los siguientes pasos sucesivos:

- Unión de los fragmentos de polilínea de un mismo elemento lineal en cada hoja.
- Unión de los fragmentos de polilínea de un mismo elemento lineal presente en más de una hoja.
- Filtrado de cada elemento lineal mediante un algoritmo sencillo, como es el de la distancia de McMaster (McMaster, 1987), con parámetro de 0,1 m para evitar problemas de picos, lazos y vueltas atrás, producidos durante el proceso de digitalización por causas psicológicas y fisiológicas.
- Filtrado mediante el algoritmo de Douglas-Peucker con parámetro nulo para eliminar puntos que estén alineados.

El resultado tras la depuración se almacenará en una base de datos de Microsoft Access para su posterior tratamiento y análisis mediante software de diseño propio. Aparte del conjunto de pares de coordenadas de cada elemento lineal, en el fichero se incorporarán campos de información complementaria de cada elemento lineal, como son su nombre, número de vértices, longitud, categoría administrativa, o una descripción de la ruta que sigue la línea, todo ello en beneficio de facilitar el manejo del conjunto de datos.

En una base de datos con topología un elemento lineal estaría formado por sucesivos arcos entre pares de nodos, y éstos se corresponderían con cruces de carreteras. Sin embargo, en el ámbito de este trabajo, el fragmentar una línea en sus arcos constituyentes podría impedir la captación de la variabilidad de la línea en cuanto a su complejidad y sinuosidad. Plazanet (1996, p. 54) plantea una jerarquización de los nodos para evitar problemas de esta índole. En este trabajo consideraremos como elemento lineal a aquella estructura lineal compleja de tra-

zado continuo en la hoja 947, que administrativamente está considerada como una vía de comunicación independiente. Si una vía apareciera formada por varios tramos no conectados entre sí, cada uno de ellos sería considerado un elemento lineal.

III.3. SEGMENTACIÓN MEDIANTE ALGORITMOS

No son abundantes los trabajos dedicados expresamente a las tareas de segmentación de elementos lineales. Entre las metodologías ya ensayadas, se encuentran la propuesta de los puntos de inflexión de Plazanet (Plazanet 1995, 1996, 1997; Plazanet et.al, 1995, 1998) y de la dimensión fractal de Skopeliti y Tsoulos (1999).

En este trabajo se propondrán y programarán nuevas metodologías que luego serán sometidas a análisis. Como punto de partida para su concepción, se dispone de la revisión de antecedentes del capítulo II, donde se ha entrevisto la potencial utilidad que presentan ciertas técnicas o algoritmos, para su empleo dentro del flujo del proceso de segmentación. Desde esa perspectiva se ha señalado al algoritmo de Visvalingam (Visvalingam y Whyhatt, 1993; Visvalingam y Williamson, 1995; Reinoso et.al, 2001; Visvalingam y Herbert, 1999), el algoritmo de Thapa (Thapa, 1989; García et.al, 2001) o el filtrado wavelet (Plazanet et.al, 1995; Fritsch, 1997; García y Ariza, 2000b).

Así, se presentarán en sucesivos subapartados varias propuestas metodológicas de segmentación, entreviendo su potencialidad a priori. Con posterioridad sus resultados serán analizados en el capítulo IV, comprobando su capacidad para diferenciar secciones que sean intrínsecamente homogéneas.

El marco de trabajo vendrá acotado por la escala de la muestra de líneas seleccionada, procedente del MTN25, y por la intención de pretender la mejora de la generalización desde esta serie cartográfica a otras de escala inferior, como el MTN50. Este aspecto condicionará la automatización pretendida de la segmentación y las conclusiones a obtener, frente a estudios que trabajen sobre la seg-

mentación de muestras procedentes de cartografías de escala muy diferente, como la 1:100 000. No obstante es importante volver a resaltar la importancia de concentrar los esfuerzos en una escala como la 1:25 000, cuya serie cartográfica de cobertura nacional en España, el MTN25, es de carácter básico y pretende convertirse en base de datos de partida para la derivación de series a escala menor por medio de la generalización.

III.3.1. Método de las áreas efectivas

La propuesta pretende verificar la potencialidad exhibida por el algoritmo de Visvalingam (Visvalingam y Whyhatt, 1993), ya que se cree útil su capacidad de filtrar progresivamente desde los detalles más locales hasta los más globales, conforme se aumenta el parámetro que lo gobierna. De forma muy simplificada, el proceso puede definirse como la aplicación del filtrado de Douglas-Peucker sobre un espacio de áreas efectivas de Visvalingam-Whyhatt calculadas para cada vértice de un elemento lineal.

Así, el concepto base de todo el proceso es el de área efectiva *A*, definida como el área del triángulo de cada punto de la línea respecto a sus dos vecinos, y que viene a significar el desplazamiento que sufrirá la línea en el caso de eliminar ese punto. Cuando se aplica el algoritmo sobre una línea, se van realizando sucesivas pasadas, en cada una de las cuales se eliminará el punto con menor área efectiva.

Así, las hipótesis de partida son:

- Que la heterogeneidad en la sinuosidad de un elemento lineal se traducirán en heterogeneidad en el área efectiva de los puntos que lo integran, permitiendo distinguir diferentes secciones.
- Que el algoritmo de Douglas-Peucker podrá detectar adecuadamente los cambios de sección en un espacio de áreas efectivas.

Dado que se pretende emplear el área efectiva para detectar zonas de diferente sinuosidad, el primer paso ha de ser aplicar el algoritmo de Visvalingam sobre el

elemento lineal, para tener un valor de área efectiva por cada punto de la línea. Por ejemplo, la gráfica de la Figura III.8 presenta la distribución de áreas efectivas a lo largo de la longitud de la línea A-316. A la vista de la misma, se puede comprobar cómo la mayor parte del área efectiva total de la línea (3147 Ha) se concentra en un reducido grupo de puntos, que serían los únicos puntos que permanecerían tras un fuerte filtrado con este algoritmo. Si no se efectúa ninguna operación más, esta gráfica es insuficiente para poder establecer una segmentación en función de la sinuosidad.

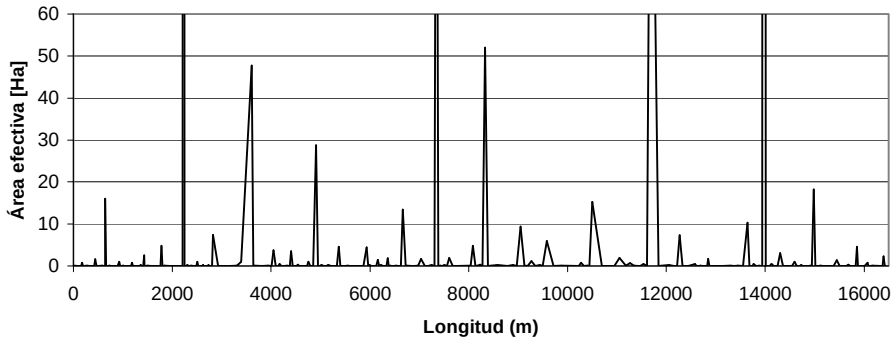


Figura III.8 - Distribución de áreas efectivas en la línea A-316.

No obstante, sobre el diagrama de áreas efectivas se pueden plantear diferentes alternativas para detectar la posible existencia de secciones con diferente comportamiento. Se propone una metodología de integración de los valores de área efectiva mediante una suma acumulada, que de forma resumida respondería a los siguientes pasos consecutivos (véase también Ariza et.al (2005)):

- Aplicar el algoritmo de Visvalingam-Whyhatt para determinar el área efectiva A_i de cada punto *i* que pertenece a un elemento lineal.
- Obtención de la función $F(d_i, A_i)$, y representación en un espacio de desplazamientos (eje X que se corresponde con el desplazamiento sobre el propio elemento lineal) y área efectiva (eje Y que se corresponde con el valor A_i determinado para cada vértice *i* del elemento lineal).
- Cambio a escala logarítmica del eje Y (áreas efectivas): $F(d_i, LogA_i)$.

- Para cada punto *i*, suma de las áreas efectivas en secciones de longitud fija *L*: $F(d_i, SLogA_i)$.
- Suavizado de la función suma mediante filtro gausiano de parámetro σ, $G(F(d_i, SLogA_i); \sigma)$.
- Aplicación del algoritmo de Douglas-Peucker, de parámetro *DP*, sobre $G(F(d_i, SLogA_i); \sigma)$ para la extracción de los puntos que limitan la serie de secciones.

Los primeros pasos tienen como misión la de crear un espacio de áreas efectivas sobre el cual, en el último paso, se aplica Douglas-Peucker, que es el que se encarga de detectar las secciones en dicho espacio. En los siguientes dos subapartados se describen los referidos pasos del proceso.

III.3.1.1. Preparación del espacio de áreas efectivas

Dado que se pretende asociar variaciones en la sinuosidad con variaciones en el área efectiva, parece lógico acumular los valores de ésta por cada *L* metros de longitud de la línea original. No obstante, esta suma no es factible realizarla sobre los valores del área efectiva, ya que siempre en escasos puntos se concentran los mayores valores. Para paliar este problema, se realizará un cambio de escala para disminuir la influencia de esos puntos. Se empleará una escala logarítmica, obteniendo una gráfica como la de la Figura III.9.

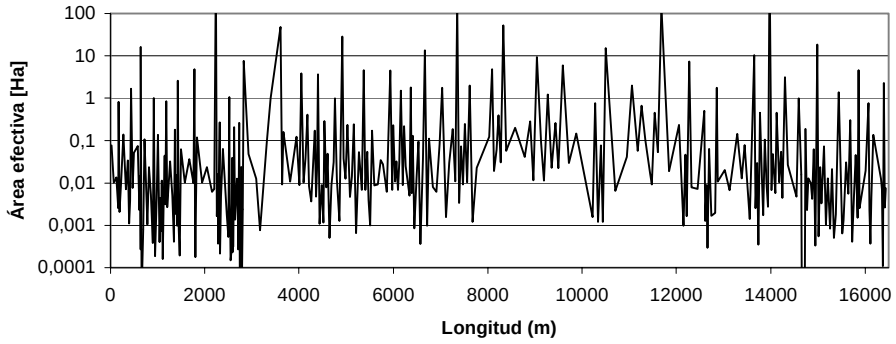


Figura III.9 - Distribución de áreas efectivas en la línea A-316 (escala logarítmica).

Una vez se tiene la gráfica de la Figura III.9, se está en disposición de aplicar una suma acumulada de las áreas efectivas. Así, para cada punto *i* se sumarán los logaritmos de las áreas efectivas A_j de los puntos que le preceden y que se encuentren a menos de *L* metros de él:

$$SLog(A_i) = \sum_j Log_{10}(A_j) \qquad \forall j \,/\, j < i \,;\, dis(i,j) < L$$

La representación gráfica, para el presente ejemplo, es la que se muestra en la Figura III.10. El comportamiento de esta función (en adelante "función suma") advierte de la distribución de las áreas efectivas a lo largo de la línea. Por ejemplo:

- Una zona con tendencia horizontal se asocia a una sección donde la sinuosidad es estable, ya que se mantiene constante la suma de los exponentes de los logaritmos de las áreas efectivas de los últimos *L* metros.
- Una zona con tendencia creciente representa un aumento progresivo de la sinuosidad.
- Una zona con tendencia decreciente representa una disminución progresiva de la sinuosidad.

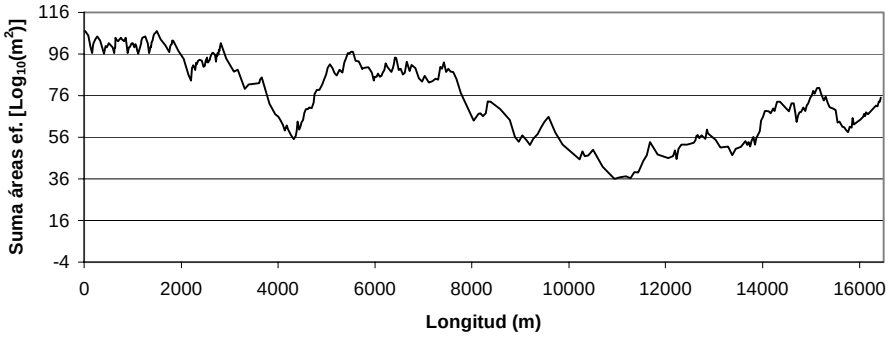


Figura III.10 - Suma del Log10 de las áreas efectivas en la línea A-316 con *L* = 1500 m.

Además, como paso previo a la aplicación de Douglas-Peucker, se ha creído adecuado introducir un suavizado sobre la función suma, por ejemplo mediante un

filtrado gausiano con parámetro σ, con el objetivo de realzar la tendencia principal de dicha función.

III.3.1.2. Detección de secciones mediante Douglas-Peucker

El último paso del proceso es la extracción de secciones homogéneas. La idea es detectar los puntos críticos que supongan un cambio en la tendencia de la función suma y, por tanto, un cambio de comportamiento de la sinuosidad y un cambio de sección. Para ello se ha propuesto el empleo algoritmo de Douglas-Peucker (Douglas y Peucker, 1973), por estar ampliamente contrastado, y por su rapidez de ejecución. Es decir, este algoritmo se aplicará sobre la función suma, de la misma forma en que es aplicado sobre un elemento cartográfico lineal. El ajuste de su parámetro *DP* permitirá detectar más o menos puntos críticos. Un ejemplo de la aplicación de este procedimiento sobre la Figura III.10 se presenta en la Figura III.11, y la consecuente segmentación. Para un mejor comportamiento del algoritmo la escala vertical de la función $F(d_i, SLogA_i)$ será multiplicada por 10.

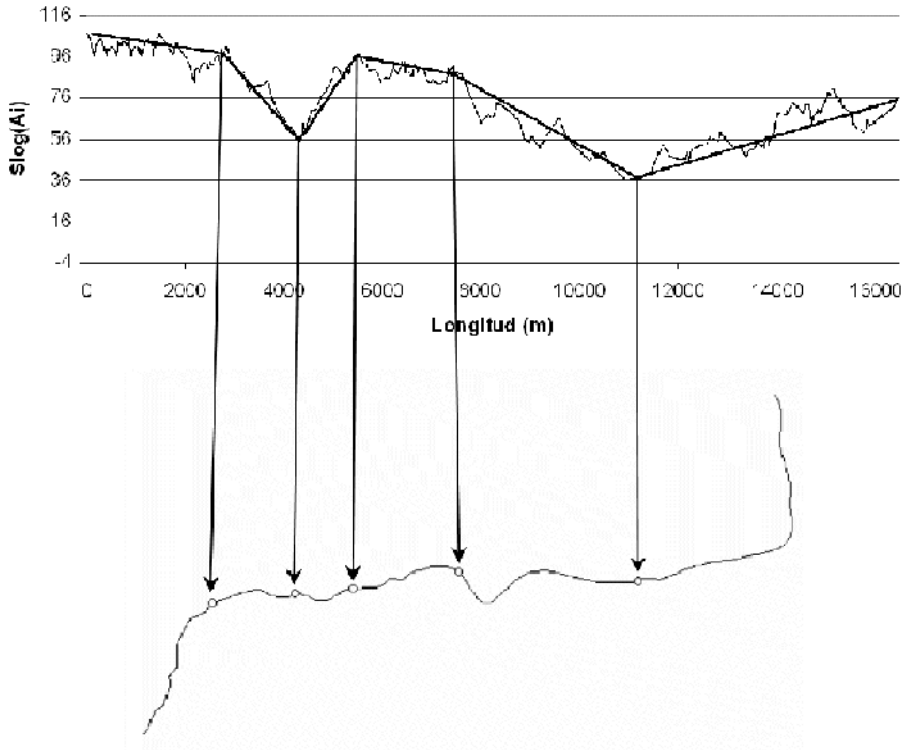


Figura III.11 - Arriba: ejemplo de detección de puntos críticos con Douglas-Peucker. Abajo: segmentación de la línea A-316 a partir de los puntos críticos.

Por otro lado, es importante comentar que es posible que se produzcan interferencias entre la longitud *L* y la longitud curvilínea de una sección detectada. Así, por ejemplo, supóngase un conjunto de áreas efectivas más o menos constante al que sigue otro conjunto con valores aproximadamente nulos (ver la "línea original" en la Figura III.12). La función suma permanecería sensiblemente constante hasta el punto frontera entre un conjunto y otro, a partir del cual vendría una zona con pendiente negativa, y aproximadamente al cabo de una longitud *L*, se estabilizaría en un valor nulo). Douglas-Peucker (ver "*DP* sobre la función suma" en la figura) podría detectar como puntos críticos ambos donde ha cambiado la pendiente de la función suma ("a" y "b" en la figura), cuando se sabe que el segundo punto es una mera interferencia de la longitud *L*. En la aplicación desarrollada para el procedimiento de segmentación propuesto se han habilitado mecanismos para evitar este tipo de situaciones.

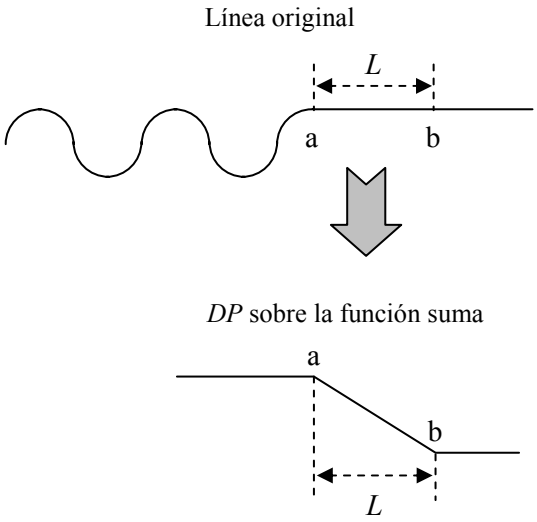


Figura III.12 - Ejemplo de interferencia de la longitud L en la detección de puntos críticos con Douglas-Peucker.

III.3.2. Método de Thapa Bidireccional Recursivo

Se pretende experimentar la segmentación mediante el algoritmo de filtrado de Thapa, dada la sensibilidad que ha mostrado a los cambios de sinuosidad. Se recurrirá a su versión modificada en García et.al (2001), el denominado Thapa Bidireccional Recursivo (en adelante, TBR). El algoritmo de Thapa tradicional no es independiente del sentido de lectura de la línea, al no tratarse de un algoritmo de tipo global, según la clasificación de McMaster y Shea (1992), y además muestra mayores problemas de comportamiento inercial, y por ello no se considera adecuado para trabajos de segmentación.

En el filtrado mediante TBR de la línea de costa de la Península Ibérica mostrado en la Figura II.23 se puede comprobar cómo existe una fuerte tendencia a la conservación de puntos en tramos sinuosos y a su eliminación en tramos más suaves. La hipótesis que manejamos es que ésta técnica va a permitir distinguir las zonas más sinuosas de las más suaves y por tanto es factible su uso para la segmentación de la línea.

En la Figura III.13 se muestra un ejemplo de filtrado de la línea *N-323b* mediante TBR. Se puede apreciar como la línea filtrada ha sufrido una simplificación ex-

cesiva en algunos tramos que han quedado reducidos a un simple segmento formado por dos puntos. Este filtrado podría ser adecuado para separar la línea en las tres secciones principales que se pueden entrever: de arriba abajo, la primera sección quedaría constituida por la parte más suave de la línea, después vendría una sección sometida a distintos cambios de dirección, formando un gran arco, y por último una sección con sucesivas curvas de signo alternativo que siguen una misma dirección principal.



Figura III.13 - Filtrado de la línea *N-323b* mediante TBR con parámetro 0,94.

Se pueden plantear diferentes alternativas para automatizar la búsqueda de secciones en la línea filtrada por TBR:

- De forma análoga al método planteado por Plazanet, tras una detección de puntos de inflexión de la línea filtrada (por TBR, frente al gausiano de Plazanet), se puede obtener la distancia media *M* entre los PI consecutivos, y para cada PI, considerar las distancias hasta el PI anterior, *d1*, y hasta el posterior, *d2*. Si (*d1*<*M y d2*>*M*) ó (*d1*>*M y d2*<*M*), entonces existe un punto crítico que distinguirá dos secciones diferentes. En la Figura III.14 se presenta el resultado de la segmentación de *N-323b* según este método, con un resultado prometedor.
- También podría esperarse un resultado positivo empleando la distancia media entre los puntos consecutivos de la línea filtrada y luego efectuar una búsqueda equivalente a la planteada para los PI.

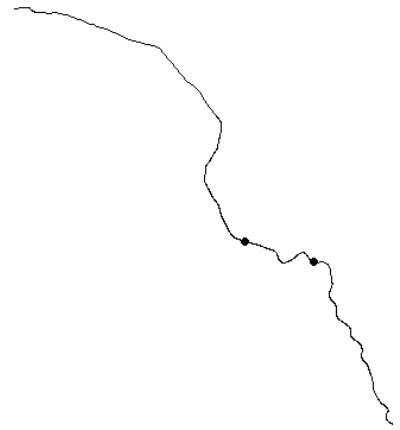


Figura III.14 - Segmentación de *N-323b* mediante TBR con parámetro 0,94.

Sin embargo a todo lo dicho, la experimentación con las distintas líneas de la muestra ha llevado a descartar esta metodología de segmentación, que no será sometida a ningún análisis posterior. El comportamiento de la segmentación frente a la modificación del parámetro de control del algoritmo de thapa se ha advertido del todo caótico, impidiendo una relación clara entre la modificación del parámetro y la detección de más o menos secciones.

III.3.3. Método del filtrado wavelet de la curvatura

En el apartado de antecedentes se ha señalado el empleo de coeficientes wavelet sobre la curvatura como una técnica con latente capacidad para su empleo en segmentación de elementos lineales (véase Plazanet et.al, 1995 o García y Ariza, 1999, 2000b).

La aplicación de un filtrado o generalización de los coeficientes wavelet, permitiría retener los coeficientes de baja frecuencia, eliminando los de alta, y por tanto aislar los comportamientos más estables de la línea en cuanto a su curvatura.

Así, nuestra hipótesis de partida es que el filtrado wavelet, aplicado sobre la curvatura de un elemento lineal, va a permitir la detección de secciones de sinuosidad más o menos estable, en función del grado de filtrado aplicado. La distribu-

ción simplificada de la curvatura estará constituida por una sucesión de valores constantes de curvatura, extendiéndose cada uno de ellos a lo largo de cierta longitud.

Obsérvese la Figura III.15. En ella se ha dispuesto la gráfica original de valores de (longitud,curvatura) de la línea *Jabalcuz* y la gráfica con los valores resultantes tras el filtrado wavelet con un 45% de pérdida de información (*K*), en la que se contempla la sucesión de valores constantes de curvatura (en adelante, "tramos de curvatura"). Se observan desde tramos de curvatura de longitud prácticamente nula hasta tramos con longitud de varios kilómetros. Es obvia la mayor facilidad que ofrece la gráfica simplificada a la hora de detectar distintos comportamientos de la curvatura a lo largo de la línea. Así, se ha marcado en esta gráfica una posible segmentación manual mediante líneas verticales discontinuas. El siguiente paso a dar sería automatizar esta detección de las secciones.

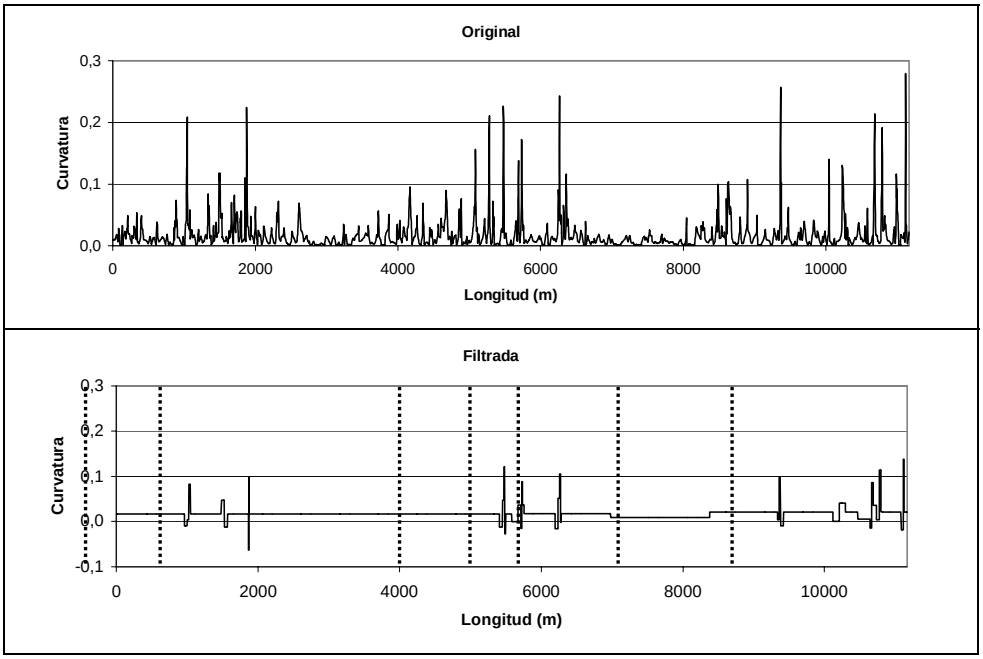


Figura III.15 - Gráficas de (longitud,curvatura) original y filtrada de la línea *Jabalcuz*. *K* = 45.

Una alternativa para automatizar la extracción de secciones puede ser una simple selección de los tramos de curvatura más largos y considerar que el inicio y fin de cada uno de ellos marca sendos puntos críticos de cambio de una sección

homogénea a otra. En la Figura III.16 se muestra la segmentación de *Jabalcuz* realizada mediante una selección de los tramos de curvatura mayores a 500 m (*L*) de la gráfica filtrada de la Figura III.15, que se corresponde prácticamente con la segmentación manual sugerida para esta gráfica.

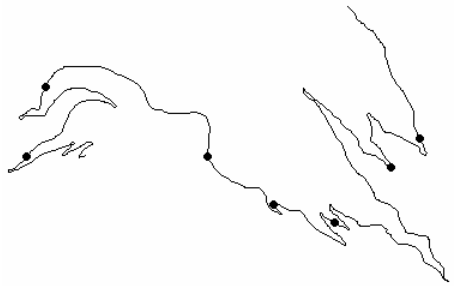


Figura III.16 - Segmentación automática mediante wavelet de la línea *Jabalcuz*. *K* = 45. *L* = 500.

En el capítulo de antecedentes, en el apartado II.5.4.3 dedicado a los filtrados en el dominio de la frecuencia ya se ha comentado cómo se puede aplicar un filtrado wavelet paso a paso. Así, la metodología propuesta en este apartado debería comenzar por el filtrado wavelet propiamente dicho (los señalados a continuación como pasos *a* y *b*) seguidos de los pasos dedicados a la detección de secciones de curvatura homogénea (véase también García y Ariza (2005)):

a) Paso de la representación en coordenadas *x*,*y* a una representación *longitud*,*curvatura*, mediante el cálculo, en cada punto, de la longitud curvilínea acumulada y de la curvatura (véase la Figura II.39). Aplicación de un remuestreo para permitir que el número de valores sea de la forma 2^n.

b) Cálculo de los coeficientes wavelet, eliminación de los coeficientes más pequeños, a partir un parámetro de porcentaje pérdida de información *K*, y reconstrucción de los valores de *longitud*,*curvatura* (véase la Figura II.40). Se empleará la wavelet de Haar (p.e. ver Stollnitz, 1996), ya empleada con éxito por Plazanet et.al (1995) o García y Ariza (2000).

c) Detección de las secciones, extrayendo los puntos críticos a partir del inicio y fin de los tramos de curvatura constante que superan un umbral *L* de longitud preestablecido.

d) Refinado de la segmentación, garantizando que la distancia entre puntos críticos sea superior a *L*.

Según la metodología que acaba de ser expuesta, los parámetros que gobernarán la segmentación serán dos: el porcentaje de pérdida de información del filtrado wavelet, *K*, y el umbral de longitud *L*.

El parámetro *K* permitirá ajustar la sensibilidad o rigurosidad de la detección de la secciones homogéneas. Cuanto menor sea *K*, más regular deberá ser la curvatura de la sección para que pueda ser considerada como tal. Por ejemplo, un valor reducido de *K* será más sensible y riguroso a los cambios de curvatura, sólo permitirá detectar las secciones de la línea más suaves y distinguirá como diferentes dos secciones aunque su suavidad sea parecida (véase ejemplo en la Figura III.17).

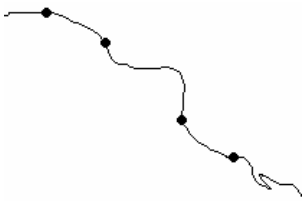


Figura III.17 - Detalle de la segmentación de *Jabalcuz* con *K* = 10%, *L* = 250.

El parámetro *L* se encargará de extraer los tramos de curvatura constante que van a ser considerados como sección homogénea. Por tanto, ejerce de filtro de los tramos de curvatura constante, considerando sólo los que tienen mayor entidad, esto es, con longitud mayor a *L*.

III.4. CLASIFICACIÓN AUTOMÁTICA DE SECCIONES

Mediante los métodos de segmentación se tiene la división de una línea en varias secciones más homogéneas que la línea original. Sin embargo, es necesario clasificar cada una de ellas. Así, tras la segmentación deberían estar disponibles una

o varias etiquetas asociadas a cada sección, tal que se facilite una toma de decisiones posterior en cuánto a la elección de operadores, técnicas y parámetros de generalización más adecuados.

Por tanto, no puede asumirse que la segmentación efectuada, por cualquiera de las metodologías propuestas, sea definitiva. Las secciones detectadas pueden ser consideradas como secciones "preliminares", ya que con posterioridad podrían fusionarse aquellas secciones consecutivas que hayan sido clasificadas en la misma categoría. De esta forma, una caracterización de las secciones permite el "refinado" de la segmentación. Las reglas que regulan la fusión de secciones pueden fundamentarse en la propia clasificación de las secciones, su longitud, etc., y deben ser más o menos permisivas, en función de la escala final a obtener tras la generalización, ya que la segmentación debe ser menos detallada en el proceso de derivación de escalas que sean menores a otras (p.e., una 1:200 000 frente a una 1:50 000).

Este trabajo verificará la potencialidad de una metodología de clasificación automática de un conjunto dado de secciones, a través de una herramienta de aprendizaje supervisado: una red neuronal, que deberá emular una clasificación de experto realizada por el ser humano. La metodología que se expondrá a continuación también puede seguirse en García et.al (2005).

III.4.1. Muestra de secciones para la experimentación

Los diversos trabajos a realizar para entrenar la red neuronal exigen disponer de una segmentación de la muestra de líneas disponible de las hojas 947 del MTN25, que deberá dar lugar a un conjunto amplio de secciones homogéneas, que además deberán estar clasificadas en diferentes categorías.

III.4.1.1. Segmentación

Para preparar la muestra de secciones a clasificar se puede optar por tres estrategias diferentes para realizar la segmentación:

- Segmentación manual. En este caso un experto debe disponer de los trazados de la muestra, preferentemente sobre papel, para realizar una segmentación a partir del análisis visual. Las ventajas son las propias que se derivan del procesamiento holístico y del conocimiento experto del que es capaz la mente humana. De hecho, recordando las palabras de Plazanet (1997), ésta señala que la segmentación de elementos lineales está relacionada con la percepción visual humana. Los inconvenientes son los comunes en cuanto es el ser humano el que realiza un procesamiento de información: falta de repetitividad, subjetividad, análisis cualitativo frente a cuantitativo, etc.
- Segmentación automática. Sería una opción en la que se emplearía alguna de las metodologías de segmentación mediante algoritmos, como las expuestas en este trabajo. Las ventajas e inconvenientes son los contrarios al procesamiento manual. Las ventajas son: repetitividad, objetividad, análisis cuantitativo, etc. Y los inconvenientes: el procesamiento secuencial de información, ausencia de una formalización del conocimiento cartográfico, etc.
- Segmentación semiautomática. Es entendida como aquella realizada mediante algún algoritmo que es controlado por el experto de forma que las secciones establecidas sean lo más homogéneas posible. Es decir, un experto cartógrafo emplea el sistema digital como si de un conjunto de herramientas se tratase. Esta opción permite aunar las ventajas de las otras dos opciones.

Se ha optado por la opción de la segmentación semiautomática para tratar de garantizar una muestra adecuada para el fin que se persigue. Se empleará la técnica de segmentación mediante áreas efectivas. Su aplicación se hará de forma guiada, modificando los parámetros del algoritmo de segmentación e inspeccionando visualmente las secciones, eligiendo una solución en la que se aprecie verdadera diferencia en las características del trazado planimétrico. No obstante, no se plantea ningún problema si se consideran secciones que sean consecutivas y de características geométricas semejantes, pues el objetivo es disponer de un conjunto de muestras amplio, que internamente sean homogéneas, y que permitan él análisis que posteriormente se efectuará sobre ellas. El fundamento de este análisis visual se explica en el apartado III.6.1.1.

III.4.1.2. Clasificación

La clasificación del conjunto de secciones es esencial, dado que formará parte del patrón del que dispondrá la red neuronal para aprender a asociar un determinado conjunto de valores de medidas caracterizadoras con una determinada clase. Del grado en que esta clasificación esté coherentemente realizada dependerá gran parte del éxito que exhibirá la red neuronal en sus tareas de clasificación.

Método de clasificación

Toda clasificación de un conjunto de secciones se realiza a partir de cierto conocimiento derivado de las mismas. Básicamente, se puede distinguir una clasificación realizada de forma manual por un experto (clasificación de experto), o de forma automática por un determinado algoritmo por ordenador (clasificación automática). Dado que el objetivo de este trabajo es precisamente la búsqueda de una metodología de clasificación que emule el comportamiento humano, parece poco adecuado optar por una clasificación automática, como la que se podría realizar mediante un análisis cluster. Es la elección más lógica la de la clasificación de experto, para que luego sea la red neuronal la que se encargue de buscar la relación entre los valores de distintas medidas cuantitativas y la clasificación realizada, formalizando el conocimiento cartográfico del experto. Esta clasificación de experto se fundamentará en el análisis visual, tal y como se comenta en el apartado III.6.1.1.

La tarea de definición de clases y de clasificación de secciones puede realizarse tanto en pantalla como sobre papel, a distintos niveles de ampliación, así como a partir de los mapas originales, en formato papel, de las cuatro hojas del MTN25.

Número de clases

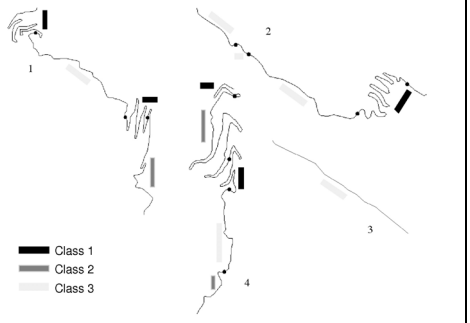
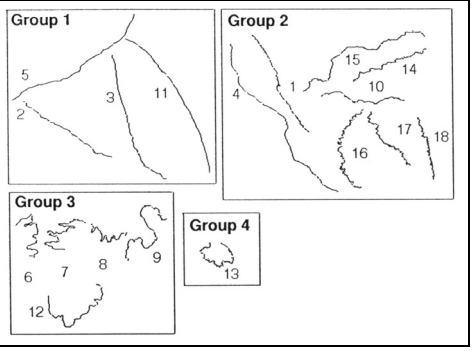
Un planteamiento ambicioso puede pretender establecer un buen número de clases diferentes. El problema es que puede ser difícil asignar una sección a una de ellas, dados los trazados tan diferentes que se pueden presentar. Asignaciones que se efectúen de forma arbitraria contaminarán enseguida la capacidad de ge-

neralización de la red neuronal en su aplicación sobre casos diferentes a los utilizados para el entrenamiento. El criterio por tanto debe ser el de establecer categorías que bajo el análisis visual dejen poco lugar para la duda a la hora de efectuar la clasificación manual. Piénsese que si es difícil para el ser humano efectuar la clasificación, más aún lo será para una red neuronal que está tratando de emular el razonamiento humano.

Los antecedentes existentes no suelen establecer un número elevado de clases. En la Tabla III.6 se resumen las clases establecidas en distintos trabajos en los que se ha realizado una clasificación no supervisada mediante análisis cluster y, tras determinar el número definitivo de grupos, se ha interpretado cada uno de ellos a través de una breve descripción. A la vista de la tabla, se puede establecer que:

- El número de clases oscila entre 3 y 4. Las clases se han establecido en los tres trabajos, en principio, según diferentes grados de sinuosidad.
- Las clases extremas, correspondientes a las seccionas más y menos sinuosas, parecen detectarse con bastante acierto. No obstante, en los trabajos de Plazanet existen muchos casos en los que la clasificación realizada para las clases intermedias parece un tanto arbitraria. En el trabajo de Skopeliti y Tsoulos las dos categorías intermedias parecen diferenciarse, más que por diferente grado de sinuosidad, por la direccionalidad: en la categoría 2 las líneas suelen ser de tendencia rectilínea mientras en la categoría 3 no conservan esta característica.
- Las muestras sobre las que se realizan la segmentaciones parecen menos heterogéneas que las del presente trabajo, sobre todo las de Plazanet (1995) y Plazanet et.al (1998), ya que no se observan vías de comunicación de primer orden, tales como autovías, que serían de una suavidad elevada, fácilmente apreciable. Así, la mayor variabilidad en el tipo de líneas a clasificar de nuestro trabajo puede permitir la definición de un número de clases mayor.

Tabla III.6 - Clasificación de secciones en trabajos de otros autores.

Referencia	Clases establecidas	Ejemplo
Plazanet (1995)	1 - Straight 2 - Sinuous 3 - Strongly sinuous	
Plazanet et.al (1998)	1 - Less sinuous 2 - Low sinuous 3 - Sinuous 4 - Very sinuous	
Skopeliti y Tsoulos (1999)	1 - Very smooth 2 - Smooth 3 - Sinuous 4 - Very sinuous with a strong arc	

III.4.2. Selección de medidas caracterizadoras

Como primer paso para poder efectuar cualquier tentativa de clasificación automática, es necesario seleccionar cuáles son las medidas caracterizadoras que van a ser empleadas para alimentar el sistema que la ejecute. Son abundantes las medidas que se pueden plantear a la hora de caracterizar una línea o sección de línea, tal y como se ha revisado en el apartado de antecedentes.

Es recomendable que las medidas seleccionadas sean significativas, no estén correladas y que se presenten normalizadas. Estas tres condiciones facilitarán cualquier tarea de clasificación que se intente realizar. Para elegir, y posteriormente normalizar, las medidas más significativas no correladas, se sugiere la aplicación de un Análisis de Componentes Principales, tal y como plantean Jasinski (1990) o Skopeliti y Tsoulos (1999). A continuación se resume de forma breve el funcio-

namiento de este método estadístico, que permitirá entrever su aplicabilidad para la tarea descrita en las anteriores líneas.

III.4.2.1. Análisis multivariable

El Análisis de Componentes Principales (ACP) forma parte del Análisis Multivariable, dentro del cual se han definido una gran cantidad y variedad de métodos. Éstos se pueden dividir en métodos descriptivos o exploratorios y métodos explicativos o confirmatorios (Bisquerra, 1989). El ACP es un método descriptivo con el que el investigador explora los datos buscando nuevos conocimientos, sin ninguna hipótesis previa, estudiando las interdependencias entre diferentes variables con el objeto de reducir al mínimo el número de variables necesarias para describir la información relevante contenida en las observaciones.

Análisis de componentes principales

Un ACP tiene sentido si existen altas correlaciones entre las variables, ya que esto es indicativo de que existe información redundante y, por tanto, pocos factores explicarán gran parte de la variabilidad total.

El ACP permite transformar un conjunto de variables correlacionadas en otro conjunto de variables que no lo están, denominadas factores o "componentes principales", que son combinación lineal de las variables originales. Primeramente se suele extraer un primer componente principal que resume lo mejor posible la información contenida en la matriz de correlaciones entre las variables (obtenida ésta a partir de los datos originales), es decir, es el que mejor explica la varianza total. El segundo componente resume lo mejor posible la información restante, es decir, el que mejor explica la varianza residual resultante, y es independiente del primero. La extracción de componentes continuaría sucesivamente hasta explicar la varianza total. Es posible extraer tantas componentes principales como variables originales haya, pero no tendría sentido, ya que lo que interesa es un mínimo de factores que expliquen un máximo de la variabilidad total y sean susceptibles de interpretación. Una regla para decidir cuantos factores con-

siderar consiste en observar el porcentaje de varianza total explicada por cada factor e ir calculando el porcentaje acumulado hasta llegar a un umbral preestablecido.

Los factores suelen representarse en la denominada "matriz factorial" donde cada columna representa un factor y el número de filas coincide con el número de variables. Cada elemento de esta matriz puede interpretarse como un índice de correlación entre cada variable y cada factor, recibiendo el nombre de pesos, cargas, ponderaciones o saturaciones factoriales. Cuando una variable muestra una saturación alta de un factor significa que está asociada a este factor, y cuando al mismo tiempo muestra saturaciones bajas en los demás factores, se dice que están saturadas en ese factor. Si el objetivo es seleccionar el subconjunto de variables que mejor sintetizan la información de las observaciones, estará integrado por variables asociadas a los factores que explican la mayor parte de la varianza.

Dado que en ocasiones es difícil la interpretación de los factores a partir de la matriz factorial, se procede a efectuar la denominada rotación factorial, que pretende obtener una matriz factorial rotada de más fácil interpretación. El procedimiento consiste en hacer girar los ejes de coordenadas que representan a los factores hasta conseguir que se aproximen al máximo a las variables en que están saturados. La matriz factorial rotada es una combinación lineal de la primera y explica la misma cantidad de la varianza inicial. Existen diversos métodos (ver Harman, 1980) para realizar las rotaciones, alterando cada uno la varianza explicada por cada factor. El más utilizado es el método de rotación ortogonal varimax, que como su propio nombre indica, pretende maximizar la varianza de los factores, tratando de obtener pesos muy altos y otros próximos a cero en cada columna de la matriz factorial. También se minimiza el número de variables con saturaciones altas en un factor, facilitando la interpretación de los resultados.

III.4.2.2. Conjunto de medidas caracterizadoras

La elección de las medidas geométricas a someter al análisis ACP se debe efectuar previendo su potencial utilidad. Así, es interesante plantear cada una de ellas considerando qué información va a aportar: sobre la sinuosidad, la densidad de detalles, etc. De forma general se pueden establecer las siguientes ideas al respecto:

- Pueden calcularse medidas sobre la sección completa, o bien obtener medidas sobre cada curva aislada para posteriormente plantear medidas de tendencia central, de dispersión, etc.
- Como medidas de tendencia central se puede emplear la media, pero en este sentido es interesante el comentario de Plazanet et.al (1998), para quien es preferible usar la mediana a la media aritmética. No obstante se incluirán ambas medidas de tendencia central para que sea el análisis estadístico el que sugiera el empleo de una u otra.
- La medida de la dispersión de cualquier medida geométrica será un indicador de la homogeneidad de la sección. En Jasinski (1990) existen ejemplos de empleo del coeficiente de variación, que tiene la ventaja de ser adimensional.
- El ACP es útil para su aplicación sobre medidas que estén correladas entre sí, luego se seleccionarán múltiples medidas, aunque algunas de ellas puedan parecer muy similares a priori.

En la Figura III.18 se observan varias de las medidas que se pueden obtener para una curva aislada. Los valores de cada una de ellas, así como los ratios que se pueden establecer entre cada par, permiten describir la forma y tamaño de cada curva. Sería adecuado obtener un valor representativo de cada una, como puede ser la media o la mediana, así como un indicador de su dispersión, como puede ser el coeficiente de variación. De esta forma, las medidas que se considerarán para una curva aislada, siendo ésta la comprendida entre dos puntos de inflexión consecutivos[1], serán las que se presentan en la Tabla III.7.

[1] Cuando se habla de dos puntos de inflexión consecutivos, la detección de éstos vendrá dada por el grado de suavizado previo a que sea sometida la sección que está siendo caracterizada. Dado que únicamente se pretenden eliminar los efectos debidos a incorrecciones en el digitalizado (microinflexiones), se aplicará un filtrado gausiano suave, con parámetro $\sigma = 1$.

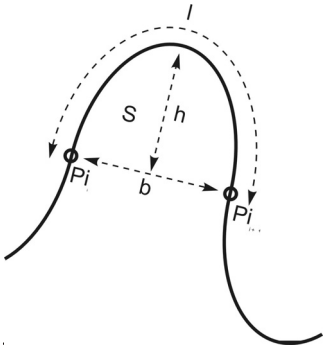


Figura III.18 - Variables a medir sobre una curva aislada, definida entre dos puntos de inflexión (P_i y P_{i+1}).

Existen trabajos donde se han seleccionado algunas medidas de forma intuitiva, buscando su independencia, pero sin ningún estudio estadístico que sustente su elección; por ejemplo, en Plazanet (1995) y Plazanet et.al (1998) se escogen la mediana del ratio entre *l* y *b*, y la mediana del ratio entre *h* y *b*; en Plazanet et.al (1998) también se tantea con el número de puntos de inflexión y la media del ratio entre *h* y *b*. Por el contrario, los previamente citados trabajos de Jasinski (1990) y Skopeliti y Tsoulos (1999) plantean el empleo del ACP para facilitar la elección las medidas. Sin embargo, estos trabajos emplean un gran número de medidas referidas a los trabajos de Buttenfield (1987), ligados a la aplicación del algoritmo de Douglas-Peucker, con los problemas ya señalados en Plazanet (1996) y referidos en el apartado II.6.2.

Tabla III.7 - Medidas consideradas sobre cada curva aislada.

- *l*: Longitud, obtenida mediante la suma de la longitud de los segmentos que constituyen la curva.
- *b*: Base, que se corresponde con la longitud de la línea-base definida por el segmento que une los dos puntos de inflexión.
- *h*: Altura, máxima distancia perpendicular que alcanza la curva respecto a la línea-base.
- *lb*: Ratio entre las longitudes *l* y *b*.
- *hb*: Ratio entre la altura *h* y la longitud *b*.
- *sb*: Ratio entre la superficie *s* del polígono, formado por la curva y la línea-base, y el cuadrado de la longitud de la línea-base.
- *a*: Para todos los vértices, excepto el primero y el último, se calcula el ángulo que forma el segmento anterior con el posterior, que puede variar entre 0 y 180º, sin tener en cuenta el signo. Seguidamente se efectúa el promedio para toda la curva.
- *c*: Para todos los vértices de la sección, excepto el primero y el último, se calcula la curvatura como el inverso del radio de la circunferencia que forma con sus vecinos anterior y posterior. Seguidamente se efectúa el promedio para toda la curva.

En este trabajo se plantea someter a un ACP las medidas[2] de la Tabla III.8, donde para cada una de ellas se especifica un número y abreviatura de la variable, su nombre (indicando la dimensión de la magnitud: longitud, ángulo, adimensional...), comentarios e información sobre que tipo de información puede aportar, así como las referencias bibliográficas que la hayan citado o empleado.

Tabla III.8 - Medidas caracterizadoras a someter a un ACP.

Variable		Nombre (dimensión)	Comentarios / Información que puede aportar	Referencias
1	***LB***	Ratio entre la longitud total y la línea-base de la sección	Medida que relaciona la longitud del trazado de la sección en relación a la del más corto en línea recta. Enriquece la información de la sinuosidad.	–
2	l_m	Media de la longitud de la curva (longitud)	Indica el tamaño de las curvas de la sección. Por tanto se trata de una medida de la densidad de cambios de dirección, por lo que enriquece la información sobre la sinuosidad.	Plazanet (1995, 1996, 1997)
3	l_{me}	Mediana de la longitud de la curva (longitud)		
4	l_{cv}	Coeficiente de variación de la longitud de la curva (adimensional)	Medida de homogeneidad, que indica la dispersión del tamaño de las curvas de la sección.	Plazanet (1995, 1996, 1997)
5	b_m	Media de la línea-base de la curva (longitud)	Da idea sobre la densidad de cambios de dirección en la sección, por lo que enriquece la	Plazanet (1995, 1996, 1997)

[2] Siguiendo la clasificación de medidas del proyecto AGENT (1999) (véase la Tabla II.6), estas medidas serían catalogadas como medidas de geometría interna, dentro de éstas como medidas de forma y finalmente concretadas en medidas de tamaño o sinuosidad /complejidad

Tabla III.8 - Medidas caracterizadoras a someter a un ACP.

Variable		Nombre (dimensión)	Comentarios / Información que puede aportar	Referencias
6	b_{me}	Mediana de la línea-base de la curva (longitud)	información sobre la sinuosidad.	
7	b_{cv}	Coeficiente de variación de la línea-base de la curva (adimensional)	Medida de homogeneidad, que indica la dispersión de la densidad de cambios de dirección en la sección.	
8	h_m	Media de la altura de la curva (longitud)	Da idea sobre la separación de una curva respecto a su línea base, por lo que enriquece la información sobre la sinuosidad.	Plazanet (1995, 1996, 1997) AGENT (1999, Appendix, p. 21)
9	h_{me}	Mediana de la altura de la curva (longitud)		
10	h_{cv}	Coeficiente de variación de la altura de la curva (adimensional)	Medida de homogeneidad, que indica la dispersión de la altura de las curvas de la sección.	Plazanet (1995, 1996, 1997)
11	lb_m	Media del ratio entre la longitud y la línea-base de la curva (adimensional)	Adecuado para parametrizar la forma de la curva, por lo que enriquece la información sobre sinuosidad.	Plazanet (1995, 1996, 1997) Plazanet et.al (1998) Skopeliti y Tsoulos (1999)
12	lb_{me}	Mediana del ratio entre la longitud y la línea-base de la curva (adimensional)		
13	lb_{cv}	Coeficiente de variación del ratio entre la longitud y la línea-base de la curva (adimensional)	Medida de homogeneidad, que indica la dispersión del ratio entre la longitud y la línea-base de las curvas de la sección.	Plazanet (1995, 1996, 1997)
14	hb_m	Media del ratio entre la altura y la línea-base de la curva (adimensional)	Adecuado para parametrizar la forma de la curva, por lo que enriquece la información sobre sinuosidad.	Plazanet (1996, 1997) Plazanet et.al (1998) AGENT (1999, Appendix, p. 20)
15	hb_{me}	Mediana del ratio entre la altura y la línea-base de la curva (adimensional)		
16	hb_{cv}	Coeficiente de variación del ratio entre la altura y la línea-base de la curva (adimensional)	Medida de homogeneidad, que indica la dispersión del ratio entre la altura y la línea-base de las curvas de la sección.	–
17	sb_m	Media del ratio entre el área de la curva y el cuadrado de la línea base (adimensional)	Adecuado para parametrizar la forma de la curva, por lo que enriquece la información sobre sinuosidad.	–
18	sb_{me}	Mediana del ratio entre el área de la curva y el cuadrado de la línea base (adimensional)		–
19	sb_{cv}	Coeficiente de variación del ratio entre el área de la curva y el cuadrado de la línea base (adimensional)	Medida de homogeneidad, que indica la dispersión de las superficies encerradas por las curvas y las líneas-base de la sección.	–
20	a_m	Media de la angularidad de la curva (ángulo)	Aporta información sobre la angularidad de las microcurvas de las líneas, por lo que enriquece la información sobre la sinuosidad.	McMaster (1986) Jasinski (1990) Bernhardt (1992) Skopeliti y Tsoulos (1999)
21	a_{me}	Mediana de la angularidad de la curva (ángulo)		
22	a_{cv}	Coeficiente de variación de la angularidad de la curva (adimensional)	Medida de homogeneidad, que indica la dispersión de la angularidad de las curvas de la	Jasinski (1990)

Tabla III.8 - Medidas caracterizadoras a someter a un ACP.

Variable		Nombre (dimensión)	Comentarios / Información que puede aportar	Referencias
			sección.	
23	c_m	Media de la curvatura de la curva (longitud^{-1})	Aporta información sobre la curvatura de las microcurvas de las líneas, por lo que enriquece la información sobre la sinuosidad.	Fritsch (1997) Barrault (1998) AGENT (1999, Appendix, pp. 49,50)
24	c_{me}	Mediana de la curvatura de la curva (longitud^{-1})		
25	c_{cv}	Coeficiente de variación de la curvatura de la curva (adimensional)	Medida de homogeneidad, que indica la dispersión de la curvatura de las curvas de la sección.	–

III.4.3. Clasificación mediante una red neuronal

Una vez se tenga disponible un conjunto de medidas caracterizadoras, tras el ACP, de cada una de las secciones, es necesaria una herramienta o sistema que, en función de una entrada (medidas caracterizadoras de una sección de línea), produzca una salida, que vendrá a ser la clasificación de la línea o sección.

En Werschlein y Weibel (1994) o Weibel (1995b) se subraya el potencial que las redes neuronales muestran en generalización cartográfica, señalando las tareas de clasificación temática, el reconocimiento de estructuras y el desarrollo de soluciones alternativas de generalización; también citan específicamente la posibilidad de aplicarlas en tareas de segmentación de elementos lineales en secciones homogéneas. Schuurman (1999) es poco optimista respecto a su aplicabilidad en tareas de generalización propiamente dichas, pero destaca su probada utilidad en tareas de clasificación. Como ejemplos de aplicación de redes neuronales en generalización, en Allouche y Moulin (2002, 2005) se emplea la red de Kohonen (Kohonen, 1984) para el operador de amalgamación; en Sester (2005) se ensaya el empleo de la red de Kohonen para el operador de tipificación.

En el presente trabajo se plantea la utilización del aprendizaje supervisado, a través del diseño, entrenamiento y validación de una red neuronal que realice la tarea de clasificación de elementos cartográficos de carácter lineal. Así, la hipótesis de partida es que la red neuronal será capaz de emular la clasificación de las secciones de líneas que realiza el ser humano (en adelante, experto). No se

tiene constancia del empleo de este tipo de herramienta en esta labor. Trabajos previos como los de Plazanet, Bigolin y Ruas (1998) o Skopeliti y Tsoulos (1999) se sirven del empleo del análisis cluster para la clasificación de muestras de elementos lineales o secciones de los mismos.

Para entrenar la red habrá que disponer de un conjunto de secciones de líneas, que serán las obtenidas mediante la segmentación semiautomática comentada en el apartado III.4.1.1, y además deberá estar disponible la entrada a la red para cada una de ellas (medidas caracterizadoras) y su salida prevista (tipo de línea), tal y como se ha indicado en el apartado III.4.1.2.

Entre los distintos tipos de redes neuronales, la red Backpropagation está considerada como una de las más adecuadas para realizar tareas de clasificación de patrones (véase Price et.al 1994; Finke y Müller, 1994, etc.), con aplicaciones prácticas que han dado buenos resultados en diferentes trabajos. Es por ello por lo que se plantea emplear este modelo de red para diseñar y validar una metodología automática de clasificación.

Un ejemplo práctico de clasificación de información es el de Bortolan, Degani y Willens (1990), que emplean una red neuronal para clasificar electrocardiogramas. El número total de muestras es de 3266 señales, de los cuales seleccionan aleatoriamente 2446 para entrar la red, quedando 820 para comprobar el funcionamiento del clasificador. Para cada una de las señales se calculan 39 parámetros, que dan lugar a 39 neuronas de entrada. El número de tipos de electrocardiogramas es de 7, por lo que el número de neuronas de salidas es de 7. Establecen una sola capa oculta, que dimensionan en 7 neuronas tras probar con diferente número. Los resultados de la clasificación de las 820 señales de comprobación oscilaron entre el 88% y el 96%, según el tipo de señal de que se tratase.

III.4.3.1. Capa de entrada

La capa de entrada es la encargada de recibir las entradas o estímulos que se captan desde el exterior. En el caso de la clasificación de sección de líneas co-

rrespondientes a vías de comunicación del MTN25, puede considerarse tanto información cuantitativa como cualitativa, tal y como se describe a continuación.

Información cuantitativa procedente de las medidas caracterizadoras

Tras realizar el ACP sobre las medidas del apartado III.4.2.2. estará disponible una selección de medidas significativas a la hora de caracterizar un elemento lineal. En la red neuronal se incluirá una neurona de entrada por cada una de estas medidas.

Es necesario señalar que suele considerarse adecuado el realizar una estandarización de las medidas o estímulos que alimentan una red neuronal. La estandarización suele realizarse de forma que la variabilidad o rango de una determinada variable refleje su importancia. Así, una variable más importante debería mostrar mayor varianza o rango. No obstante, si no se dispone de ninguna información sobre la importancia relativa de las distintas variables, los valores suelen estandarizarse según uno de los siguientes métodos (Sarle, 1997):

- Media 0 y desviación estándar 1.
- Rango 2, con centro en 0, es decir, un reescalado en el intervalo [-1, 1].

Dado que en los datos que alimentarán la red no se presupone la existencia de ningún interés sobre ninguna de las variables, ni tampoco ningún comportamiento según una distribución normal, la estandarización aplicada será la del reescalado en el intervalo [-1, 1]. De esta forma para cada una de variables se calculará el máximo y el mínimo del total de secciones disponibles, realizando el reescalado según la siguiente expresión, donde X es la variable a reescalar, X_i es un caso de la variable X y R_i es el reescalado de X_i:

$$MitadRango(X) = \frac{Max(X) + Min(X)}{2}$$

$$Rango(X) = Max(X) - Min(X)$$

$$R_i = \frac{X_i - MitadRango}{Rango} \cdot 2$$

Información cualitativa, según el tipo de red de carreteras

Además de las medidas caracterizadoras, parece adecuado incorporar a la red neuronal una información de carácter cualitativo, como es el de la red de carreteras a la que pertenece cada línea, ya que existe cierto conocimiento geométrico implícito, como son los criterios generales de diseño planimétrico de las diferentes redes de carreteras, que establecen diferentes niveles de rigurosidad en los parámetros que constriñen este diseño. Esto implica la ampliación de la capa de entrada para soportar esta información adicional. Existirá una neurona de entrada por cada categoría administrativa considerada

En la Tabla III.9 se recuerdan las distintas redes de carreteras a las que pueden pertenecer cada una de las secciones de línea. Combinando la red con el tipo de vía, existen 8 categorías a las que puede pertenecer una sección. No obstante, dado que el interés de incluir esta información en la red neuronal se debe a los condicionantes que se aplican al diseño planimétrico de cada categoría, se considera adecuado agrupar algunas categorías muy afines. Es el caso de las dos categorías de autovía, la Red de Carreteras del Estado de tipo convencional y la Red Básica Autonómica de tipo convencional, así como la Red Complementaria Autonómica y la Red Provincial. Agrupando estas 3 parejas, las 5 categorías de redes de carreteras a considerar para la capa de entrada de la red neuronal se presentan en la Tabla III.10.

Tabla III.9 - Redes de carreteras a las que pertenecen las secciones disponibles.

Red de Carreteras	Subred1	Subred2	Tipo de vía
Red de Carreteras del Estado	-	-	autovía
	-	-	convencional
Red de Carreteras de Andalucía	Red Autonómica	Red Básica	autovía
			convencional
		Red Intercomarcal	convencional
		Red Complementaria	convencional
	Red Provincial	Red Comarcal	convencional
Otras	-	-	pista

Tabla III.10 - Categorías de vías de comunicación para alimentar la red neuronal.

Categoría	Nombre	Redes incluidas
1	Autovías	Red de Carreteras del Estado. Red Autonómica. Red Básica.
2	Convencionales 1er orden	Red de Carreteras del Estado. Red Autonómica. Red Básica.
3	Convencionales 2º orden	Red Autonómica. Red Intercomarcal.
4	Convencionales 3er orden	Red Autonómica. Red Complementaria. Red Provincial. Red Comarcal.
5	Otras	Ninguna. Se incluyen las pistas.

Las 5 categorías de vías de comunicación que se han considerado dan lugar a 5 nuevas neuronas en la capa de entrada. Dado que esta información no es cuantitativa y que la red neuronal necesita trabajar con datos numéricos, habrá que efectuar una codificación de esta información. Como los valores de entrada a la red se pretende que estén estandarizados en el intervalo [-1, 1], cuando una sección pertenezca a una determinada categoría, su correspondiente neurona recibirá un valor de entrada de 1, mientras las otras 4 neuronas restantes recibirán un valor -1.

III.4.3.2. Capas ocultas

El número de capas ocultas debe derivarse de la propia experimentación. En principio puede ser suficiente con una sola capa oculta si se comprueba que el aprendizaje de la red converge sin mayores problemas. El principal problema podrá venir dado por el número de neuronas ocultas a considerar. Un número reducido puede impedir la convergencia de la red, pero un número excesivo pueda dar lugar a problemas en la generalización de la clasificación si se produce un sobreentrenamiento desde el momento en que el número de secciones de líneas disponible no sea muy elevado. Por tanto, este parámetro deberá derivarse por tanteo durante la fase de entrenamiento, a la vista del error global de la red tanto en el patrón de entrenamiento como en el patrón de validación.

III.4.3.3. Capa de salida

El objetivo de la red neuronal es la clasificación de las secciones de línea en *N* categorías no ordenadas. En estos casos, la capa de salida de la red neuronal se

estructura con *N* neuronas, de forma que en la fase de entrenamiento y en tanto que cada sección pertenece a una categoría, la neurona de salida correspondiente recibe un valor de 1, siendo 0 el valor del resto de neuronas.

Posteriormente, cuando la red haya sido correctamente entrenada y se esté empleando para la tarea de clasificación para la que ha sido diseñada, los valores resultantes (reales entre 0 y 1) servirán para estimar la probabilidad de pertenencia de cada sección de línea a cada una de las categorías.

III.4.3.4. Función de transferencia de las neuronas

La función de transferencia entre las neuronas, que debe ser continua y diferenciable en el caso de una red de tipo Backpropagation, será la de tipo sigmoidal $f(x) = 1 / (1 + e^{-ax})$.

III.4.3.5. Aprendizaje de la red

La ejecución del aprendizaje de la red se realizará mediante la regla delta generalizada más la adición de un momento, por las ventajas que muestra a la hora de facilitar la convergencia de la red.

Este aprendizaje toma forma en tanto la red estima qué valor han de tomar las conexiones entre las neuronas (los llamados *pesos* de la red) para que se produzcan las salidas deseadas en función de las entradas expuestas. Por tanto, el aprendizaje se puede poner en marcha en cuanto se tenga preparado el conjunto de valores de entrada y de salida de la red para cada una de las secciones derivadas de la segmentación semiautomática, formando el llamado *patrón de entrenamiento*.

Sería deseable el disponer de cientos o miles de secciones para entrenar la red, pues la presupuesta diversidad de casos presentados garantizaría la capacidad de generalización de la red, esto es, respondería de forma adecuada ante casos de secciones no empleados durante el entrenamiento, que en suma es el objetivo

final. Sin embargo, esta no es la situación de la muestra disponible, pues tras la segmentación semiautomática de las 24 líneas del MTN25, es previsible la obtención de un conjunto de secciones del orden de varias decenas. Por tanto, se está en una situación propicia para que se produzca un perjudicial sobreentrenamiento de la red que reduzca su capacidad de generalización, que es el problema más serio en el entrenamiento de redes neuronales (Sarle, 1995, 1997).

Es recomendable y habitual el estimar el error de la generalización de la red, para tomar las decisiones pertinentes enfocadas a su reducción, por ejemplo modificando el número de neuronas ocultas. La forma más habitual es la de dividir la muestra en dos partes, *conjunto de entrenamiento* y *conjunto de prueba*, siendo requisito que esta última no se haya empleado durante el entrenamiento en ninguna forma. Este conjunto de prueba debe ser representativo del conjunto de casos que queramos que sea capaz de generalizar la red. El error que cometa la red ya entrenada al ser aplicada sobre el conjunto de prueba será una estimación del error de generalización de la red. El inconveniente de esta metodología reside en la reducción de la cantidad de datos disponibles para la fase de entrenamiento, más importante aún en el caso de que la muestra sea reducida.

Una metodología alternativa, que permite emplear para el entrenamiento toda la muestra o conjunto de datos disponible es el de *validación cruzada* (ver Mustière, 2005, p. 948), más adecuada para casos en los que la muestra es de pequeño tamaño, con el inconveniente de la necesidad de entrenar la red sucesivas veces. La validación cruzada puede realizarse de diferentes maneras. Una de ellas es la de los *k-pliegues* (en inglés, k-fold cross validation), en los que el conjunto de datos se divide en *k* subconjuntos de igual tamaño. Se realiza el entrenamiento *k* veces, y en cada una de ellas uno de los subconjuntos no se emplea durante el entrenamiento, sino que se constituye en conjunto de prueba para calcular el indicador de error que se desee. Si además se cuida que las clases previstas estén adecuadamente representadas tanto en el conjunto de prueba como en el de entrenamiento, se hablará de validación cruzada con estratificación. Un valor común para *k* es 10 (Sarle, 1997). Un caso concreto de la validación cruzada es aquella en la que *k* es igual al tamaño de la muestra (en inglés, leave-one-out

cross validation). El principal inconveniente reside en los elevados requisitos de computación que conlleva, y en la imposibilidad de realizar una estratificación en el conjunto de prueba.

Así, se plantea en este caso la utilización del método de validación cruzada mediante pliegues, de la siguiente manera:

- La validación cruzada será estratificada, esto es, garantizará que existan casos de todas las clases de secciones de línea en los *k* subconjuntos.
- *k* será igual a 10. Pero si existe alguna clase cuyo número de casos sea inferior a esta cifra, el número de estratos será igual a este número, para garantizar una correcta estratificación. Por tanto se realizarán varios aprendizajes de la red, en cada uno de los cuales la red entrenada se empleará sobre el subconjunto de prueba correspondiente, anotando las clases a las que han sido asociadas las secciones de línea de prueba, con el fin de realizar una matriz de confusión (también denominada matriz de error o tabla de contingencia) que evidencie la capacidad de clasificación de la red. La matriz de confusión es una herramienta que suele emplearse para evaluar la calidad de clasificaciones temáticas como es el caso de las imágenes de satélite (véase Ariza y Pinilla, 1996, o Ariza, 2002), que permite el cálculo de diversos índices cuantitativos, globales, por clase o por caso.
- Para tantear el número de neuronas más adecuado para la capa oculta, se realizará una validación cruzada completa para distintos tamaños de esta capa, aunque serán los propios resultados que se vayan obteniendo los que guiarán la experimentación.
- Se escogerá la estructura definitiva tras un análisis pormenorizado de los resultados de la clasificación. Dado que se dispondrá de varios entrenamientos para la estructura definitiva, debido al proceso de validación cruzada, se analizará cuál es el más adecuado, que será escogido como definitivo.

III.4.3.6. Implementación de la red neuronal

Existen multitud de herramientas software disponibles para la investigación mediante el empleo de redes neuronales simuladas. Para este trabajo, en principio servirá cualquiera que permita diseñar, entrenar y validar la red neuronal, y que:

- permita modificar los parámetros que controlen el aprendizaje,
- proporcione información sobre el error global de la red conforme se va realizando el aprendizaje.
- contemple el empleo de la red ya entrenada para su empleo, permitiendo efectuar la clasificación automática pretendida.

Un programa que cumple estas premisas es el denominado JavaNNS (Java Neural Network Simulator), programa gratuito desarrollado por la universidad alemana de Tübingen (ver Figura III.19). Está basado en el programa SNSS (Stuttgart Neural Network Simulator), desarrollado por el Institute of Parallel and Distributed Systems (IPVS) de la universidad alemana de Stuttgart con el objetivo de crear un entorno de simulación eficiente y flexible para la investigación y aplicación de redes neuronales. JavaNNS se basa en el núcleo de SNNS, pero presenta una interface gráfica más cercana al usuario y además, dado que está programada en Java, es más fácil su empleo en diferentes plataformas. JavaNNS está disponible en la dirección:

http://www-ra.informatik.uni-tuebingen.de/software/JavaNNS/welcome_e.html

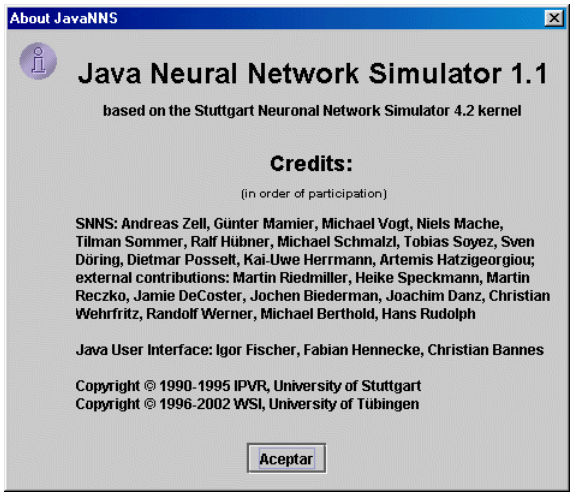


Figura III.19 - Créditos del programa JavaNNS.

Ejemplos de empleo de JavaNNS para la investigación sobre redes neuronales son los de Zhou y Nelson (2002), que trabajan en la predicción de congestiones de tráfico, Greenwald y Artz (2004), que pretenden el aprendizaje de un robot de bajo coste, Asonov y Agrawal (2004), quienes ensayan una metodología para captar la información mecanografiada en un teclado mediante el análisis de las señales acústicas emitidas y captadas mediante micrófono, o Jacobs (2003), que pretende predecir la velocidad media de una carretera para facilitar el cálculo de rutas óptimas. Estas referencias avalan la capacidad de JavaNNS para su empleo en investigación. En el campo concreto de la aplicación de redes neuronales en generalización cartográfica, en Werschlein (1995) se emplea SNNS para tantear su empleo en la generalización de elementos lineales.

En el Anexo G se resumen algunas particularidades del empleo de este software de simulación de redes neuronales.

III.4.4. Resumen del proceso para la creación de la red neuronal

Una vez detallado todo el proceso que lleva a la definición de una red neuronal artificial que emule al ser humano en la clasificación de las secciones de línea, es de interés sintetizar los pasos en un diagrama que aclaren el trabajo a realizar (Figura III.20):

- Se ha de disponer de un conjunto de secciones enriquecidas (entrada de la red) y clasificadas (salida de la red), que constituirán el patrón con el que se entrenará la red, como se puede observar en los primeros pasos del diagrama.
- Seguidamente se tanteará el entrenamiento de distintas arquitecturas de la red, modificando el número de neuronas de la capa oculta. Este proceso se realizará por validación cruzada, técnica adecuada cuando el número de datos con los que se dispone no es muy elevado. Se garantizará que cualquier pliegue de la validación cruzada tenga un número representativo de secciones de cada clase, por lo que se realizará un paso previo de estratificación del patrón.
- Del análisis de los resultados obtenidos en las distintas arquitecturas se realizarán dos tareas: por un lado se seleccionará una arquitectura definitiva, y por otro lado se modificará el patrón de entrenamiento si se detectan secciones que deberían pertenecer a otra clase.
- Seguidamente se procederá al entrenamiento por validación cruzada de la arquitectura elegida con el patrón modificado.
- Una vez evaluados los resultados de este último entrenamiento, se elegirá el mejor entrenamiento de la validación cruzada y se almacenará la RNA definitiva.

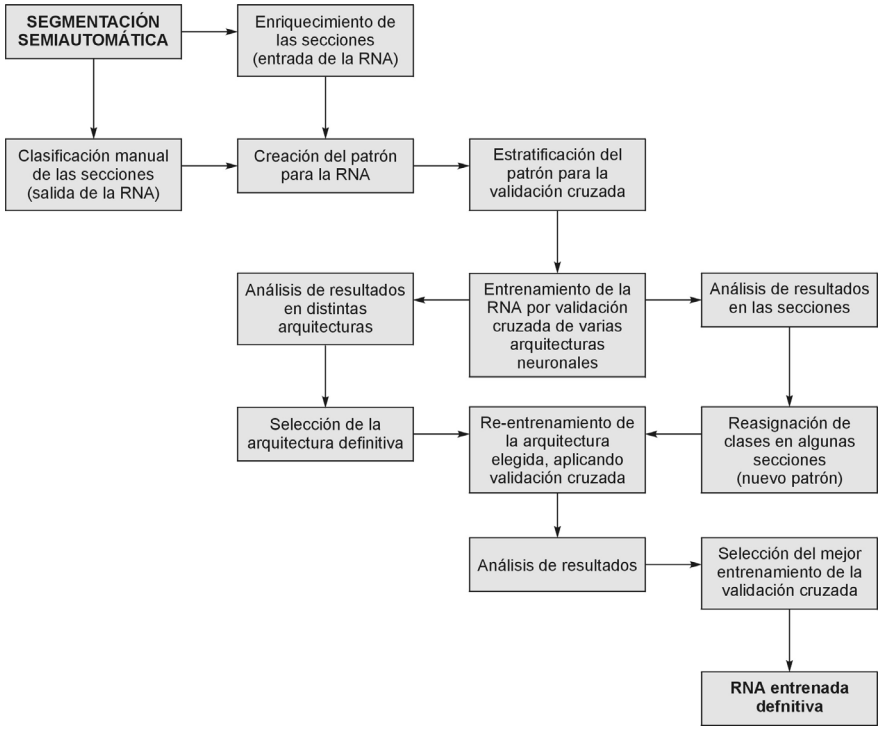


Figura III.20 - Resumen del proceso de creación de una red neuronal artificial para la clasificación automática de secciones.

III.5. SEGMENTACIÓN MEDIANTE LA RED NEURONAL

Una vez se efectúen los trabajos reseñados en el apartado anterior, se dispondrá de una red neuronal entrenada para efectuar tareas de clasificación de secciones de elementos lineales correspondientes a vías de comunicación del MTN25. Puede pensarse inmediatamente que esta facultad de clasificar secciones puede ser empleada para realizar una tarea de segmentación. Ésta precisamente se logra buscando alteraciones en la sinuosidad, complejidad, etc., del trazado del elemento lineal, es decir, la pertenencia a clases de línea diferentes.

Un ejemplo sencillo sería presentar a la red neuronal una línea dividida en sucesivos fragmentos de igual longitud. La presencia de dos fragmentos consecutivos clasificados en la misma clase indicaría que pertenecen a la misma sección, mientras que si pertenecen a clases diferentes se indicaría la existencia de un cambio de sección.

Esta idea, no obstante, restringe la detección de las secciones a un subconjunto de puntos de la línea, que viene dado por los extremos de los fragmentos presentados a la red. Podría pensarse en reducir el tamaño de estos fragmentos, pero esto podría conllevar a un tamaño de los fragmentos que sea muy inferior al tamaño de las secciones con las que ha sido entrenada la red, lo que podría dar lugar a resultados no apropiados.

Una mejora de esta propuesta de segmentación mediante la red neuronal sería relajar esta discretización de los posibles cambios de sección al tiempo que se mantiene una longitud suficiente de los fragmentos. Esto sería posible si se le va presentando sucesivamente a la red un fragmento de la línea original contenido dentro de una *ventana móvil* que se va desplazando a lo largo de la línea con un paso de una determinada longitud. Por ejemplo, si se establece una longitud *L* del fragmento de 1000 m y un paso *l* de 100 m, el primer fragmento a extraer para su clasificación por la red sería el que se extiende desde los 0 a los 1000 m de línea, el siguiente sería desde los 100 m a los 1100 m, el tercero desde los 200 m a los 1200 m, y así sucesivamente (ver ejemplo en la Figura III.21).

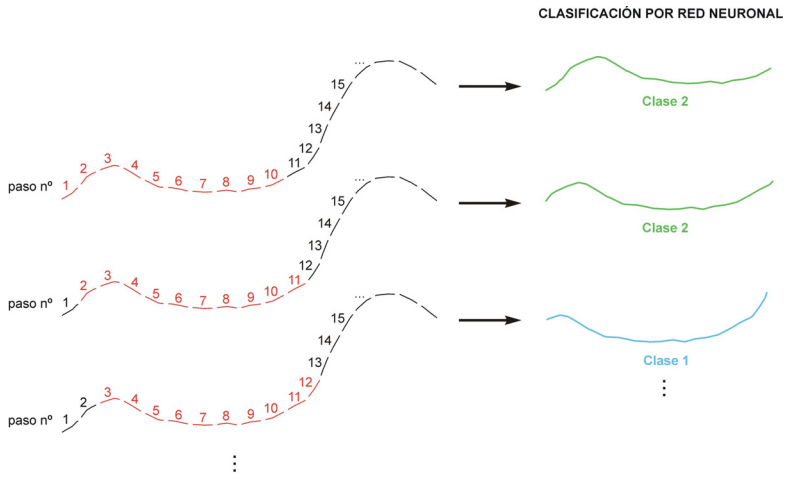


Figura III.21 - Extracción de fragmentos de la línea para su clasificación por la red neuronal.

Así, siguiendo este ejemplo, cada paso de 100 m sería clasificado en un total de 10 ocasiones. La moda de estos 10 valores vendría a indicar cuál es la clase a la que pertenece el paso, robusteciéndose así la tarea de clasificación. En la Figura

III.21 el paso 10 comenzaría siendo clasificado como clase 2, seguidamente de nuevo clase 2, a continuación clase 3, etc., y finalmente se calcularía la moda para establecer cuál es su clase definitiva.

En caso de que un paso no tuviera valor modal (p.e., si de los 10 valores hubiera 5 de dos clases diferentes), se propone actuar de la siguiente manera:

a) Considerar un intervalo definido por todos los pasos consecutivos que estén en esta circunstancia.
b) Tomar la moda de los pasos anterior ($moda_{ant}$) y posterior ($moda_{pos}$) al intervalo.
c) Si $moda_{ant} = moda_{pos}$ entonces se toma este valor para los pasos del intervalo.
d) Si $moda_{ant} \neq moda_{pos}$ entonces se toma el punto medio del intervalo; los pasos de la primera mitad tenrán valor modal $moda_{ant}$ y los de la segunda mitad un valor modal $moda_{pos}$.

Además, se puede refinar el método estableciendo una longitud mínima de la sección. Así, en caso de que la sección detectada sea inferior a este umbral se actuaría de forma parecida a la que acaba de comentarse, siendo ahora el intervalo el definido por los pasos que forman una sección de longitud inferior al umbral.

De esta forma, se propone ensayar esta metodología de segmentación una vez sea determinada la red neuronal de clasificación de elementos lineales, comparando los resultados con el resto de métodos de segmentación propuestos.

III.6. EVALUACIÓN VISUAL DE LOS RESULTADOS

La evaluación visual de los resultados es parte fundamental de este trabajo, en el que los objetivos se centran en la automatización de un proceso de segmentación y de un proceso de clasificación. Se trata de una emulación de tareas que

hasta la fecha se efectuaban de forma manual, o asistida en un entorno digital, con la subjetividad y falta de repetitividad que ello conlleva.

Aunque se puede tratar de formalizar medidas cuantitativas que informen sobre aspectos sobre la bondad de la segmentación o clasificación, y de hecho se han efectuado diferentes tanteos que no se han incluido en este trabajo, se ha considerado que, en principio, es el ser humano el encargado de evaluar estas tareas. La mente humana es muy compleja y es complicado emular la evaluación que ella efectúa sobre las dos tareas referidas.

En este trabajo se considera que, partiendo de una evaluación visual, en el momento en que se consiguiera ajustar unos parámetros para que el resultado fuera juzgado como positivo, se habría conseguido la automatización del proceso mediante los valores encontrados para los parámetros.

En los dos subapartados siguientes se concreta cómo y en qué fases del trabajo se llevará a cabo el análisis visual de los resultados de segmentación y clasificación. El primero se ocupa del análisis visual realizado por el doctorando durante el desarrollo de los trabajos para obtener unos resultados finales, tanto de segmentación (ajustando los parámetros que controlan la segmentación) como de clasificación (para entrenar la red neuronal). El segundo explica cómo se ha diseñado la evaluación de los resultados finales, tanto de segmentación como de clasificación, por parte de un panel de expertos. Por supuesto, ambas evaluaciones deben ser lo más homogéneas posible en tanto se realicen partiendo de los mismo supuestos, por lo que este panel de expertos ha de recibir información e instrucciones sobre los criterios que debe usar.

III.6.1. Evaluación durante el desarrollo de los trabajos

El recurso al análisis visual es reiterado a lo largo de este trabajo. La toma de decisiones acerca de la idoneidad de una segmentación o una clasificación frente a otra se sirve de este proceso visual en los siguientes casos:

a) Elección de parámetros para la automatización de la segmentación mediante áreas efectivas (metodología en el apartado III.3.1, resultados en el apartado IV.1).

b) Elección de parámetros para la automatización de la segmentación mediante wavelets (metodología en el apartado III.3.3, resultados en el apartado IV.2).

c) Elección de parámetros para la automatización de la segmentación mediante la red neuronal (metodología en el apartado III.5, resultados en el apartado IV.4).

d) Segmentación semiautomática para la posterior creación del patrón de entrenamiento de la red neuronal (metodología en el apartado III.4.1.1, resultados en el apartado IV.3.1.1).

e) Clasificación manual para la creación del patrón de entrenamiento de la red neuronal (metodología en el apartado III.4.1.2, resultados en el apartado IV.3.1.2).

III.6.1.1. Criterios para el análisis visual

El proceso de análisis visual tendrá su fundamento en el proceso de segmentación y clasificación presente en la generalización manual tradicional que se comenta en el apartado II.5.2 del capítulo de antecedentes. En este sentido, se toma como referente a McMaster (1995), en cuanto se determinarán los cambios en la geometría de la línea atendiendo a la sinuosidad y a la direccionalidad. Para comprender mejor este hecho, piénsese que es común que cualquier conductor habitual que compare diferentes rutas alternativas para un desplazamiento en su vehículo, observe, además de la categoría administrativa de la vía, estos dos aspectos a la hora de elegir el itinerario de su interés.

El análisis visual deberá permitir elegir entre diferentes segmentaciones de un mismo elemento lineal. De esta forma, se optará por una segmentación en la que se detecte que los cambios de sección señalan variaciones, lo más evidentes posible, en cuanto a la sinuosidad, direccionalidad o ambas. La sinuosidad se eva-

luará a través del tamaño de las curvas, su radio, así como mediante la presencia de tramos rectilíneos. La direccionalidad parte de la propia presencia de tramos rectilíneos, pero se basa en una observación global de la tendencia principal de la línea. Lógicamente, es de esperar que sea más sencillo comparar segmentaciones para una línea que sea poco homogénea, ya que los cambios de sección idóneos serán más evidentes. Una línea más homogénea es más difícil de segmentar manualmente y por tanto también será más difícil comparar dos segmentaciones realizadas sobre ella.

Un aspecto esencial que hay que concretar para interpretar correctamente el proceso de evaluación realizado es el del nivel de detalle del análisis visual. Se trata de una evaluación global, de visión de la línea en su conjunto, que pretende dividirla en varias, pero no gran cantidad, de secciones. Este proceder se fundamenta en la utilidad que tendría el disponer de una segmentación de este tipo, que facilitase la posterior generalización mediante algoritmos que se suelen aplicar a un elemento lineal íntegro (no a una de sus curvas integrantes). Ejemplos de este tipo de algoritmos son los de filtrado, consistente en la eliminación de parte de los puntos de la línea, un filtrado de curvatura, etc. (ver apartados II.5.3. y II.5.4).

Combinando lo dicho en cuanto la detección de cambios de sinuosidad y direccionalidad con lo referido en cuanto al nivel de detalle, en la Figura III.22 se presentan ejemplos de segmentaciones guiadas por el análisis visual:

- La línea 1 se puede segmentar en 3 secciones. El principio de la línea viene marcado por una sinuosidad baja, con una geometría con direccionalidad muy marcada y algunas curvas de amplio radio. Sin embargo al avanzar en la lectura de la línea este comportamiento se altera de forma drástica, por lo que se decide introducir un cambio de sección, que se ha simbolizado con un circulo negro que va a separar la primera sección (sección a) de la segunda (sección b). La sección b muestra una mayor heterogeneidad en el radio de las curvas, algunas de ellas de radio muy reducido, y presenta una direccionalidad menos marcada. El tramo final de la línea es similar al primero por lo que se introduce un nuevo cambio de sección que da lugar a la sección c.

- La línea 2 también se ha dividido en 3 secciones, indicando con un círculo negro los lugares donde el análisis visual indica que se produce un cambio en la sinuosidad y/o direccionalidad. La sección a es de sinuosidad muy baja y su direccionalidad no está claramente definida pues su geometría forma un gran arco. La sección b exhibe una mayor sinuosidad con curvas de pequeño radio y una direccionalidad poco definida. La sección c muestra una sinuosidad moderada, pero su direccionalidad está muy definida.
- La línea 3 muestra un comportamiento muy heterogéneo, y se ha dividido en 4 secciones. La sección a es de sinuosidad elevada, con direccionalidad poco definida. La sección b es de sinuosidad muy baja y direccionalidad bastante definida. La sección c es muy heterogénea, con algunas curvas de radio muy reducido y una direccionalidad muy variable. La sección d es de una direccionalidad muy marcada y de sinuosidad muy reducida.

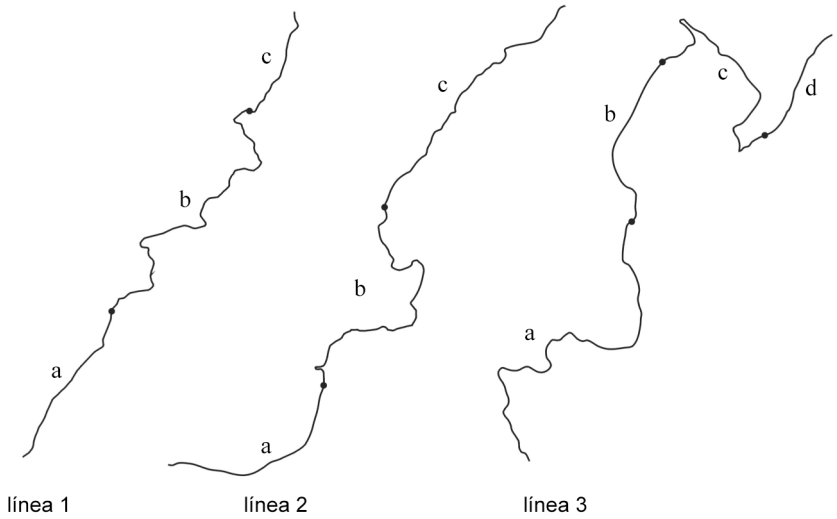


Figura III.22 - Ejemplos de líneas no homogéneas, con variación en su sinuosidad y/o direccionalidad.

Evaluación de los procesos de segmentación

En los puntos a, b y c señalados al comienzo de este apartado III.6.1, el análisis visual se centrará en la búsqueda de valores de parámetros que respondan de forma adecuada al mayor número de líneas posible de la muestra. Estos valores, válidos para varias líneas, estarán garantizando la "automatización" del proceso

de segmentación en cuanto proporcionarían al usuario una solución de segmentación en la que no se necesitaría su intervención.

En cambio, la segmentación semiautomática para formalizar un patrón con el que entrenar la red neuronal (punto d), buscará los parámetros más adecuados para cada línea de la muestra. Es necesario realizarlo así, para disponer de un patrón bien escogido, de forma que la red "aprenda" con el conjunto de secciones que sean internamente más homogéneas posible.

Evaluación del proceso de clasificación

En cuanto a la clasificación manual (punto e), se pretende formalizar varias clases de sección que atienden a los criterios de sinuosidad y direccionalidad mencionados anteriormente. De esta forma, una vez segmentada una línea, se podría clasificar cada sección en una de estas clases. En concreto, esta clasificación manual se aplicará sobre la segmentación semiautomática, pues se pretende que el conjunto de secciones derivado también esté clasificado para poder proceder con el entrenamiento de la red. Una vez la red sea capaz de asociar las entradas (secciones enriquecidas con medidas) y salidas (clasificación de las secciones) estará preparada para acometer la clasificación automática de cualquier sección. En el apartado III.4.1.2 se concreta el proceso de formalización de estas clases.

III.6.2. Evaluación final de resultados por un panel de expertos

Se ha considerado de gran valor el disponer de una evaluación externa de los resultados por parte de expertos en la materia. Esta evaluación puede señalarse como imprescindible, considerando que es muy difícil establecer medidas cuantitativas capaces de medir la bondad de un proceso tan complejo como es el de la segmentación y clasificación de un elemento lineal para un fin concreto. Para Ariza (2002, p. 25), las estimaciones de experto, si bien no permiten cuantificar, permiten obtener una valoración orientativa, que será subjetiva y dependiente

del conocimiento que tiene el experto sobre la temática sobre la que se la pide su opinión.

De esta forma, en este apartado se presenta la metodología seguida para este proceso de evaluación. La prueba está diseñada para que el experto pueda valorar la bondad tanto de los procesos de segmentación como de clasificación que han sido expuestos en los apartados previos.

Los objetivos principales que se plantean al realizar esta prueba al conjunto de expertos se concretan en la obtención de información sobre:

- La valoración de las distintas técnicas de segmentación. En esta valoración se incluye la segmentación semiautomática realizada para entrenar la red neuronal.
- La adecuación de técnicas de segmentación a unas tipologías de líneas frente a otras.
- La valoración de la clasificación automática realizada por la red neuronal para las distintas segmentaciones realizadas. En esta valoración se incluye la clasificación manual realizada para entrenar la red neuronal.
- La mejor adaptación de la clasificación automática realizada por la red neuronal a alguna técnica de segmentación frente a otras.
- La adecuación de la clasificación automática realizada por la red neuronal a unas tipologías de líneas frente a otras.

III.6.2.1. Panel de expertos

La elección de los expertos se ha realizado siguiendo los siguientes criterios:

- Deben ser experimentados en cartografía, bien a través de una dedicación docente, investigadora o de producción.
- Han de pertenecer a distintas instituciones. La diversidad ha de atender al tipo de institución (tanto universidades como organismos productores de car-

tografía), y a la nacionalidad (no sólo españolas, sino también de otros países).

- El número de expertos ha de ser suficientemente amplio para garantizar que cada línea es evaluada por varios de ellos.

De esta forma, los expertos seleccionados para la evaluación figuran en la Tabla III.11, indicando su nombre, la institución a la que pertenecen (indicando el país en caso de no ser España), e indicando si su labor en relación a la cartografía es eminentemente docente, investigadora o de producción.

Una vez el experto efectúe la evaluación de uno de los elementos lineales, se obtendrá la siguiente información (esta información se le suministra al experto en la carta de presentación que se indica posteriormente, para que tenga constancia de la utilidad de sus aportaciones).

- Una segmentación alternativa de la línea, sugerida por el experto.
- Una valoración de la segmentación de cada línea de la muestra mediante cada metodología de segmentación (RNA, áreas efectivas, wavelet).
- Los principales problemas detectados en la aplicación de cada metodología de segmentación sobre cada línea.
- Una clasificación alternativa de cada sección de línea, sugerida por el experto.
- Una valoración de la clasificación automática de cada sección de línea mediante la red neuronal.
- Una valoración de la segmentación y clasificación con la que ha sido entrenada la red neuronal.

Tabla III.11 - Panel de expertos previsto para la evaluación de los resultados

Experto	Institución	Doc	Inv	Prod
Ariza López, Francisco Javier	Universidad de Jaén	x	x	
Baella i Borderas, Blanca	Instituto de Cartografía de Cataluña		x	x
Bernabé Poveda, Miguel Ángel	Universidad Politécnica de Madrid	x	x	
Cruz Rodriguez, Marina	Universidad de Jaén	x		
Fernández del Castillo, Tomás	Universidad de Jaén	x	x	
Garrido Almonacid, Antonio	Universidad de Jaén	x		
Iribas Cardona, Francisco Javier	Delegación del Gobierno en La Rioja		x	x
Mackaness, William A.	University of Edinburgh (Escocia)	x	x	
Martín Betancor, Moisés	Universidad de Las Palmas de Gran Canaria	x	x	
Mesa Mingorance, José Luis	Universidad de Jaén	x		
Mozas Calvache, Antonio	Universidad de Jaén		x	
Ojeda Manrique, Juan Carlos	Instituto Geográfico Nacional			x
Pla Toldra, María	Instituto de Cartografía de Cataluña		x	x
Reinoso Gordo, Juan Francisco	Universidad de Granada	x	x	
Ruas, Anne	Institut Géographique National (Francia)		x	x
Ruiz Capiscol, Salvador	Instituto Geográfico Nacional	x		x
Sester, Monica	Universität Hannover (Alemania)	x	x	
Stuart, Thom	Ordnance Survey (Reino Unido)		x	x
Ureña Cámara, Manuel Antonio	Universidad de Jaén	x	x	
Weibel, Robert	Universität Zurich (Suiza)	x	x	

III.6.2.2. Diseño de la prueba

El diseño de la prueba se ha realizado de forma que el experto desarrolle una tarea que le permita acercarse progresivamente al elemento lineal bajo análisis, a través de varias tareas consecutivas:

a) **Observación** del elemento lineal. Se trata del primer contacto con el elemento lineal bajo análisis. El experto toma conciencia de la geometría de la línea, observando detalladamente los cambios de sinuosidad y direccionalidad que presenta.

b) **Segmentación manual** por el experto. Esta tarea es inmediata a la anterior (incluso pudiera ser simultánea) y en ella el experto presenta su propuesta sobre la mejor forma de segmentar el elemento lineal según los criterios que le han sido indicados.

c) **Evaluación de las segmentaciones presentadas**. Una vez el experto conoce el elemento lineal y ha propuesto su segmentación, está en una posición idónea para valorar otras segmentaciones alternativas a la suya propia, e incluso indicar qué problemas presentan.

d) **Clasificación de las secciones** por el experto. Seguidamente, independientemente de su valoración de la segmentación, se le solicita que clasifique cada una de las secciones resultantes de las segmentaciones presentadas.

e) **Evaluación de la clasificación presentada**. Una vez ha clasificado todas las secciones, se le presenta una propuesta de clasificación, que deberá valorar. El grado de acercamiento del experto al elemento lineal es máximo, y puede hacer comparaciones con la clasificación que él mismo había propuesto en el paso anterior.

Se ha tratado de orientar al experto en las distintas tareas, a través de la concreción de las clases de secciones de líneas en las que se basa la segmentación y clasificación, así como con la definición de escalas de puntuación e interpretación de las mismas. Esto es imprescindible si se pretende que todos los expertos entiendan de la misma forma el trabajo a realizar.

La prueba se ha estructurado en una carta de presentación más 4 hojas, cada una con los siguientes contenidos.

a) **Carta de presentación**, en la que se solicita la colaboración del experto y se le presenta el trabajo de investigación realizado, indicando el objetivo del mismo y su utilidad. Se detalla el interés de contar de su opinión, indicando para qué servirán sus aportaciones. Finalmente se presentan las 4 hojas que forman la prueba propiamente dicha. Se ha elaborado en idioma español y en idioma inglés.

b) **Hoja 1 - Instrucciones y tabla de respuestas**. Todo el proceso a desarrollar por el experto está pormenorizado en este documento, elaborado tanto en idioma español como inglés. El documento plantea las cinco tareas consecutivas que se resumen a continuación:

- Observar la línea de la Hoja 2 y segmentarla manualmente en secciones homogéneas en esta misma hoja. Para este cometido se indican qué criterios de sinuosidad y direccionalidad se deben seguir, indicando las 5 clases de sección que se van a distinguir, mostrando una figura (Figura III.23) que sirve de guía. Esta figura es clave para el desarrollo de todas las tareas por parte del experto, pues muestra ejemplifica y concreta el trabajo de segmentación y clasificación realizado, de forma que entienda cada clase de sección de la misma forma que en este trabajo. Hay que puntualizar

que la Figura III.23, aunque se incluye en el presente capítulo III, se ha elaborado tras efectuar el trabajo referido en el apartado III.4.1.2, cuyos resultados se presentan en el apartado IV.3.1.2.

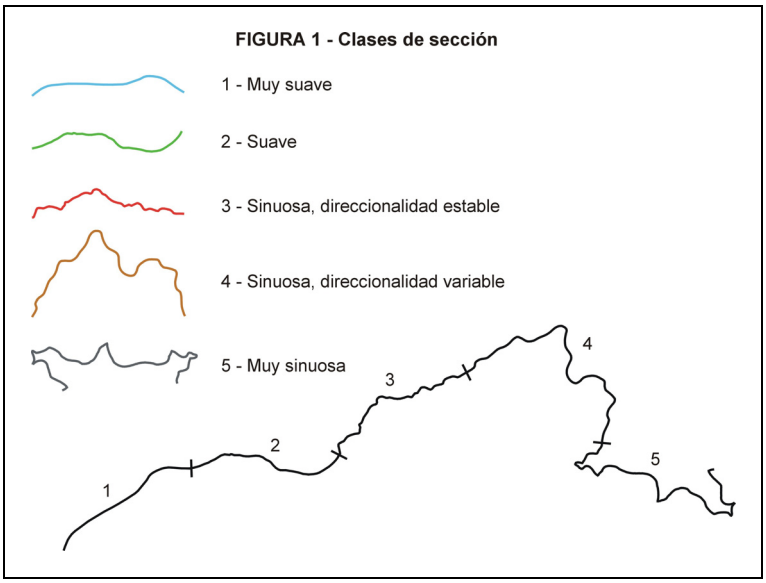


Figura III.23 - Clases de sección propuestas en la prueba.

- Evaluar los 4 casos de segmentación que se presentan en la Hoja 3. Para ello en la Hoja 1 se ha incluido una tabla de respuestas (Figura III.24) en la que debe señalar con una "X", en la columna 1, su grado de satisfacción entre 1 (nada satisfactorio) y 5 (muy satisfactorio). Se le sugiere comparar estas segmentaciones con la suya propia que ha realizado en la Hoja 2.
- Indicar si alguno de los 4 casos de la Hoja 3 presenta algún problema. Para ello en la tabla de respuestas de la Hoja 1 se sugieren varias tipologías de problemas en la columna 2 (ver Figura III.24), que se pueden marcar con una "X", o bien escribir cualquier observación que se considere oportuna.
- Clasificar las secciones presentadas en la Hoja 3, en esta misma hoja. Para esta operación se han introducido una serie de recuadros junto a cada sección, para que el experto señale si se trata de una sección de clase 1, 2, 3, 4, ó 5.

- Evaluar la clasificación automática, que se presenta en la Hoja 4, de las mismas secciones de la Hoja 3. Para ello en la Hoja 1 se ha incluido la columna 3 (ver Figura III.24) en la tabla de respuestas, debiendo señalar con una "X" el grado de satisfacción entre 1 (nada satisfactorio) y 5 (muy satisfactorio). Se le sugiere comparar esta clasificación con la suya propia que ha realizado en la Hoja 3.

TABLA 1

CASO	COLUMNA 1					COLUMNA 2		COLUMNA 3				
	Puntuación (hoja 3)					Problemas detectados / observaciones (hoja 3)		Puntuación (hoja 4)				
a)	1 - Nada satisfactorio	2 - Poco satisfactorio	3 - Satisfactorio	4 - Bastante satisfactorio	5 - Muy satisfactorio	Nº de secciones excesivo		1 - Nada satisfactorio	2 - Poco satisfactorio	3 - Satisfactorio	4 - Bastante satisfactorio	5 - Muy satisfactorio
						Nº de secciones insuficiente						
						Existen cambios de sección en lugares incorrectos						
						Existen secciones excesivamente largas						
						Existen secciones excesivamente cortas						
						Observación 1: _____						
						Observación 2: _____						
b)	1 - Nada satisfactorio	2 - Poco satisfactorio	3 - Satisfactorio	4 - Bastante satisfactorio	5 - Muy satisfactorio	Nº de secciones excesivo		1 - Nada satisfactorio	2 - Poco satisfactorio	3 - Satisfactorio	4 - Bastante satisfactorio	5 - Muy satisfactorio
						Nº de secciones insuficiente						
						Existen cambios de sección en lugares incorrectos						
						Existen secciones excesivamente largas						
						Existen secciones excesivamente cortas						
						Observación 1: _____						
						Observación 2: _____						
c)	1 - Nada satisfactorio	2 - Poco satisfactorio	3 - Satisfactorio	4 - Bastante satisfactorio	5 - Muy satisfactorio	Nº de secciones excesivo		1 - Nada satisfactorio	2 - Poco satisfactorio	3 - Satisfactorio	4 - Bastante satisfactorio	5 - Muy satisfactorio
						Nº de secciones insuficiente						
						Existen cambios de sección en lugares incorrectos						
						Existen secciones excesivamente largas						
						Existen secciones excesivamente cortas						
						Observación 1: _____						
						Observación 2: _____						
d)	1 - Nada satisfactorio	2 - Poco satisfactorio	3 - Satisfactorio	4 - Bastante satisfactorio	5 - Muy satisfactorio	Nº de secciones excesivo		1 - Nada satisfactorio	2 - Poco satisfactorio	3 - Satisfactorio	4 - Bastante satisfactorio	5 - Muy satisfactorio
						Nº de secciones insuficiente						
						Existen cambios de sección en lugares incorrectos						
						Existen secciones excesivamente largas						
						Existen secciones excesivamente cortas						
						Observación 1: _____						
						Observación 2: _____						

Figura III.24 - Tabla de respuestas de la prueba.

c) **Hoja 2 - Segmentación preliminar del experto**. Esta hoja se presenta en formato A4 o A3, según el tamaño de la línea bajo análisis. En ella se presenta con trazo negro la línea original, para que el experto la segmente manualmente, indicando el cambio de sección mediante un pequeño trazo perpendicular. En la Figura III.25 se presenta como ejemplo el caso de la línea *P-CaminoAzadillas*.

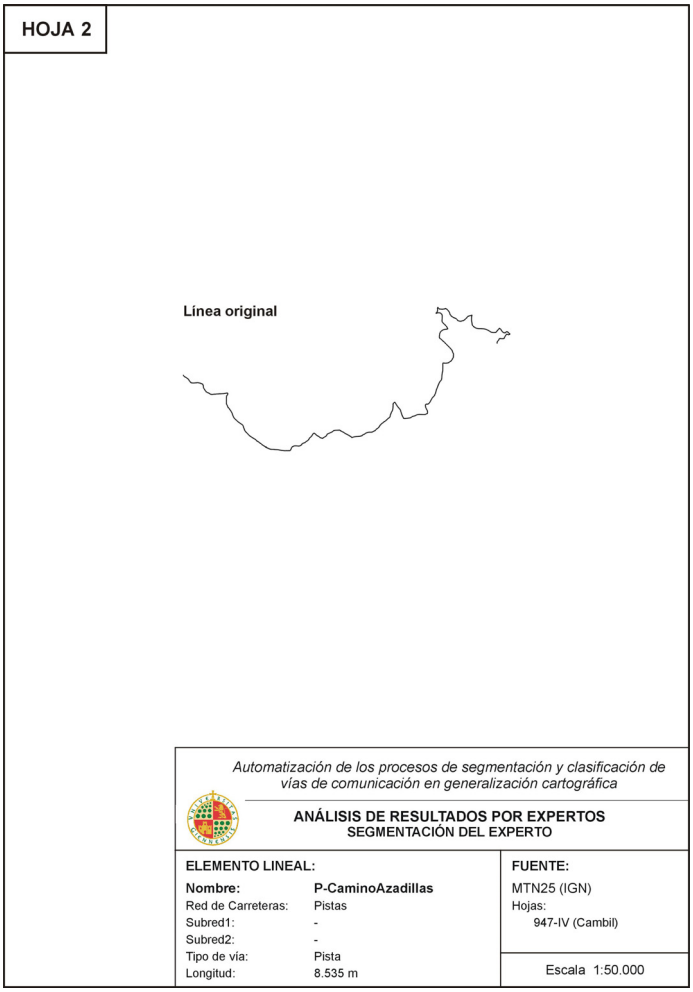


Figura III.25 - Ejemplo de Hoja 2: línea *P-CaminoAzadillas*.

d) **Hoja 3 - Segmentaciones propuestas**. Esta hoja se presenta en el mismo formato (A4 o A3) de la Hoja 2. En ella se presentan con trazo negro cuatro propuestas diferentes de segmentación de la línea, indicando el cambio de sección mediante un pequeño trazo perpendicular. En la Figura III.26 se presenta como ejemplo el caso de la línea *P-CaminoAzadillas*.

Los casos se nombran mediante una letra (a, b, c, d). El caso (a) se corresponde con la segmentación semiautomática realizada para entrenar la red neuronal; el caso (b) es la segmentación realizada por esta red una vez entrenada; el caso (c) es la segmentación realizada mediante el método de las áreas efectivas; el caso (d) se corresponde con la segmentación realizada

mediante wavelets. La valoración de cada caso se realiza en la columna 1 de la tabla de respuestas de la Hoja 1. Los problemas detectados se indican en la columna 2 de la misma tabla. Es interesante destacar que al incluir estos cuatros casos a evaluar, el experto está comparando, sin saberlo, la segmentación semiautomática realizada para entrenar la red neuronal, con los resultados obtenidos a partir de las otras tres técnicas de segmentación.

Además, junto a cada sección propuesta se sitúa una casilla cuadrada de trazo discontinuo para que el experto pueda indicar la clase a la que pertenece según su criterio.

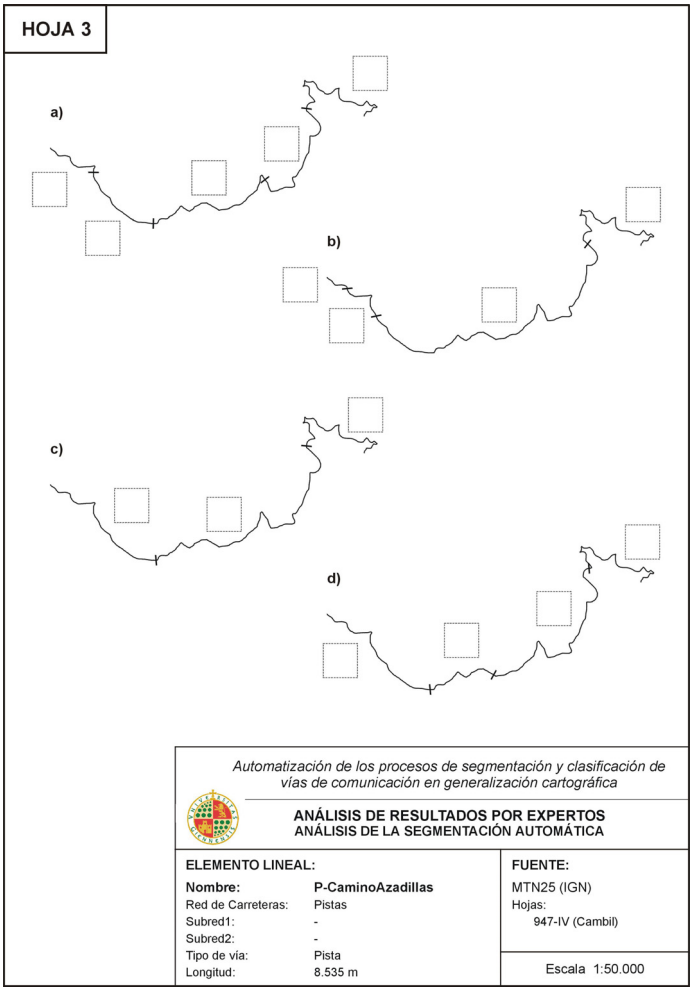


Figura III.26 - Ejemplo de Hoja 3: línea *P-CaminoAzadillas*.

e) **Hoja 4 - Clasificaciones propuestas**. Esta hoja se presenta en el mismo formato (A4 o A3) de las hojas 2 y 3, introducida dentro de un sobre cerrado

que sólo debe abrirse en al final del proceso de evaluación de la línea. En esta hoja se presenta la clasificación de las secciones de los mismos 4 casos (a, b, c, d) de la Hoja 3, utilizando el color de la línea para diferenciar los tipos de sección de la Figura III.23. En la Figura III.27 se presenta como ejemplo el caso de la línea *P-CaminoAzadillas*. La valoración de cada caso se realiza en la columna 3 de la tabla de respuestas de la Hoja 1. Es también de interés apuntar que el experto está comparando, sin saberlo, el caso (a) que es la clasificación manual realizada para entrenar la red neuronal, con el resto de casos, que son clasificaciones realizadas por la red neuronal una vez entrenada.

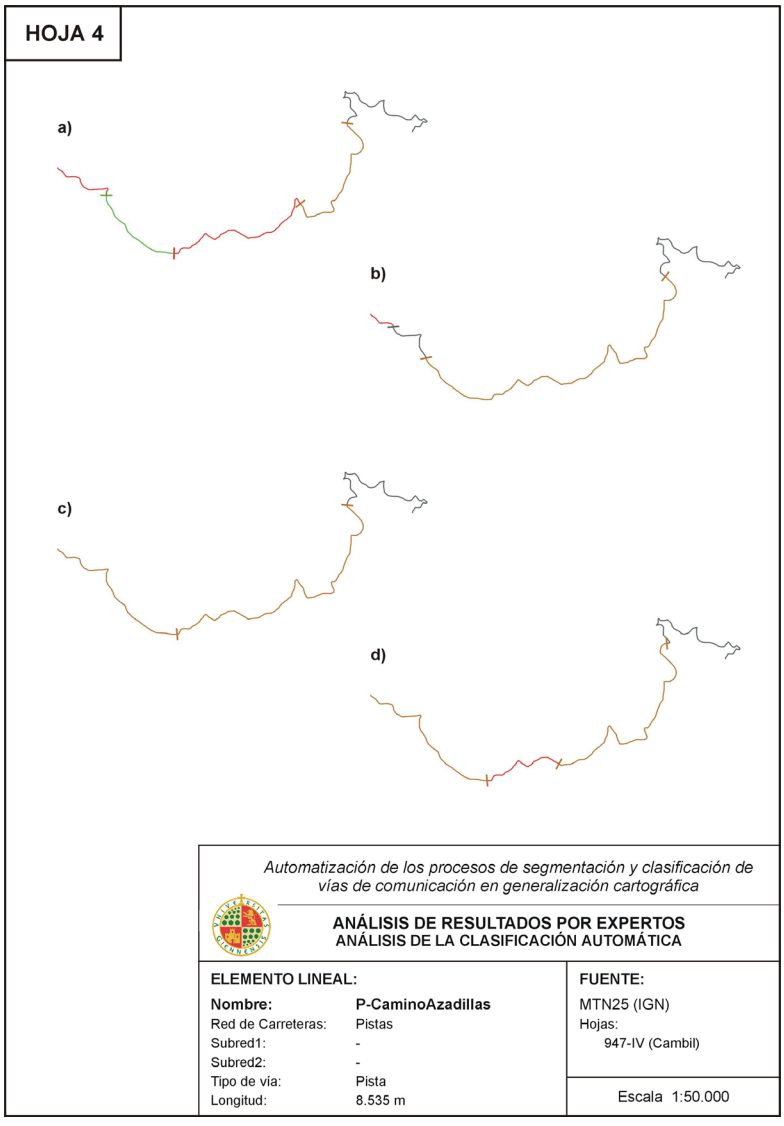


Figura III.27 - Ejemplo de Hoja 4: línea *P-CaminoAzadillas*.

Capítulo IV
Resultados y Discusión

En este apartado se presentarán y analizarán los resultados obtenidos mediante las diferentes metodologías de segmentación y de clasificación automática. Las primeras centrarán la atención en el calibrado de los parámetros que controlan la segmentación. La segunda se centrará en el entrenamiento y validación de la red neuronal que efectúa la clasificación automática. Los subapartados siguen el orden natural del proceso de investigación realizado; así por ejemplo, la aplicación de la red neuronal para segmentación es posterior al entrenamiento de esta red para efectuar la clasificación:

a) Segmentación automática mediante áreas efectivas
b) Segmentación mediante wavelets.
c) Entrenamiento y validación de la red neuronal para la clasificación automática de secciones.
d) Segmentación mediante la red neuronal.
e) Evaluación de resultados por expertos.

Los apartados (a) y (b) analizan la capacidad de segmentación de las dos metodologías algorítmicas propuestas. El apartado (c) se subdivide en tres subapartados: 1 - preparación de una muestra de secciones (obtenidas mediante segmentación con la metodología de áreas efectivas) clasificadas; 2 - búsqueda de medidas para enriquecer estas secciones; 3 - entrenamiento de la red neuronal. El apartado (d) se sirve de la red entrenada del apartado anterior para analizar su uso en segmentación. Por último el apartado (e) permite conocer la opinión de distintos expertos sobre los resultados, tanto relativos a segmentación como a clasificación.

IV.1. SEGMENTACIÓN MEDIANTE ÁREAS EFECTIVAS

Dada la metodología descrita en el apartado III.3.1, son tres los parámetros que influyen en el resultado del proceso de segmentación:

- la longitud *L* para obtener la función *SLogA* de suma de áreas efectivas
- el parámetro σ del filtrado gausiano sobre la función suma,
- el parámetro *DP* de detección de puntos críticos mediante un filtrado con Douglas-Peucker sobre el resultado del filtrado gausinao.

Para poder hacer más fácilmente gobernable la segmentación, es preferible dejar sólo libre uno de estos parámetros, el parámetro *DP*, ya que la aplicación de Douglas-Peucker es la que permitirá extraer más o menos puntos críticos en la función *SLogA*. Por ello, el primer y segundo subapartados se orientan a fijar los valores de σ y *L*. Seguidamente se presenta el apartado dedicado al ajuste del parámetro DP.

IV.1.1. Determinación del parámetro σ

El parámetro σ del filtrado gausiano es el que menos influencia debería tener sobre el método de segmentación propuesto, ya que sólo debe ser considerado como un pretratamiento, anterior a la aplicación de Douglas-Peucker, que pretende realzar la tendencia principal de la función suma *SLogA* calculada sobre la longitud *L*.

La muestra de líneas, procedente del MTN25, no presenta una densidad media homogénea en el número de puntos por unidad de longitud. Esto es, los trabajos de digitalización, usualmente de tipo fotogramétrico, atienden al trazado del elemento lineal en cuestión a la hora de aumentar o disminuir la frecuencia de la captura de vértices de la polilínea. En la Tabla IV.1 se presentan el número de puntos y la longitud de cada elemento, que permite calcular la distancia media entre vértices de cada línea, que oscila entre los 112,6 m de la autovía *A-44* y los 9,5 m de la pista *P-CerroSantin*, que además se presenta de forma gráfica en

la Figura IV.1. La forma escalonada de esta figura permite comprobar cómo se han empleado diferentes niveles de frecuencia captura:

- Las autovías, *A-44* y *A-316A*, así como la carretera autonómica de la Red Básica A-316 muestran una clara frecuencia menor respecto al resto de líneas, con 112,6, 88,2 y 51,2 m respectivamente.
- Las líneas *JV-2222*, *JV-2223* y *A-1102*, muestran densidades de unos 40 metros.
- Las líneas *A-311* y *JP-2332* muestran una densidad de unos 30 metros.
- Las líneas *JV-2226*, *JV-2225*, *JV-3012*, *N-323* y *JV-2224* muestran una densidad de unos 20 metros.
- El resto de líneas de la muestra presentan densidades entre 9,5 y 16,4 m.

Si se observan los trazados de las líneas, no se detecta una relación estrecha entre la sinuosidad de los trazados y la densidad de puntos. Sólo de una forma general se puede asumir que se aumenta la frecuencia de digitalización conforme la línea es más sinuosa o bien es de menor categoría administrativa, pero no siempre se cumple.

Tabla IV.1 - Distancia (densidad) media entre puntos de las líneas de la muestra (ordenada de mayor a menor)

Línea	nº de puntos	longitud [m]	distancia media entre puntos [m]
A-44	226	25451,794	112,619
A-316A	95	8382,355	88,235
A-316	325	16639,527	51,199
JV-2222	360	15063,726	41,844
JV-2223	198	8091,843	40,868
A-1102	385	15704,586	40,791
A-311	207	6863,586	33,157
JP-2332	212	5943,493	28,035
JV-2226	328	6913,705	21,078
JV-2225	277	5547,481	20,027
JV-3012	435	8708,316	20,019
N-323	1017	20241,886	19,904
JV-2224	354	6855,465	19,366
A-324	760	12483,677	16,426
P-CerroJabalcuz	774	11177,436	14,441
P-SierraPeñaAguila	938	13506,091	14,399
JV-3241	789	10952,771	13,882
A-320	899	12300,475	13,682
P-CaminoAncho	495	6632,108	13,398
JV-3242	783	9678,987	12,361
P-CerroAlmaden	1122	13674,774	12,188
P-Pegalajar-Central	571	6200,358	10,859
P-CaminoAzadillas	841	8542,599	10,158
P-CerroSantin	589	5620,676	9,543

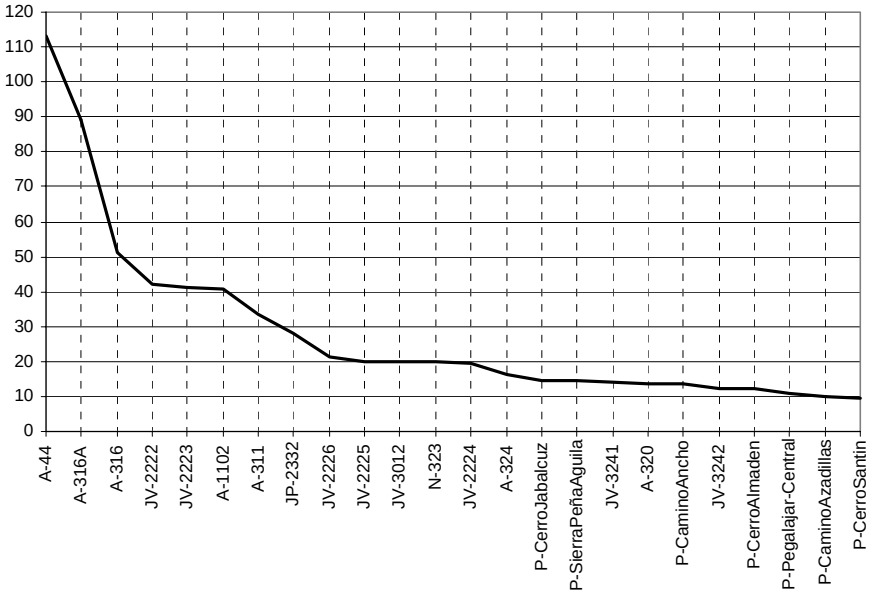


Figura IV.1 - Gráfica con la distancia media entre puntos en cada línea.

El filtrado gausiano, de parámetro σ, emplea un número de $(4 \times \sigma)$ vecinos a uno y otro lado del punto en el que se está calculando la convolución, por lo que el número total de puntos que intervienen es de $(8 \times \sigma + 1)$. Por tanto la elección

de σ va a suponer que en la convolución participe una determinada longitud de la línea en función de su densidad de puntos. Así:

- Un σ constante para toda la muestra de líneas supone considerar que la densidad media de digitalización es dependiente de la geometría de la línea. Una línea más sinuosa tendría mayor densidad y por tanto en el filtrado emplearía una longitud menor de la línea original.
- Por otro lado se podría modificar σ para que fuera independiente de la densidad, calculando este parámetro para una determinada longitud sobre la que se quiere hacer la convolución a partir de la densidad media calculada, pero esto obviaría que la geometría de las líneas puede ser muy diferente; por ejemplo, se obviaría que no es lo mismo filtrar 1 km de autovía que 1 km de pista de montaña.

La primera de las opciones es la deseable, pero ya se ha indicado que no existe esa relación entre sinuosidad y densidad de digitalización. Sin embargo se puede computar alguna medida indicadora de la sinuosidad que permita relacionarla con el nivel de filtrado, como es el caso de la medida de longitud curvilínea media que existe entre los puntos de inflexión de la línea.

Así, la propuesta consiste en fijar un parámetro para una de las líneas y estimar cuál debería ser el parámetro del resto de líneas a partir de la relación existente entre la medida de sinuosidad y la densidad. En la Tabla IV.2 se presenta la longitud curvilínea media entre puntos de inflexión consecutivos (l_m, 2ª columna de la tabla) y la densidad (denominada *densidad real*, 3ª columna) en m/punto. El cociente entre ambas variables permite calcular para cada línea el promedio de puntos digitalizados entre cada pareja de puntos de inflexión consecutivos (4ª columna), oscilando entre los 11,6 puntos de la línea *JV-3241* y los 4,3 puntos de la línea *JV-2223*. El promedio de todas las líneas es 7,1 puntos, y será este valor el que se empleará para estimar una *densidad estimada* (5ª columna) para cada línea, dividiendo l_m entre esta constante. Si resulta un valor de densidad estimada, en m/punto, superior a la real, esto quiere decir que la digitalización de la línea es más densa de lo que debería y por tanto que el filtrado debería efectuarse con más puntos, y viceversa en el caso contrario.

Por tanto el cociente de densidad estimada entre densidad real proporciona un escalar para ampliar o reducir el valor del filtrado gausiano una vez que se fije una referencia. Por ejemplo se puede fijar un suavizado leve, con $\sigma = 2$ para la línea *A-44*, que es la que tiene curvas más amplias, según su valor de l_m. Así se obtiene la 6ª columna de la tabla en la que se indica un valor de σ estimado para cada línea.

Tabla IV.2 - Estimación del parámetro del filtrado de cada línea

Línea (*)	l_m [m]	**dens. real** [m/punto]	**nº ptos entre PI consecutivos**	**dens. estimada** [m/punto]	**σ estimado**
A-44	880,927	113,119	7,8	123,419	2
N-323	209,918	19,923	10,5	29,410	3
A-316A	722,233	89,174	8,1	101,185	2
A-316	438,875	51,357	8,5	61,487	2
A-311	201,870	33,318	6,1	28,282	2
A-320	137,428	13,698	10,0	19,254	3
A-324	108,099	16,448	6,6	15,145	2
A-1102	202,492	40,897	5,0	28,369	1
JV-2222	244,941	41,960	5,8	34,316	1
JV-2223	175,910	41,075	4,3	24,645	1
JV-2224	109,660	19,421	5,6	15,363	1
JV-2225	94,459	20,100	4,7	13,234	1
JV-2226	125,464	21,143	5,9	17,578	2
JV-3012	141,030	20,065	7,0	19,758	2
JV-3241	160,635	13,899	11,6	22,505	3
JV-3242	134,880	12,377	10,9	18,897	3
JP-2332	173,506	28,168	6,2	24,308	2
P-CaminoAncho	94,744	13,425	7,1	13,274	2
P-CaminoAzadillas	53,702	10,170	5,3	7,524	1
P-CerroAlmaden	86,538	12,199	7,1	12,124	2
P-CerroJabalcuz	75,721	14,460	5,2	10,609	1
P-CerroSantin	47,633	9,559	5,0	6,673	1
P-Pegalajar-Central	60,401	10,878	5,6	8,462	1
P-SierraPeñaÁguila	165,391	14,414	11,5	23,171	3

IV.1.2. Determinación del parámetro L

Dado que la idea del método es la detección secciones con diferente acumulación de valores de área efectiva de Visvalingam, en principio, el parámetro *L* no puede ser demasiado pequeño, ya que la atención recaería de forma local sobre los puntos que acumulan los principales valores de área efectiva. Tampoco puede ser excesivamente grande, ya que podrían pasar desapercibidas secciones de interés.

Podría pensarse en un valor de *L* a emplear sobre cualquier línea de la muestra, pero esto no tendría en cuenta que la gran variabilidad existente en cuanto a sinuosidad y trazados geométricos. Una línea más suave de curvas amplias y más largas requerirá mayores valores de *L* para detectar diferentes comportamientos en su trazado que una línea con curvas de radio reducido y frecuentes cambios de dirección. Es por ello por lo que se ha decidido efectuar un tanteo con valores entre 1 y 4 km, en pasos de 500 m. Así, en la Tabla IV.3 se presentan los valores de *L* procedentes de este tanteo, realizado mediante un análisis visual de diferentes resultados obtenidos con la modificación de *L* y de *DP*.

Tabla IV.3 - Tanteo de valores de *L* para las líneas de la muestra

Línea	*L*	Línea	*L*
A-44	4000	*JV-2226*	2000
N-323	4000	*JV-3012*	2000
A-316A	4000	*JV-3241*	2000
A-316	2000	*JV-3242*	2000
A-311	2000	*JP-2332*	1500
A-320	2000	*P-CaminoAncho*	2000
A-324	2000	*P-CaminoAzadillas*	2000
A-1102	2000	*P-CerroAlmadén*	3000
JV-2222	2000	*P-CerroJabalcuz*	2500
JV-2223	2500	*P-CerroSantín*	2500
JV-2224	2000	*P-Pegalajar-Central*	2500
JV-2225	2500	*P-SierraPeñaDelÁguila*	2500

Con la lectura de la Tabla IV.3 se puede observar que el valor más frecuente es el de 2000 m (13 casos), seguido de 2500 (6 casos), 4000 m (3 casos) y 1500 y 3000 m (1 caso cada uno). Los mayores valores (4000 m) se corresponden con líneas de redes de carreteras de alta capacidad (autovías y nacionales). No obstante, el resto de casos no permiten sacar otra conclusión diferente a que el valor de 2000 m es el que suele funcionar mejor. Si acaso se puede añadir que las líneas más sinuosas, como *P-CerroJabalcuz*, tienen el valor más frecuente en 2500 m.

IV.1.3. Ajuste del parámetro DP

Una vez fijados los parámetros *L* y σ, es la variación del parámetro *DP* la que permitirá extraer más o menos secciones sobre el diagrama de la función *SLog*. Dado que se emplea el algoritmo de Douglas-Peucker, y que éste se puede emplear recursivamente para subdividir un elemento lineal (ver Ballard, 1981; But-

tenfield, 1991), cada sección detectada estará contenida en otra de orden superior, formando un árbol binario.

Por tanto, se puede fijar un determinado nivel de resolución en el árbol y en la segmentación. Como casos extremos están aquel en que toda la línea es una sección, es decir, no se han detectado secciones que dividan la línea, y aquel en que constituye una sección diferente cada uno de los segmentos formados por dos puntos consecutivos de la línea original. En principio el número de secciones a detectar dependerá de los requisitos de los posteriores procesos de producción cartográfica.

La interpretación geométrica del parámetro *DP* es la más difícil de asimilar, ya que el algoritmo de Douglas-Peucker se aplica sobre un espacio (*longitud*, *SLogA*) que no es ni homogéneo, ni habitual. No obstante, en zonas de caída o subida brusca de la función suma, la interpretación de *DP* es directa y se corresponde con el intervalo de longitud en el cual se produce el cambio. En las zonas con valores más constantes de la función, *DP* se referirá mayormente a un valor interpretable como suma de exponentes. De cualquier forma, conviene advertir que esta aplicación de Douglas-Peucker no es más que una forma de simplificar una función para poder detectar sus puntos fundamentales.

Indudablemente, con arreglo a lo apuntado en los párrafos anteriores, según vaya variando el valor de *DP*, de menor a mayor, se obtendrá un menor número de secciones que funcionarán como intervalos encajantes de las secciones determinadas con valores menores de *DP*. Además, planteamos la hipótesis de que, dada la geometría de un elemento lineal, expresada según la función $F(d_i, SLogA_i)$, existirá una "tendencia" a ser segmentada en un número determinado de secciones por el algoritmo de Douglas-Peucker.

La mejor manera de entender y justificar lo anterior es mediante una gráfica (ver Figura IV.2) que represente, en su eje vertical, el número de secciones detectadas sobre $F(d_i, SLogA_i)$ frente al valor de *DP* en el eje horizontal. La propensión de una línea a ser segmentada en un cierto número de secciones quedará en

evidencia por el(los) intervalo(s) de *DP* que posea(n) mayor recorrido y que, en principio, aporten robustez a la segmentación (en la figura, este número se ha rodeado con un círculo).

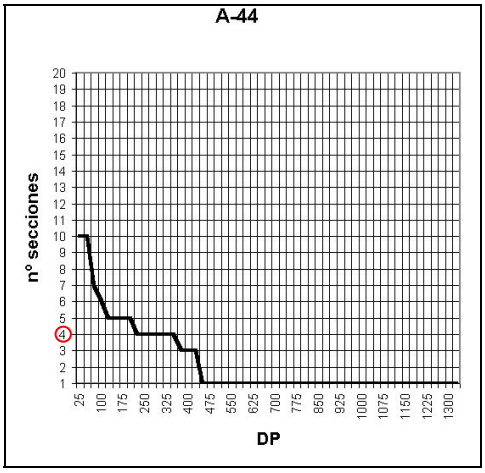


Figura IV.2 - Evolución del número de secciones *n* detectadas sobre $F(d_i, LogA_i)$ al modificar *DP* entre 50 y 450.

De esta forma, se ha planteado la aplicación sucesiva del algoritmo de Douglas-Peucker a cada elemento lineal, aplicando valores de *DP* en un intervalo $[DP_{MIN}, DP_{MAX}]$. Para cada línea se ha elaborado una gráfica como la de la Figura IV.2 que permita detectar la presencia de zonas estables que sugieran un número de secciones lógico o natural en cada caso. En esta operación se han aplicado los valores de *L* y σ sugeridos en los dos apartados previos, en un intervalo amplio de *DP*, con DP_{MIN} = 25 y DP_{MAX} = *1325*, en pasos de 25 unidades. Las gráficas resultantes se presentan en el Anexo A. Del análisis de las mismas se pueden detectar los siguientes comportamientos:

a) Se detectan algunos casos que no muestran zonas de estabilidad, lo que se puede interpretar como una indicación de homogeneidad y por tanto de la ausencia de necesidad de segmentar (líneas *A-311*, *JV-2225*, *P-CaminoAncho*).

b) Otro grupo de líneas se caracterizan por una marcada zona de estabilización, que se debe interpretar como una segmentación típica de una línea muy heterogénea, con secciones claramente diferentes, en la que la solución de la

segmentación ofrece menos margen de duda. Este es el caso de las líneas *A-316A*, *JV-2222*, *JV-3241*, *JV-3242*, *P-CaminoAzadillas*, *P-CerroSantín*.

c) Un tercer grupo estaría formado por aquellas líneas que presentan distintas zonas de estabilización, de amplitud similar, que provoca un dibujo en escalera en la gráfica correspondiente. Aquí la interpretación debe apuntar hacia la existencia de distintas soluciones, de forma que, si bien suele existir una zona de estabilización más amplia que en principio sería la más adecuada según este método, se podría elegir una u otra en función del grado de detalle requerido en la segmentación. Aquí se incluyen las líneas *A-44*, *N-323*, *A-320*, *A-324*, *A-1102*, *JV-2226*, *P-CerroAlmadén*, *P-SierraPeñaÁguila*.

d) Un último grupo responderá a aquellos casos con una zona de estabilización mayor a las demás, pero de poca amplitud. Se trataría de líneas de difícil segmentación, en los que la extracción de secciones homogéneas no es clara. Este sería el caso de las líneas *A-316*, *JV-2223*, *JV-2224*, *JV-3012*, *JP-2332*, *P-CerroJabalcuz*, *P-Pegalajar-Central*.

El análisis visual de los trazados de las líneas segmentadas, incluidos también en el Anexo A junto a cada gráfica, de los casos (b), (c) y (d) con parámetro *DP* en la zona de estabilización más extensa, permite corroborar la sensibilidad del método respecto a la falta de homogeneidad de los distintos elementos lineales. Sirvan de ejemplo aquellos casos en los que la visión de la segmentación parece totalmente acertada desde el primer golpe de vista, como son las segmentaciones obtenidas para *N-323*, *A-320*, *A-324*, *JV-3241*, *JV-3242*, *P-CaminoAzadillas*, *P-CerroAlmadén* o *P-SierraPeñaÁguila*. No obstante la visión detallada de todos los casos permite comprobar que la metodología siempre suele extraer las secciones atendiendo a cambios, más o menos sutiles, del trazado de la línea. Por tanto, puede afirmarse que es adecuada para su aplicación en vías de comunicación del MTN25 en tareas de segmentación.

IV.2. SEGMENTACIÓN MEDIANTE WAVELETS

A partir de la metodología expuesta en el apartado III.3.3, los parámetros que controlan la segmentación realizada mediante filtrado wavelet sobre valores de curvatura serán dos:

- El porcentaje de pérdida de información del filtrado wavelet, *K*.
- El umbral de longitud *L*.

Al igual que en la técnica de segmentación mediante áreas efectivas, el empleo de más de un parámetro dificulta el control de la segmentación, por lo que la primera tarea a realizar será estudiar la respuesta de la segmentación a cada uno de ellos.

IV.2.1. Estudio de los parámetros de control

K es el parámetro fundamental de esta técnica. Recordando su interpretación, responde al porcentaje de información eliminada al igualar a cero los coeficientes wavelets de menor valor, siendo, en suma, la intensidad del filtrado realizado. Interpretando su aplicación a la curvatura de un elemento lineal, aumentar *K* significa realizar un filtrado más fuerte y por tanto permitir una mayor variabilidad para los valores de curvatura que se igualan tras el filtrado. El resultado del filtrado es una función *(longitud, curvatura)* formada por una sucesión de valores constantes de curvatura de distinta longitud (a los que se denominan "tramos de curvatura").

En la Figura IV.3 se muestra una serie de filtrados wavelet de la función *(longitud, curvatura)*, modificando *K* entre 0 (ningún filtrado) y el 50% (el filtrado es una función constante). El filtrado wavelet debe permitir detectar diferentes comportamientos del elemento lineal en cuanto a su curvatura, es decir, debe evidenciar la falta de homogeneidad del elemento lineal y por tanto la presencia de secciones. En la figura, es a partir de *K = 20%* cuando esta circunstancia se hace plausible, haciéndose claramente patente la presencia de 4

secciones cuando *K* = *40%*. Por tanto, puede deducirse que la elección del valor adecuado de *K* va a permitir una inmediata segmentación del elemento lineal.

Por otro lado, el parámetro *L* determina cuál es la longitud mínima de una sección para poder ser considerada como tal. Así, dada una serie de tramos de curvatura tras el filtrado wavelet, sólo los de longitud mayor a *L* será considerados secciones. Además, al fijar *L* se evita que pequeños detalles locales del trazado del elemento lineal sean considerados como una sección independiente o provoquen la división de una sección homogénea en dos secciones consecutivas. En suma, al fijar *L* se establece el nivel de detalle de la segmentación (ver Figura IV.4). Además, se robustece la solución, pues detalles diferentes, procedentes de filtrados con diferente *K*, no alteran la segmentación final (Figura IV.5).

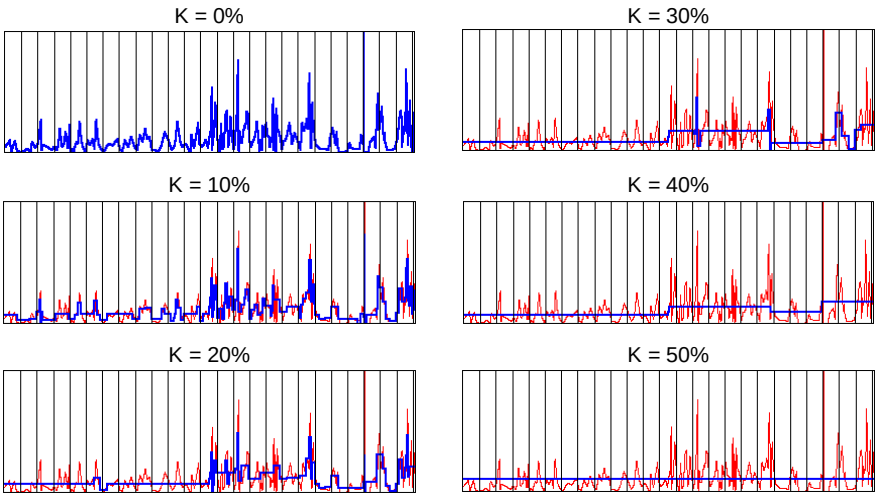


Figura IV.3 - Gráficas (longitud, curvatura) de la línea A-44. Original en rojo y filtradas wavelet en azul.

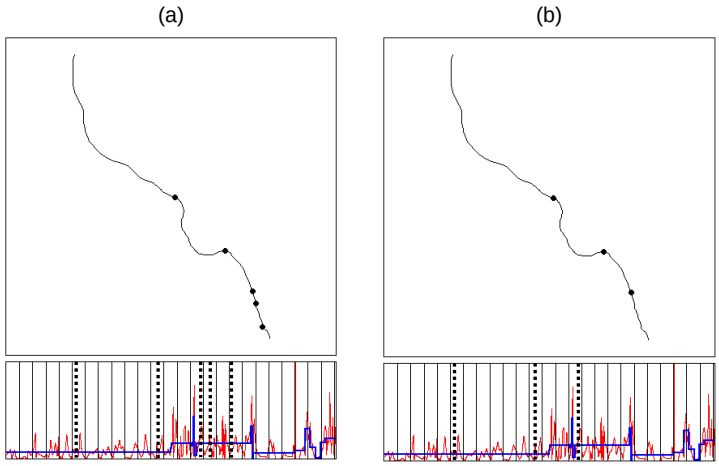


Figura IV.4 - Segmentación mediante wavelet de la línea *A-44*, con *K* = *30%* y *L* = 500 m (a) ó 1000 m (b).

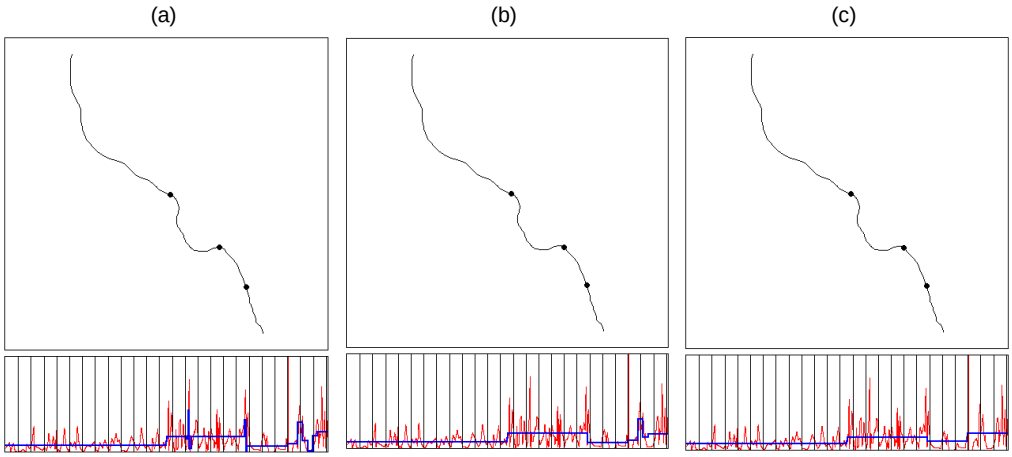


Figura IV.5 - Segmentación mediante wavelet de la línea *A-44*, con *K* = *30%* (a), *35%* (b), *40%* (c), y *L* = 2000 m.

Así, se ha sometido a un proceso de tanteo cada una de las líneas de la muestra, buscando valores de *K* y de *L* que proporcionen soluciones adecuadas de segmentación mediante el análisis visual. El estudio se ha llevado a cabo modificando el parámetro *K* desde el 30% hasta que se alcanza una función de curvatura constante, en pasos del 5%. En el caso de *L*, se ha probado con los valores de 1000 m y 2000 m. El empleo de un valor menor de *L* se ha comprobado que puede llevar a que los detalles locales cobren excesiva importancia en la segmentación.

En la Tabla IV.4 se resume el número de secciones detectadas en cada elemento lineal según los valores de *K* y de *L.* El caso habitual (véase la línea *JV-2224*) es que al aumentar *K*, el número de secciones muestra una tendencia que pasa de ser ascendente a descendente, hasta alcanzar un valor de 1. Cada solución se ha sometido a un análisis visual, verificando si los límites entre secciones se correspondían con cambios de sinuosidad. En la Tabla IV.4 se han marcado con fondo claro las soluciones más adecuadas y con fondo oscuro las más desfavorables. Se ha verificado que las líneas más heterogéneas son más fáciles de evaluar; por el contrario, una línea más homogénea es más difícil de segmentar manualmente, lo que redunda en una dificultad en la evaluación de la segmentación realizada de forma automática.

Tabla IV.4 - Número de secciones en cada elemento lineal tras el filtrado wavelet. Con fondo claro aparecen las mejores soluciones y con fondo oscuro las más desfavorables.

	***L* = 1000 m**									***L* = 2000 m**							
***K* (%)**	**30**	**35**	**40**	**45**	**50**	**55**	**60**	**65**	**70**	**30**	**35**	**40**	**45**	**50**	**55**	**60**	**65**
A-44	4	5	4	2	1	1	1	1	1	4	4	4	2	1	1	1	1
N-323	9	10	8	8	3	2	1	1	1	4	3	4	5	2	2	1	1
A-316A	3	4	3	2	2	1	1	1	1	3	3	3	2	2	1	1	1
A-316	5	5	4	5	4	3	2	1	1	2	2	4	4	3	3	2	1
A-311	2	3	2	2	2	1	1	1	1	1	1	1	1	1	1	1	1
A-320	5	4	4	3	4	3	1	1	1	1	3	4	3	3	1	1	1
A-324	3	3	2	4	4	4	4	2	1	3	3	2	2	3	3	3	2
A-1102	3	5	4	6	6	4	3	1	1	1	1	2	2	2	3	3	1
JV-2222	4	5	7	5	5	4	4	1	1	1	2	2	3	4	3	3	1
JV-2223	3	3	3	2	2	3	1	1	1	1	1	2	2	2	2	1	1
JV-2224	1	1	2	4	3	2	1	1	1	1	1	1	1	2	2	1	1
JV-2225	1	4	3	3	1	1	1	1	1	1	1	1	1	1	1	1	1
JV-2226	3	3	3	3	3	3	2	1	1	1	1	1	1	1	2	2	1
JV-3012	3	3	6	6	4	3	1	1	1	1	2	2	2	3	1	1	1
JV-3241	4	4	5	5	4	4	3	3	1	2	2	2	2	4	3	3	3
JV-3242	5	4	4	3	3	3	2	1	1	1	1	1	2	3	2	2	1
JP-2332	2	2	2	2	2	2	3	3	1	2	2	2	2	2	2	2	2
P-CaminoAncho	3	3	3	3	3	3	3	3	2	1	1	2	2	2	2	2	1
P-CaminoAzadillas	2	3	4	3	3	3	4	1	1	1	1	3	3	3	3	3	1
P-CerroAlmadén	4	4	6	6	2	1	1	1	1	2	2	2	2	2	3	1	1
P-CerroJabalcuz	3	5	5	5	5	1	1	1	1	1	1	2	2	3	1	1	1
P-CerroSantín	1	2	2	2	3	3	1	1	1	1	1	2	2	2	2	1	1
P-Pegalajar-Central	1	1	1	3	2	1	1	1	1	1	1	1	1	2	1	1	1
P-SierraPeñaDelÁguila	6	5	5	5	1	1	1	1	1	1	3	3	3	2	1	1	1

El tanteo mostrado en la Tabla IV.4 ha permitido comprobar que, en general, es preferible un valor de *L* de 1000 m a uno de 2000 m. Sólo en las líneas más suaves, como es el caso de las líneas correspondientes a la Red de Carreteras del

Estado y a la Red Autonómica, ambos valores muestran resultados adecuados. Así, se puede optar por fijar este parámetro en 2000 m para estas líneas, y en 1000 m para el resto (Red Provincial y pistas).

Centrando la atención en los valores de *K* que ofrecen soluciones más adecuadas, suelen oscilar entre el 30% y el 45%, siendo el 40% el valor más frecuente. La recomendación de uso sería optar por este valor, modificándolo hacia arriba o hacia abajo si la solución no se considerara adecuada. No obstante, son muchos los elementos lineales en los que la robustez de la segmentación hace que sea la misma en un intervalo de valores de *K*. Por ejemplo, éste es el caso de las líneas *A-316*, *A-311*, *JV-2223*, *JV-2226*, *JP-2332*, *P-CerroJabalcuz*, etc.

Por tanto puede asumirse esta metodología como adecuada para tareas de segmentación. Los parámetros sugeridos para su aplicación sobre las líneas de la muestra dan lugar a las segmentaciones que se indican en el Anexo B.

IV.3. ENTRENAMIENTO Y VALIDACIÓN DE LA RED NEURONAL PARA LA CLASIFICACIÓN AUTOMÁTICA DE SECCIONES

Este apartado queda estructurado en los pasos consecutivos necesarios para efectuar el entrenamiento de la red neuronal. Así, en primer lugar, es necesario disponer de patrones que permitan entrenar la red, lo que lleva a la necesidad de disponer de un conjunto de secciones, enriquecidos con medidas (entrada de la red neuronal), y clasificados según el criterio deseado (salida de la red neuronal). Así, los dos primeros subapartados presentan los resultados para disponer de esta muestra patrón. El tercer subapartado se ocupa de los resultados del entrenamiento de la red.

IV.3.1. Preparación de la muestra de secciones homogéneas y clasificadas

Como se comentó en el capítulo III, se hace necesario disponer de un conjunto de secciones homogéneas y clasificadas sobre las que realizar análisis posteriores enfocados hacia la búsqueda de una herramienta automática para la clasificación de secciones de elementos lineales, en este caso concreto correspondientes a vías de comunicación procedentes del MTN25.

IV.3.1.1. Segmentación semiautomática

La propuesta ha consistido en realizar una segmentación mediante el empleo de la técnica de suma acumulada de áreas efectivas, cuyos resultados se han expuesto en el apartado IV.1. No obstante, y como se especifica en el apartado III.4.1.1, se empleará esta técnica de forma asistida o semiautomática, modificando línea a línea los parámetros del algoritmo. Así, mediante la inspección visual, se garantiza que se entrena la red neuronal según el criterio que un experto cartógrafo podría perseguir a la hora de obtener un conjunto de secciones que sean internamente homogéneas.

Como se explica en el apartado III.6.1, han sido las modificaciones en la direccionalidad y sinuosidad de una línea las que han guiado el proceso semiautomático de segmentación, eligiendo aquellas segmentaciones que separaban secciones en las que se detectaba una alteración visualmente significativa de alguno de estos dos aspectos.

En la Tabla IV.6 se presentan, para cada línea, los parámetros *L* y *DP* que se han seleccionado para efectuar la segmentación de las líneas de la muestra (Figura IV.6), indicando el número de secciones resultantes. El número total de secciones de la muestra ha sido de 73, cuyo trazado puede observarse en la Figura IV.7.

IV.3.1.2. Clasificación de las secciones

Dado que es necesario disponer de un patrón de entrenamiento para la red neuronal, se han de establecer una serie de clases a las que asignar cada una de las secciones detectadas, que será una clasificación de experto. Posteriormente la red neuronal formalizará, a través de los pesos de las conexiones entre las diferentes neuronas, el conocimiento que permita realizar clasificaciones que emulen la realizada por el ser humano. Por tanto se debe ser cuidadoso a la hora de establecer clases y a la hora de asignar las secciones a una de ellas.

La metodología de trabajo se ha fundamentado en la evaluación visual (ver apartado III.6.1) mediante una observación minuciosa y clasificación reiterativa del conjunto de secciones. Se han realizado múltiples revisiones de la clasificación realizada, partiendo de una clasificación preliminar más grosera y luego refinándola con una contemplación más detallada de las líneas. Debido fundamentalmente a la siempre inevitable existencia de secciones de línea que combinan características de unas clases y otras, en múltiples ocasiones se hizo necesario volver a redefinir las características comunes de las líneas incluidas en cada clase y reclasificar cierto conjunto de secciones.

Se ha optado tanto por una visualización de las secciones en su ubicación geográfica relativa original (como la Figura IV.7), que facilita la comparación entre secciones consecutivas de una misma línea, como por visualizaciones de conjuntos de secciones agrupados por clases (como la Figura IV.8), que permite la comparación de las líneas agrupadas bajo una misma clase en un momento dado. También se ha dispuesto de los mapas originales, en formato papel, de las cuatro hojas del MTN25.

Es necesario comentar que se ha comprobado que no es fácil esta tarea de clasificación, dada la gran variabilidad de trazados que se presentan. Es de esperar que la dificultad sea aún mayor cuando un procesamiento sea automatizado, y no cuente con las ventajas del conocimiento, capacidad de análisis, y visión holística de la mente humana. Con todo, las clases establecidas para este trabajo se presentan en la Tabla IV.5. En la última columna de la Tabla IV.6 se indica la

clase de cada una de las secciones. Gráficamente, la clasificación puede observarse en las figuras IV.7. y IV.8.

Tabla IV.5 - Clases establecidas a la vista de las líneas de la muestra.

Clase		Características	
1	**Muy suaves**	Longitud y radio de curvas: Dirección predominante: Vías más frecuentes:	grande muy manifiesta Red de Carrereteras del Estado Red Autonómica, Básica
2	**Suaves**	Longitud y radio de curvas: Dirección predominante: Vías más frecuentes:	variable muy manifiesta Red Autonómica, Intercomarcal Red Provincial
3	**Sinuosas**, con direccionalidad estable	Longitud y radio de curvas: Dirección predominante: Vías más frecuentes:	reducido manifiesta Red Autonómica, Complementaria Red Provincial
4	**Sinuosas**, con direccionalidad variable	Longitud y radio de curvas: Dirección predominante: Vías más frecuentes:	reducido poco manifiesta Red Provincial Pistas
5	**Muy sinuosas**	Longitud y radio de curvas: Dirección predominante: Vías más frecuentes:	muy reducido poco manifiesta Pistas

Tabla IV.6 - Parámetros para la segmentación semiautomática.

Línea	*L*	*DP*	nº secciones	Tipos de secciones (*)
A-44	4000	400	3: 1, 2, 3	1, 1, 1
N-323	4000	450	3: 4, 5, 6	2, 1, 3
A-316A	4000	400	2: 7, 8	2, 1
A-316	2000	350	3: 9, 10, 11	3, 1, 1
A-311	2000	400	1: 12	2
A-320	2000	450	3: 13, 14, 15	2, 3, 1
A-324	2000	400	5: 16, 17, 18, 19, 20	4, 2, 3, 2, 4
A-1102	1500	400	3: 21, 22, 23	3, 3, 3
JV-2222	2000	275	5: 24, 25, 26, 27, 28	3, 4, 3, 1, 4
JV-2223	2500	400	1: 29	2
JV-2224	2000	400	2: 30, 31	2, 3
JV-2225	2500	100	2: 32, 33	2, 3
JV-2226	2000	400	2: 34, 35	3, 3
JV-3012	1500	200	3: 36, 37, 38	2, 4, 2
JV-3241	1500	300	3: 39, 40, 41	3, 4, 1
JV-3242	2000	300	5: 42, 43, 44, 45, 46	1, 3, 1, 3, 3
JP-2332	1400	200	4: 47, 48, 29, 50	3, 2, 3, 2
P-CaminoAncho	2000	400	1: 51	2
P-CaminoAzadillas	2000	75	5: 52, 53, 54, 55, 56	3, 2, 3, 4, 5
P-CerroAlmadén	2000	200	4: 57, 58, 59, 60	4, 4, 5, 5
P-CerroJabalcuz	1000	130	6: 61, 62, 63, 64, 65, 66	5, 5, 5, 5, 3, 5
P-CerroSantín	1500	400	1: 67	4
P-Pegalajar-Central	1500	300	2: 68, 69	3, 3
P-SierraPeñaDelÁguila	2500	500	4: 70, 71, 72, 73	2, 4, 2, 4
(*) Los tipos de secciones están ordenados según el sentido de la línea en el fichero original del MTN25.				

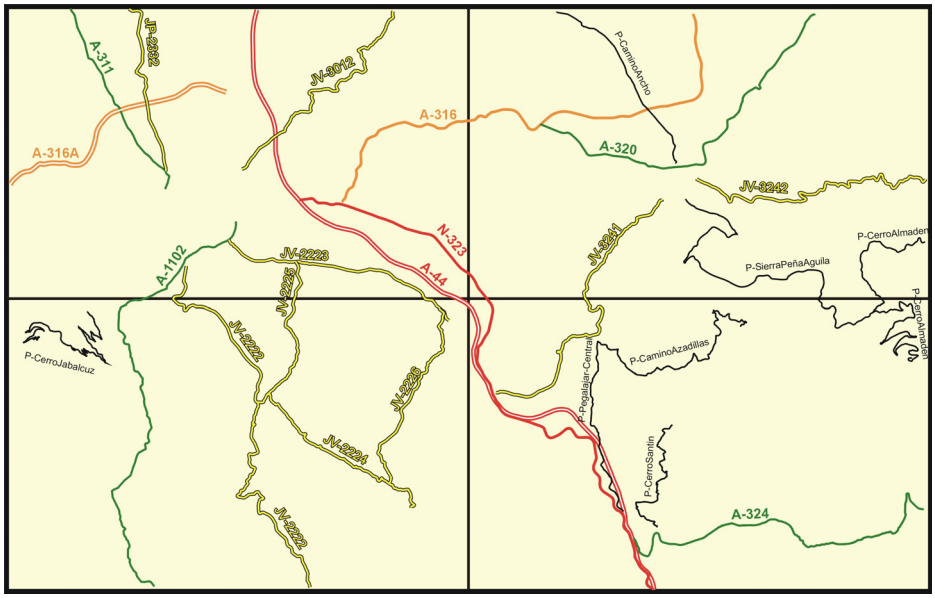


Figura IV.6 - Muestra de líneas original (no está a escala).

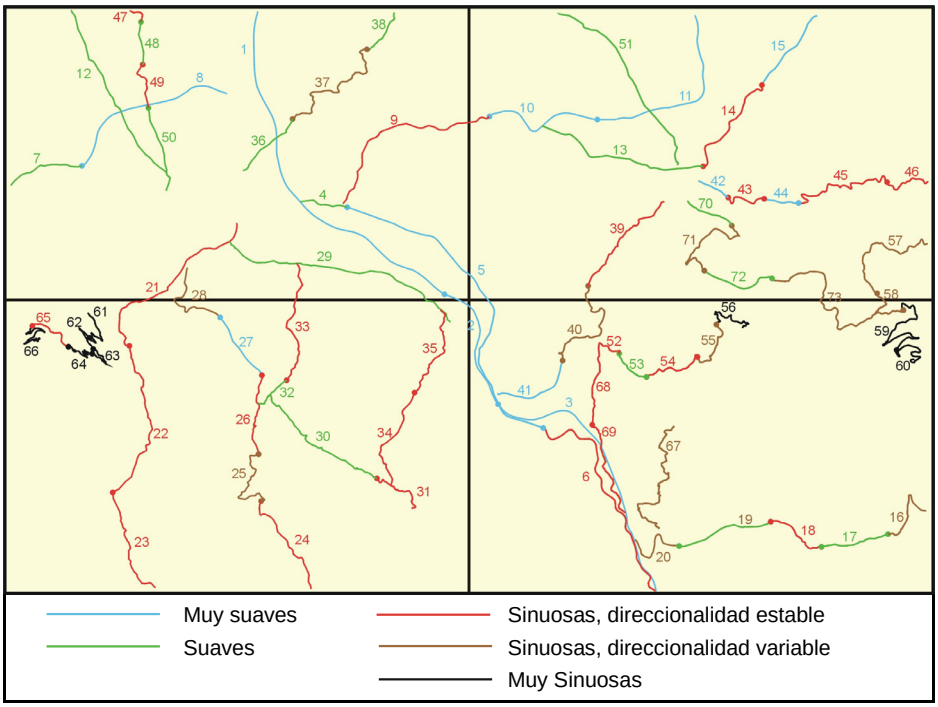


Figura IV.7 - Clasificación manual de las secciones. Ubicación relativa original (no está a escala).

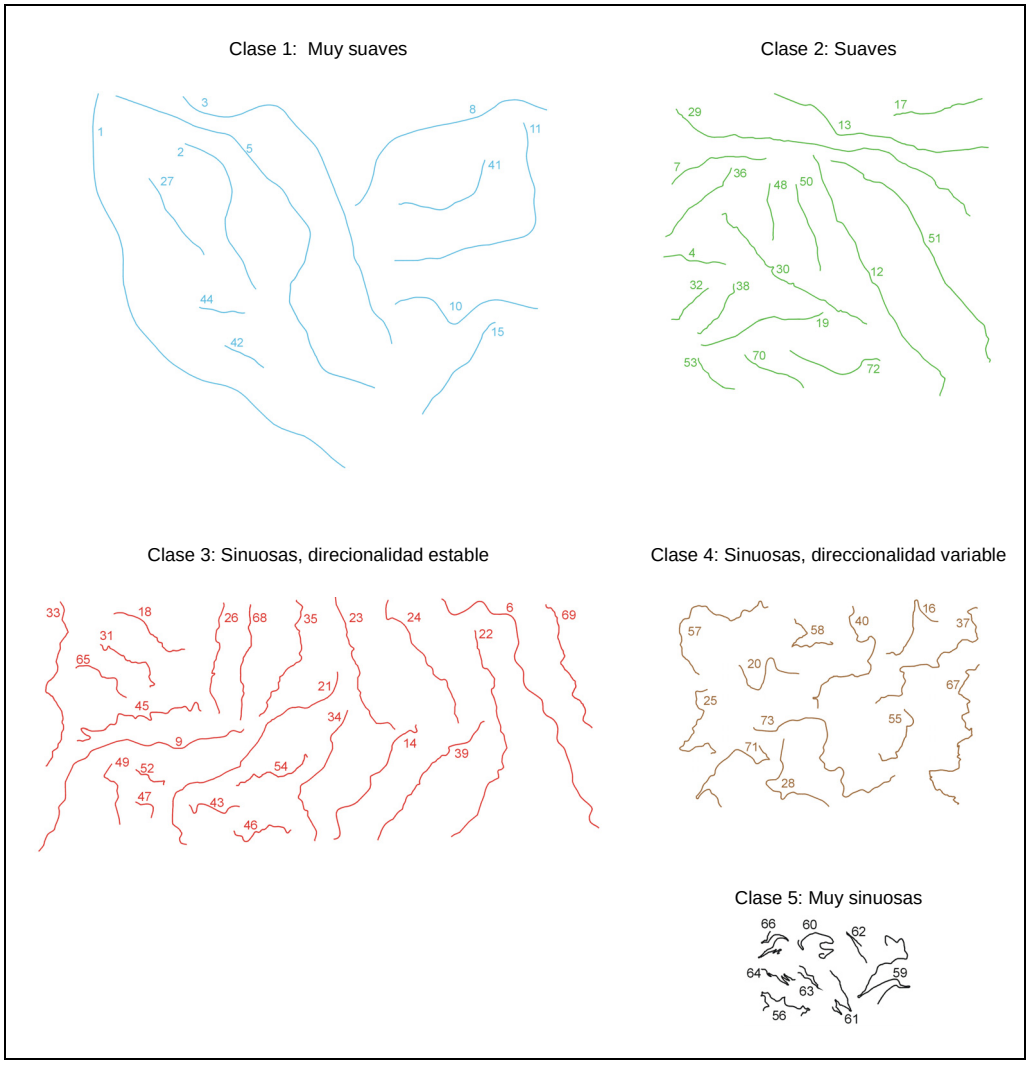


Figura IV.8 - Clasificación manual de las secciones. Secciones agrupadas (no está a escala).

IV.3.2. Análisis de Componentes Principales de las medidas caracterizadoras

Mediante el software SPSS 11 se ha sometido a un Análisis de Componentes Principales (ACP) al conjunto de medidas caracterizadoras enumeradas en la Tabla III.8 y calculadas para todas las secciones obtenidas en el apartado anterior, con el objetivo de detectar aquellas que aportan una mayor cantidad de información cuantitativa no correlada sobre cada sección de línea.

IV.3.2.1. Primer ACP

Los resultados indican que las 3 primeras componentes explican el 77% de la varianza y que las 6 primeras componentes, con valores propios superiores a la unidad, explican ya el 93% (ver Tabla IV.7). En la Tabla IV.8 se presenta la matriz factorial de estas 6 primeras componentes. No obstante, se ha realizado una rotación factorial mediante el método de rotación ortogonal varimax (Tabla IV.9), que facilita la interpretación al maximizar la varianza de las componentes.

Tabla IV.7 - Varianza explicada por las 6 primeras componentes.

Componente	eigenvalores		
	Total	% de la varianza	% acumulativo
1	8,585	34,342	34,342
2	7,226	28,903	63,245
3	3,506	14,025	77,270
4	1,587	6,349	83,619
5	1,196	4,785	88,404
6	1,143	4,574	92,978
7	0,501	2,006	94,983
8	0,305	1,221	96,204

Tabla IV.8 - Matriz factorial, para 6 componentes.

Variable		Componente					
		1	2	3	4	5	6
1	***LB***	-0,657	0,387	-0,400	0,153	0,085	-0,165
2	l_m	-0,105	0,886	0,407	-0,062	0,028	0,160
3	l_{me}	-0,050	0,910	0,343	-0,147	0,059	0,131
4	l_{cv}	-0,443	-0,368	0,437	0,644	-0,005	0,226
5	b_m	-0,128	0,887	0,386	-0,081	0,029	0,173
6	b_{me}	-0,077	0,904	0,335	-0,167	0,052	0,145
7	b_{cv}	-0,438	-0,356	0,416	0,650	0,026	0,224
8	h_m	0,093	0,821	0,497	0,110	0,030	0,068
9	h_{me}	0,207	0,877	0,326	0,019	0,113	0,018
10	h_{cv}	-0,519	-0,521	0,497	0,244	-0,043	0,150
11	lb_m	-0,881	0,105	-0,270	-0,189	-0,086	0,158
12	lb_{me}	-0,817	-0,227	0,088	-0,353	-0,184	0,216

Tabla IV.8 - Matriz factorial, para 6 componentes.

Variable		Componente					
		1	2	3	4	5	6
13	lb_{cv}	0,749	-0,345	0,479	-0,024	-0,009	-0,096
14	hb_{m}	0,891	-0,101	0,350	-0,002	-0,027	-0,183
15	hb_{me}	0,868	0,300	-0,107	0,296	0,117	-0,133
16	hb_{cv}	0,052	-0,636	0,684	-0,271	-0,091	-0,070
17	sb_{m}	0,751	-0,180	0,452	-0,159	-0,097	-0,213
18	sb_{me}	0,860	0,300	-0,107	0,295	0,134	-0,167
19	sb_{cv}	0,104	-0,624	0,686	-0,268	-0,125	-0,040
20	a_{m}	0,871	-0,047	-0,193	0,034	0,011	0,294
21	a_{me}	0,852	0,065	-0,258	0,071	-0,065	0,267
22	a_{cv}	-0,408	-0,468	0,306	-0,090	0,517	-0,190
23	c_{m}	0,626	-0,445	-0,147	-0,169	0,243	0,484
24	c_{me}	0,678	-0,418	-0,143	-0,136	-0,031	0,500
25	c_{cv}	-0,195	-0,292	0,023	-0,167	0,852	0,06

Tabla IV.9 - Matriz factorial rotada (método varimax), para 6 componentes.

Variable		Componente					
		1	2	3	4	5	6
1	***LB***	0,093	-0,272	-0,716	0,019	-0,449	0,043
2	l_{m}	0,982	-0,033	-0,097	-0,024	-0,108	-0,073
3	l_{me}	0,974	-0,012	-0,105	-0,146	-0,087	-0,048
4	l_{cv}	-0,093	-0,156	0,045	0,968	-0,108	0,054
5	b_{m}	0,978	-0,063	-0,117	-0,036	-0,101	-0,069
6	b_{me}	0,970	-0,049	-0,111	-0,151	-0,083	-0,047
7	b_{cv}	-0,091	-0,140	0,019	0,959	-0,105	0,077
8	h_{m}	0,931	0,219	0,016	0,075	-0,125	-0,104
9	h_{me}	0,897	0,309	-0,066	-0,131	-0,079	-0,053
10	h_{cv}	-0,174	-0,427	0,285	0,735	-0,138	0,137
11	lb_{m}	0,016	-0,802	-0,487	0,022	-0,213	0,024
12	lb_{me}	-0,068	-0,943	-0,004	0,141	-0,123	0,049
13	lb_{cv}	-0,087	0,508	0,772	0,030	0,236	0,007
14	hb_{m}	0,027	0,693	0,640	-0,142	0,203	-0,090
15	hb_{me}	0,136	0,924	-0,001	-0,200	0,211	-0,130
16	hb_{cv}	-0,196	-0,223	0,895	0,224	-0,012	0,150
17	sb_{m}	0,014	0,485	,772	-0,163	0,128	-0,081
18	sb_{me}	0,130	0,932	-0,001	-0,209	0,180	-0,111
19	sb_{cv}	-0,183	-0,197	0,910	0,218	0,033	0,106
20	a_{m}	-0,081	0,587	0,117	-0,211	0,674	-0,151
21	a_{me}	-0,036	0,602	0,024	-0,244	0,624	-0,254
22	a_{cv}	-0,219	-0,260	0,235	0,253	-0,266	0,696
23	c_{m}	-0,300	0,229	0,222	-0,105	0,829	0,209
24	c_{me}	-0,302	0,221	0,268	-0,098	0,836	-0,070
25	c_{cv}	-0,116	-0,101	-0,042	0,042	0,095	0,919
Nota: con fondo gris se señalan las variables con mayor saturación en las componentes 1 y 2, formadas por parejas de medidas de tendencia central de media y mediana.							

A la vista de la matriz factorial rotada de la Tabla IV.9, se pueden extraer primeramente conclusiones respecto a qué medidas de tendencia central de las planteadas, la media y la mediana, tienen una mayor significatividad. Plazanet et.al (1998) proponía la mediana frente a la media aritmética, pero sin ningún análisis estadístico que sustentara su propuesta. En los resultados del ACP se observan distintos comportamientos:

- En la componente 1 aparecen como variables saturadas las correspondientes a las medidas 2, 3, 5, 6, 8, y 9 (señaladas con fondo gris). Estas seis medidas, 3 parejas de media y mediana, están altamente correladas entre sí, ya que todas pretenden medir el tamaño medio de la curva de la sección, y por tanto la densidad de detalles en la sección. No obstante, lo importante es comprobar cómo la saturación de las variables correspondientes a los valores de media son superiores a los de mediana en los tres casos.
- En la componente 2 aparecen como variables saturadas las correspondientes a las medidas 11, 12, 14, 15, 17 y 18 (señaladas con fondo gris). La correlación existente entre estas 3 parejas de media y mediana es menor que la observada en las variables saturadas en la componente 1, pero todavía es importante. En este caso las medidas señaladas pretenden extraer la forma típica de una curva de la sección. La diferencia entre la saturación de las variables correspondientes a valores de mediana y mediana se hace más patente, pero siendo en este caso es la mediana que siempre muestra una mayor saturación.

A la vista de estos resultados, se propone realizar un nuevo ACP, esta vez seleccionando una única medida de tendencia central, media o mediana, para una determinada variable cuantificada en una curva de la sección:

- En el caso de medidas de densidad (las saturadas en la componente 1) se escogerá la media.
- Para las medidas de forma (las saturadas en la componente 2) se escogerá la mediana.
- Para la pareja de medidas 20, 21, media y mediana de la angularidad respectivamente, es complicado extraer alguna conclusión ya que muestran saturaciones similares en las componentes 2 y 5, mayor en la mediana en la componente 2, y mayor en la media en la componente 5. Es por ello por lo que se incluirán ambas en el nuevo ACP.
- La pareja de medidas 23, 24, media y mediana de la curvatura, aparecen saturadas en la componente 5, siendo mayor la saturación de la mediana, que será la que se seleccionará.

IV.3.2.2. Segundo ACP. Interpretación de componentes

Tras realizar el nuevo ACP eliminando las variables señaladas, los resultados indican que las 3 primeras componentes explican el 75% de la varianza y que las 5 primeras componentes, con eigenvalores superiores a la unidad, explican el 89% (ver Tabla IV.10). En la Tabla IV.11 se presenta la matriz factorial de estas 6 primeras componentes. Se ha realizado de nuevo una rotación factorial mediante el método de rotación ortogonal varimax, que se presenta en la Tabla IV.12.

Tabla IV.10 - Varianza explicada por las 6 primeras componentes (segundo ACP)

Componente	eigenvalores		
	Total	% de la varianza	% acumulativo
1	6,501	36,115	36,115
2	4,551	25,283	61,398
3	2,403	13,348	74,746
4	1,445	8,029	82,774
5	1,144	6,353	89,127
6	0,746	4,145	93,272
7	0,372	2,064	95,337
8	0,256	1,425	96,761

Tabla IV.11 - Matriz factorial, para 5 componentes (segundo ACP)

Variable		Componente				
		1	2	3	4	5
1	***LB***	-0,352	-0,731	-0,365	0,187	0,072
2	l_m	0,115	-0,723	0,630	-0,168	0,031
4	l_{cv}	-0,635	0,218	0,349	0,636	-0,075
5	b_m	0,100	-0,736	0,605	-0,179	0,026
7	b_{cv}	-0,621	0,208	0,331	0,650	-0,046
8	h_m	0,243	-0,582	0,745	-0,035	0,070
10	h_{cv}	-0,777	0,345	0,279	0,242	-0,085
12	lb_{me}	-0,835	-0,107	-0,142	-0,296	-0,281
13	lb_{cv}	0,409	0,709	0,439	-0,115	0,070
15	hb_{me}	0,910	0,059	0,151	0,246	0,191
16	hb_{cv}	-0,367	0,737	0,397	-0,321	-0,024
18	sb_{me}	0,904	0,055	0,146	0,243	0,219
19	sb_{cv}	-0,314	0,755	0,419	-0,322	-0,062
20	a_m	0,821	0,380	-0,027	0,092	-0,043
21	a_{me}	0,864	0,257	-0,051	0,123	-0,108
22	a_{cv}	-0,627	0,317	0,029	-0,093	0,540
24	c_{me}	0,496	0,652	-0,121	-0,029	-0,184
25	c_{cv}	-0,314	0,185	-0,177	-0,057	0,777

Tabla IV.12 - Matriz factorial rotada (método varimax), para 5 componentes (segundo ACP)

Variable		Componente				
		1	2	3	4	5
1	***LB***	-0,397	-0,806	0,127	0,033	0,088
2	l_m	-0,029	-0,133	0,961	-0,084	-0,110
4	l_{cv}	-0,198	0,078	-0,028	0,965	0,059
5	b_m	-0,054	-0,150	0,951	-0,097	-0,110
7	b_{cv}	-0,178	0,051	-0,033	0,960	0,082
8	h_m	0,187	-0,035	0,954	0,026	-0,109
10	h_{cv}	-0,466	0,309	-0,106	0,723	0,140
12	lb_{me}	-0,936	0,018	-0,088	0,105	-0,014
13	lb_{cv}	0,518	0,782	-0,047	0,010	0,018
15	hb_{me}	0,946	-0,018	0,127	-0,178	-0,095
16	hb_{cv}	-0,242	0,891	-0,130	0,207	0,168
18	sb_{me}	0,945	-0,025	0,129	-0,181	-0,066
19	sb_{cv}	-0,202	0,918	-0,125	0,195	0,118
20	a_m	0,788	0,215	-0,217	-0,247	-0,232
21	a_{me}	0,791	0,106	-0,170	-0,271	-0,321
22	a_{cv}	-0,351	0,243	-0,133	0,250	0,730
24	c_{me}	0,472	0,437	-0,477	-0,166	-0,228
25	c_{cv}	-0,066	-0,0034	-0,160	0,016	0,861
Nota: con fondo gris se señalan los valores de saturación superiores a 0,7 en cada componente.						

El análisis de la nueva matriz factorial rotada (Tabla IV.12) parece muy esclarecedor, pudiendo realizar la siguiente interpretación de las componentes:

- **Componente 1.** Las variables saturadas en esta componente son las número 12, 15 y 18, y algo menos las 20 y 21. Las tres primeras son variables que tratan de describir las proporciones de la curva y por tanto su forma. Por tanto la componente 1 podría ser denominada "forma y angularidad de las curvas".

- **Componente 2.** Aparecen saturadas las variables 13, 16 y 19, correspondientes a la medida de la dispersión de las proporciones de la curva saturadas en la componente 1. No obstante, también aparece saturada la variable 1, que relaciona la longitud curvilínea de la sección con la longitud rectilínea entre el inicio y final, esto es, su tendencia rectilínea. Así, la componente 2 podría ser denominada "dispersión de la forma de las curvas y tendencia rectilínea de la sección"

- **Componente 3.** La saturación se concentra en las variables 2, 5 y 8, que se corresponden con la media del tamaño de las curvas, y por tanto con la densidad de curvas en la sección. De esta forma la componente 3 podría ser denominada "densidad de curvas en la sección".

- **Componente 4.** En este caso la saturación se localiza en medidas de dispersión de las variables saturadas en la componente 3, concretamente en las variables 4 y 7. La componente 4 podría ser denominada "dispersión de la densidad de curvas en la sección".
- **Componente 5.** Las variables saturadas son la 25, que mide la dispersión en la curvatura, y en menor medida la 22, que mide la dispersión en la angularidad. La componente 5 podría ser denominada "dispersión en curvatura y angularidad".

IV.3.2.3. Análisis de correlaciones. Selección definitiva de variables

Recordando que el objetivo del ACP es la selección de un conjunto de medidas significativas no correladas, es necesario detectar la correlación existente entre el conjunto de 16 medidas seleccionadas, para escoger las de mayor saturación en caso de una correlación elevada. En la Tabla IV.13 se presenta la tabla de correlación correspondiente, señalando con fondo gris las correlaciones mayores a 0,7.

Tabla IV.13 - Matriz de correlación de las 16 variables seleccionadas tras el ACP

		1	*2*	*4*	*5*	*7*	*8*	*12*	*13*	*15*	*16*	*18*	*19*	*20*	*21*	*22*	*25*
1	***LB***	**1,000**	0,214	0,041	0,231	0,057	0,084	0,342	-0,785	-0,349	-0,545	-0,346	-0,619	-0,519	-0,427	-0,024	0,078
2	l_m	0,214	**1,000**	-0,107	0,999	-0,104	0,924	-0,033	-0,206	0,092	-0,287	0,092	-0,280	-0,159	-0,095	-0,247	-0,190
4	l_{cv}	0,041	-0,107	**1,000**	-0,115	0,983	-0,041	0,322	-0,026	-0,385	0,315	-0,392	0,300	-0,361	-0,404	0,373	0,117
5	b_m	0,231	0,999	-0,115	**1,000**	-0,109	0,904	-0,009	-0,239	0,068	-0,298	0,069	-0,291	-0,172	-0,107	-0,244	-0,182
7	b_{cv}	0,057	-0,104	0,983	-0,109	**1,000**	-0,059	0,295	-0,053	-0,367	0,301	-0,369	0,285	-0,355	-0,399	0,382	0,130
8	h_m	0,084	0,924	-0,041	0,904	-0,059	**1,000**	-0,228	0,039	0,295	-0,223	0,282	-0,213	-0,025	0,028	-0,275	-0,235
12	lb_{me}	0,342	-0,033	0,322	-0,009	0,295	-0,228	**1,000**	-0,468	-0,941	0,241	-0,962	0,211	-0,656	-0,681	0,333	0,173
13	lb_{cv}	-0,785	-0,206	-0,026	-0,239	-0,053	0,039	-0,468	**1,000**	0,491	0,582	0,479	0,619	0,522	0,433	0,019	-0,061
15	hb_{me}	-0,349	0,092	-0,385	0,068	-0,367	0,295	-0,941	0,491	**1,000**	-0,301	0,988	-0,250	0,713	0,742	-0,476	-0,217
16	hb_{cv}	-0,545	-0,287	0,315	-0,298	0,301	-0,223	,0241	0,582	-0,301	**1,000**	-0,296	0,980	-0,063	-0,174	0,467	0,164
18	sb_{me}	-0,346	0,092	-0,392	0,069	-0,369	0,282	-0,962	0,479	0,988	-0,296	**1,000**	-0,252	0,695	0,728	-0,449	-0,211
19	sb_{cv}	-0,619	-0,280	0,300	-0,291	,285	-0,213	0,211	0,619	-0,250	0,980	-0,252	**1,000**	-0,023	-0,132	0,403	0,131
20	a_m	-0,519	-0,159	-0,361	-0,172	-0,355	-0,025	-0,656	0,522	0,713	-0,063	0,695	-0,023	**1,000**	0,975	-0,422	-0,111
21	a_{me}	-0,427	-0,095	-0,404	-0,107	-0,399	0,028	-0,681	0,433	0,742	-0,174	0,728	-0,132	0,975	**1,000**	-0,545	-0,197
22	a_{cv}	-0,024	-0,247	0,373	-0,244	0,382	-0,275	0,333	0,019	-0,476	0,467	-0,449	0,403	-0,422	-0,545	**1,000**	0,526
25	c_{cv}	0,078	-0,190	0,117	-0,182	0,130	-0,235	0,173	-0,061	-0,217	0,164	-0,211	0,131	-0,111	-0,197	0,526	**1,000**
Nota: con fondo gris se señalan los coeficientes de correlación superiores a 0,7.																	

A la vista de los coeficientes de correlación de la Tabla IV.13 se establecen las siguientes conclusiones para cada componente:

- **Componente 1.** Existe una correlación casi absoluta entre las variables 12, 15 y 18. Dado que la saturación en la componente 1 es similar en las tres, se

escogerá la que presenta menor saturación en el resto de componentes, que en este caso será la **variable 12**. Las variables 20 y 21 muestran también una correlación muy elevada, entre sí, y más moderada con las variables 15 y 18. Se escogerá la **variable 20**, por mostrar una mayor saturación y por exhibir coeficientes de correlación menores con estas dos variables.

- **Componente 2.** Se observa una correlación casi absoluta entre las variables 16 y 19, de las que se escogerá la **variable 19**, pues muestra una mayor saturación en esta componente. Las **variables 1 y 13** muestran una correlación menor pero todavía importante; no obstante, se ha considerado interesante conservar ambas, pues su interpretación geométrica es muy diferente.
- **Componente 3.** Se presenta una correlación casi absoluta entre las variables 2, 5 y 8, por lo que se seleccionará la de mayor saturación, en este caso la **variable 2**.
- **Componente 4.** Se presenta una correlación casi absoluta entre las variables 4 y 7, por lo que se seleccionará la de mayor saturación, en este caso la **variable 7**.
- **Componente 5.** La correlación entre las **variables 22 y 25** no es elevada por lo que se seleccionarán ambas.

Por tanto las medidas seleccionadas son: 1(***LB***), 2($\boldsymbol{l_m}$), 7($\boldsymbol{b_{cv}}$), 12($\boldsymbol{lb_{me}}$), 13($\boldsymbol{lb_{cv}}$), 19($\boldsymbol{sb_{cv}}$), 20($\boldsymbol{a_m}$), 22($\boldsymbol{a_{cv}}$) y 25($\boldsymbol{c_{cv}}$). En la Tabla IV.14 se resumen cuáles son las medidas que se han seleccionado para cada una de las componentes detectadas mediante el ACP.

Tabla IV.14 - Medidas caracterizadoras seleccionadas

Componente	Interpretación	Medidas seleccionadas
1	forma y angularidad de las curvas	$\boldsymbol{lb_{me}}$, $\boldsymbol{a_m}$
2	dispersión de la forma de las curvas y tendencia rectilínea de la sección	***LB***, $\boldsymbol{lb_{cv}}$, $\boldsymbol{sb_{cv}}$
3	densidad de curvas en la sección	$\boldsymbol{l_m}$
4	dispersión de la densidad de curvas en la sección	$\boldsymbol{b_{cv}}$
5	dispersión en curvatura y angularidad	$\boldsymbol{a_{cv}}$, $\boldsymbol{c_{cv}}$

IV.3.3. Red Neuronal de clasificación de líneas

IV.3.3.1. Creación de los patrones de entrenamiento y prueba

El total de secciones de línea disponibles tras la segmentación semiautomática y clasificación de experto es de 73 (véanse las tablas IV.5 y IV.6). Este conjunto de secciones ha de ser dividido en varios conjuntos para poner en práctica con posterioridad una validación cruzada que permita detectar cuál cantidad de neuronas ocultas es la más idónea para reducir el error de la red neuronal a la hora de clasificar las secciones. Dado que una de las clases de sección (clase 5, "muy sinuosas") tiene 8 muestras, se pretende aplicar la validación cruzada estratificada con 8 pliegues (k = 8), lo que garantiza que en todos los conjuntos existan muestras de todas las clases.

De esta manera, se crearán 8 conjuntos, 7 de los cuales estarán formados por 9 secciones y 1 estará integrado por 10 secciones, sumando en total las 73 disponibles. La distribución de las secciones en los conjuntos se realizará de forma aleatoria estratificada. Así, se asegurará que en los conjuntos los estratos estén homogéneamente representados, tal y como se indica en la Tabla IV.15. La selección aleatoria de secciones se presenta en la Tabla IV.16.

Tabla IV.15 - Número de secciones por estrato (clase) en cada conjunto.

		Grupos estratificados en la validación cruzada								
		C1	**C2**	**C3**	**C4**	**C5**	**C6**	**C7**	**C8**	**TOTAL**
Clase de sinuosidad	**1:** muy suaves	1	1	1	1	2	2	2	2	12
	2: suaves	2	2	2	2	2	2	2	3	17
	3: sinuosas, direccionalidad estable	3	3	3	3	3	3	3	3	24
	4: sinuosas, direccionalidad variable	2	2	2	2	1	1	1	1	12
	5: muy sinuosas	1	1	1	1	1	1	1	1	8
	TOTAL secciones por grupo	9	9	9	9	9	9	9	10	73

Tabla IV.16 - Secciones por estrato (clase) y conjunto (asignación aleatoria).

	Conj. 1	**Conj. 2**	**Conj. 3**	**Conj. 4**	**Conj. 5**	**Conj. 6**	**Conj. 7**	**Conj. 8**
Clase 1	8	44	41	15	11, 42	1, 3	5, 27	2, 10
Clase 2	19, 48	36, 38	13, 17	7, 29	4, 12	30, 50	32, 53	51, 70, 72
Clase 3	26, 33, 43	34, 35, 46	18, 52, 65	31, 39, 47	9, 24, 69	23, 54, 68	14, 22, 45	6, 21, 49
Clase 4	28, 67	57, 71	16, 37	20, 25	58	73	40	55
Clase 5	60	64	62	59	61	66	56	63
Nota: los valores son los índices de las secciones								

Tras la selección aleatoria estratificada de las secciones pertenecientes a cada uno de los 8 conjuntos, y dado que se va a realizar una validación cruzada con ellos, será necesario establecer 8 archivos de patrón de entrenamiento (cada uno con 7 conjuntos de entrenamiento) y 8 archivos de patrón de prueba (cada uno con 1 conjunto de prueba), en el formato propio de JavaNNS, conforme se expone en la Tabla IV.17.

Tabla IV.17 - Conjuntos presentes en cada patrón de entrenamiento y de prueba

Patrón	Conjuntos en patrón de entrenamiento								Conjuntos en patrón de prueba
1		2	3	4	5	6	7	8	1
2	1		3	4	5	6	7	8	2
3	1	2		4	5	6	7	8	3
4	1	2	3		5	6	7	8	4
5	1	2	3	4		6	7	8	5
6	1	2	3	4	5		7	8	6
7	1	2	3	4	5	6		8	7
8	1	2	3	4	5	6	7		8

IV.3.3.2. Estructura y aprendizaje de la red neuronal

Tal y como se ha comentado en el apartado de metodología, se pretende utilizar una red de tipo Backpropagation, de 3 capas, debiendo entrever además cuál es el tamaño óptimo de la capa oculta de la red neuronal. Así, en JavaNNS se han creado varias redes neuronales con diferente número de neuronas ocultas (1 a 6), manteniendo el número de neuronas de entrada y de salida (en este caso, 14 y 5, respectivamente). En todas las neuronas de las tres capas se han considerado funciones de transferencia o activación de tipo sigmoidal, *logistic* en JavaNNS. La función de salida en todos los casos ha sido la función identidad.

Como función de aprendizaje se ha empleado la de la regla delta generalizada más la adición de un momento, que en JavaNNS se indica como *Backprop-Momentum* (véase la Figura IV.9). Como parámetros que gobiernan el aprendizaje se han empleado exclusivamente la tasa de aprendizaje α y la influencia del momento β. Los parámetros *c* y *dmax* no se han considerado (su valor se ha fijado en 0), y se han dejado para casos con problemas de convergencia, que finalmente no se han producido. Los valores de α y β empleados han sido los que sugiere el programa por defecto: un valor bajo, de 0,2, para el primero y un va-

lor de 0,5 para el segundo. En principio, el número de iteraciones introducido ha sido elevado (5000) para poder observar si se estabiliza el aprendizaje

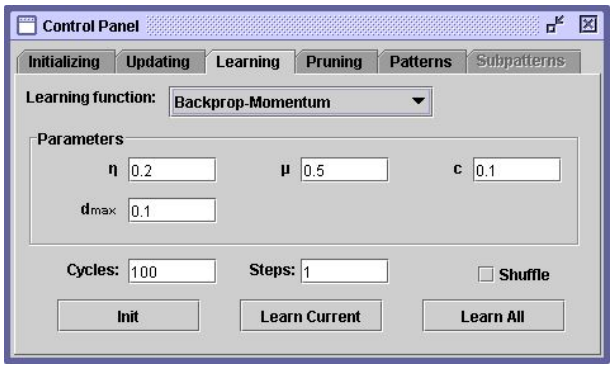


Figura IV.9 - Panel de control de JavaNNS. Pestaña de aprendizaje. La tasa de aprendizaje se simboliza con η y la influencia del momento con μ.

Dado que se pretende detectar cuál es el número más adecuado de neuronas ocultas, sobre cada una de las redes propuestas se ha repetido el proceso de validación cruzada mediante los 8 patrones de aprendizaje y prueba que han sido preparados, lo que ha llevado a realizar 8 ciclos completos de aprendizaje.

Los valores de los pesos tras el aprendizaje, así como la convergencia de éste, se ven muy influenciados por los valores de inicialización que son asignados de forma aleatoria. Se ha comprobado que reiterados procesos de aprendizaje realizados sobre la misma red con el mismo patrón, producen resultados diferentes en el sentido anteriormente apuntado. Esto introduce la necesidad de repetir varias veces el aprendizaje, sobre cada conjunto de patrones entrenamiento-prueba, hasta que sea aceptado como válido. Así, se han tenido en cuenta las siguientes premisas, que se han considerado como necesarias para un correcto aprendizaje, a partir de la observación de la gráfica de error que JavaNNS presenta (ver Figura IV.10), y que muestra tanto el error que se produce en el patrón de entrenamiento como en el patrón de validación:

- La evolución del error en el patrón de aprendizaje debe mostrar una clara tendencia descendente.
- El error en el patrón de aprendizaje debe ser bajo, pero no necesariamente cercano a 0, ya que esto podría indicar sobreentrenamiento.

- El error en el patrón de validación deberá mostrar una tendencia descendente y ser lo más bajo posible. El valor mínimo del error indicará el momento en que la red tiene una mayor capacidad de generalización.

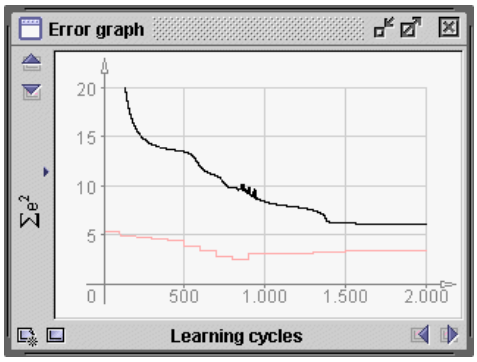


Figura IV.10 - Gráfica de error generada por JavaNNS durante el aprendizaje de una red neuronal. El eje X representa el número de iteraciones realizadas y el eje Y el error alcanzado en las salidas de la red neuronal. En negro se representa el error sobre el patrón de entrenamiento y en gris sobre el patrón de validación.

Resultados del aprendizaje

Antes de efectuar la validación cruzada de alguna de las arquitecturas propuestas para la red neuronal, se ha efectuado un estudio preliminar para rechazar aquellas cuyo comportamiento se adivinara claramente inferior al de otras. Para ello se ha analizado el aprendizaje de las distintas redes a través de la gráfica de error, empleando uno de los patrones de aprendizaje y uno de los de prueba, empleando este último como patrón de validación en JavaNNS.

Ya se ha indicado que los valores aleatorios de inicialización influyen sobremanera en el posterior aprendizaje. No obstante, aquí se indicarán los comportamientos generales que se han observado durante las diferentes tentativas realizadas sobre cada una de las arquitecturas planteadas, mediante un número elevado de iteraciones (5000), utilizando el patrón de entrenamiento 1 (64 casos) y el patrón de prueba 1 (9 casos), y cuyas gráficas de error pueden observarse en la Figura IV.11:

- 1 neurona oculta (19 conexiones neuronales): El aprendizaje de la red se estabiliza demasiado pronto, con un error del patrón de entrenamiento aún

muy elevado. Posiblemente se deba a que el número de conexiones neuronales sea insuficiente. El error sobre el patrón de validación permanece siempre muy estable. Se rechaza esta estructura para realizar sobre ella la validación cruzada.

- 2 neuronas ocultas (38 conexiones neuronales): El aprendizaje se estabiliza en torno a un valor de error del patrón de entrenamiento de 15. El error en el patrón de validación muestra tendencia descendente durante todo el aprendizaje. Se propone realizar en esta estructura la validación cruzada.
- 3 neuronas ocultas (57 conexiones neuronales): El error del patrón de entrenamiento tiende a la estabilización ligeramente por encima de un error de 10. El error en el patrón de validación muestra tendencia descendente, más acusada que en la arquitectura anterior. También esta estructura se propone para realizar la validación cruzada.
- 4 neuronas ocultas (76 conexiones neuronales): En este caso, el error del patrón de entrenamiento ya disminuye por debajo de 5 unidades. El hecho de que el número de conexiones neuronales (76) sea superior al número de casos del patrón de entrenamiento (64), puede provocar problemas de sobreentrenamiento de la red, memorizando este patrón, y perdiendo su capacidad de adaptación a nuevas situaciones. No obstante, en la gráfica se observa que aún no se produce un aumento del error en el patrón de validación. También se propone realizar la validación cruzada sobre esta estructura.
- 5 neuronas ocultas (95 conexiones neuronales): En esta estructura, el número de conexiones supera ampliamente al de casos del patrón de entrenamiento. Es aún más fácil que aparezcan problemas de sobreentrenamiento. En la gráfica se observa cómo el error del patrón de entrenamiento desciende hasta un valor casi nulo y que el del patrón de validación permanece bajo, aunque con una tendencia estable. Dado que todavía no se observan claros problemas en el entrenamiento también se someterá esta arquitectura a la validación cruzada.
- 6 neuronas ocultas (114 conexiones neuronales): Al igual que en la arquitectura de 5 neuronas, el error del patrón de entrenamiento es prácticamente nulo, mientras en el caso del patrón de validación, el error pasa a ser de ten-

dencia ascendente. Se descartará esta arquitectura para realizar la validación cruzada.

Por tanto las arquitecturas sobre las que se ha efectuado el aprendizaje mediante una validación cruzada han sido las que incluyen 2 a 5 neuronas. Todas las gráficas de error de cada arquitectura y de cada aprendizaje (uno por cada par de patrones entrenamiento-prueba) pueden visualizarse en el Anexo C.

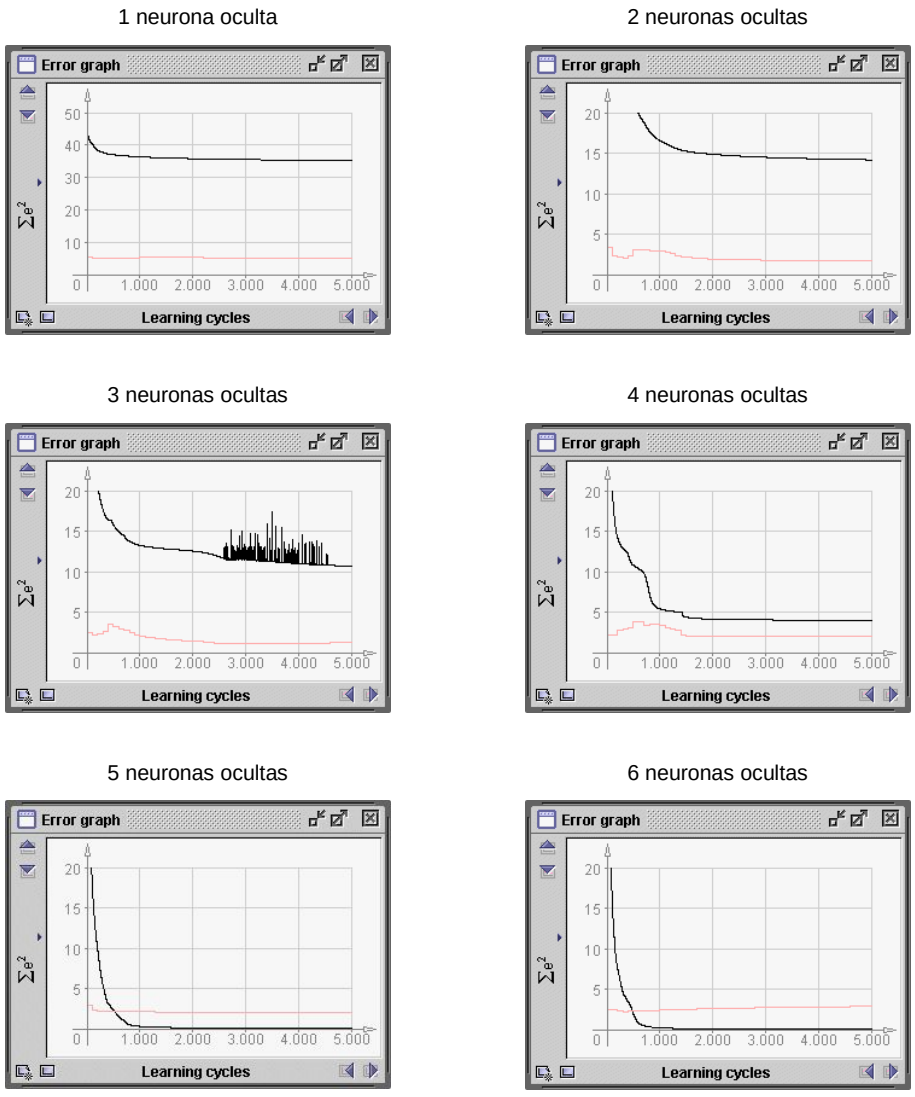


Figura IV.11 - Ejemplos de gráficas de error del aprendizaje realizado sobre las diferentes arquitecturas neuronales planteadas mediante 5000 iteraciones (se han empleado el patrón de entrenamiento 1 y el patrón de prueba 1).

IV.3.3.3. Validación de las redes neuronales

Tras el empleo de una red neuronal para clasificar los distintos patrones, los valores de las neuronas de salida sirven para estimar la probabilidad de pertenencia a cada clase. Como cada una de las neuronas de salida representa a cada una de las clases, se ha seguido el criterio de asignar la clase de la neurona con mayor valor.

Una vez realizada la asignación para todas las secciones de la muestra, es necesario examinar cuál ha sido el grado de acierto de la clasificación que la red neuronal ha efectuado de forma automática. Para ello, en cada arquitectura se ha calculado una matriz de confusión. Por columnas se tienen las clases asignadas a priori, mientras que por filas se presentan las clases asignadas a posteriori por la red neuronal. En la diagonal se encuentran los casos clasificados correctamente, mientras que fuera de ella se localizan las equivocaciones.

Además, sobre la matriz se han calculado el índice global correspondiente al porcentaje de acuerdo (PA), así como los índices por clase relativos a exactitud del usuario (EU) y exactitud del productor (EP) (ver Ariza, 2002). En este caso se debe entender que el productor es el que ha realizado la clasificación a priori para alimentar la red neuronal, mientras el usuario es aquel que disfruta de la clasificación automática realizada por la red.

No obstante, no sólo es interesante evaluar el resultado a partir de las asignaciones realizadas de forma correcta o incorrecta, sino que también lo es el comparar el valor de todas las neuronas de salida, para así distinguir diversos grados de consistencia de la clasificación realizada. Así, una activación cercana a 1,0 en una neurona de salida y a 0,0 en el resto significaría una predicción fuerte, mientras valores cercanos a 0,5 en varias neuronas evidenciarían la incapacidad de la red de efectuar una predicción fuerte (Dennis y McAuley, 1997). En el presente trabajo se seguirán los siguientes criterios:

- Se considerará que se ha realizado una clasificación fuerte de una sección cuando el valor de una de las neuronas de salida sea mayor a 0,7, y el resto próximos a cero, menores a 0,1.

- Se considerará que se ha realizado una clasificación moderada de una sección cuando se cumplan las siguientes premisas: el valor de una de las neuronas de salida será elevado, mayor a 0,7; existirán neuronas con valor mayor a 0,1; la diferencia entre la neurona con mayor valor y el resto de neuronas deberá ser mayor a 0,25.
- Se considerará que se ha realizado una clasificación débil de una sección en el resto de casos.
- Si se presenta un caso en el que ninguna neurona alcanza un valor mayor a 0,1, no se asignará la sección a ninguna de las clases, indicándose en ese caso que está sin clasificar (SC).
- Por otro lado, si existen dos o más neuronas con valores mayores a 0,1 y cuya diferencias sean menores a 0,5, se considerará que el clasificador muestra cierta indeterminación al asignar la sección a esas clases, estableciéndose la existencia de "interferencia" entre clases.

A continuación se presentan una serie de tablas que resumen los resultados de la clasificación de cada arquitectura. Así, para cada una se incluyen las siguientes:

- Tabla con los resultados pormenorizados de la clasificación. En ella se presentan correlativamente los resultados para los 8 conjuntos de secciones, indicando, para cada sección, su número de sección, la clase a la que pertenece, la clase a la que ha sido asignada por la red neuronal, el tipo de clasificación efectuada (fuerte, moderada o débil) y en su caso, entre qué clases se han detectado interferencias.
- Tabla resumen de los tipos de clasificación realizados, así como de los tipos de interferencia detectados.
- Tabla que presenta la matriz de confusión de la clasificación.
- Tabla con los índices cuantitativos por cada clase, calculados a partir de la matriz de confusión.

Tabla IV.18 - Clasificación efectuada mediante la arquitectura de 2 neuronas

	Sección	Clase	Clasificación de la red		
			Clase	Tipo	Interferencias
Conjunto 1	8	1	1	fuerte	
	19	2	2	fuerte	
	48	2	2	moderada	1 y 2
	26	3	3	fuerte	
	33	3	3	fuerte	
	43	3	3	fuerte	
	28	4	4	débil	
	67	4	4	débil	
	60	5	5	débil	4 y 5
Conjunto 2	44	1	1	débil	1 y 2
	36	2	1	débil	1 y 2
	38	2	2	débil	1 y 2
	34	3	3	débil	
	35	3	3	fuerte	
	36	3	3	fuerte	
	57	4	4	débil	
	71	4	4	débil	4 y 5
	64	5	5	débil	4 y 5
Conjunto 3	41	1	1	fuerte	
	13	2	2	fuerte	
	17	2	2	débil	
	18	3	3	moderada	2 y 3
	52	3	3	moderada	2 y 3
	65	3	3	moderada	2 y 3
	16	4	4	débil	
	37	4	3	débil	3 y 4
	62	5	5	débil	4 y 5
Conjunto 4	15	1	1	moderada	1 y 2
	7	2	1	moderada	1 y 2
	29	2	2	débil	
	31	3	3	moderada	2 y 3
	39	3	3	moderada	2 y 3
	47	3	3	moderada	2 y 3
	20	4	3	moderada	
	25	4	4	débil	
	59	5	5	moderada	4 y 5
Conjunto 5	11	1	1	fuerte	
	42	1	2	débil	2 y 3
	4	2	2	moderada	1 y 2
	12	2	2	moderada	1 y 2
	9	3	3	fuerte	
	24	3	3	fuerte	
	69	3	3	fuerte	
	58	4	5	débil	4 y 5
	61	5	5	débil	4 y 5
Conjunto 6	1	1	1	fuerte	
	3	1	1	fuerte	
	30	2	3	débil	2 y 3
	50	2	2	moderada	1 y 2
	23	3	3	moderada	3 y 4
	54	3	3	moderada	3 y 4
	68	3	3	débil	2 y 3
	73	4	3	débil	3 y 4
	66	5	5	fuerte	
Conjunto 7	5	1	1	débil	
	27	1	2	moderada	1 y 2
	32	2	2	moderada	1 y 2
	53	2	2	moderada	1 y 2
	14	3	3	fuerte	
	22	3	3	fuerte	
	45	3	3	fuerte	
	40	4	4	fuerte	
	56	5	5	débil	4 y 5
Conjunto 8	2	1	1	fuerte	
	10	1	1	fuerte	
	51	2	-	-	
	70	2	1	débil	
	72	2	1	fuerte	
	6	3	3	moderada	
	21	3	3	fuerte	
	49	3	3	fuerte	
	55	4	4	débil	
	63	5	5	moderada	4 y 5

Tabla IV.19 - Resumen de tipos de clasificación en la arquitectura de 2 neuronas.

Tipo		Casos	%
fuerte	acierta	24	32,9%
moderada	acierta	17	23,3%
débil	acierta	18	24,7%
fuerte	falla	1	1,4%
moderada	falla	3	4,1%
débil	falla	9	12,3%
Total		72	98,6%

Tabla IV.20 - Resumen de tipos de interferencia en la arquitectura de 2 neuronas.

Interferencia	Casos	%
1 - 2	12	16,4%
2 - 3	7	9,6%
3 - 4	2	2,7%
4 - 5	9	12,3%
Total	30	41,1%

Tabla IV.21 - Matriz de confusión de la arquitectura de 2 neuronas.

	1	**2**	**3**	**4**	**5**	**Total**
1	10	4				14
2	2	11	2			15
3		1	22	3		26
4				8		8
5				1	8	9
SC		1				
Total	12	16	24	12	8	72
PA = 0,81						

Tabla IV.22 - Índices por clase de la matriz de confusión de la arquitectura de 2 neuronas.

Clase	EP	EU
1	0,83	0,71
2	0,69	0,85
3	1,00	0,86
4	0,67	1,00
5	1,00	0,89

Tabla IV.23 - Clasificación efectuada mediante la arquitectura de 3 neuronas

	Sección	Clase	Clasificación de la red		
			Clase	Tipo	Interferencias
Conjunto 1	8	1	1	fuerte	
	19	2	2	fuerte	
	48	2	2	moderada	
	26	3	3	fuerte	
	33	3	3	fuerte	
	43	3	3	fuerte	
	28	4	4	débil	
	67	4	4	débil	
	60	5	5	moderada	4 y 5
Conjunto 2	44	1	1	fuerte	
	36	2	2	fuerte	
	38	2	2	moderada	
	34	3	2	débil	2 y 3
	35	3	3	fuerte	
	36	3	3	fuerte	
	57	4	4	débil	
	71	4	5	moderada	4 y 5
	64	5	5	moderada	4 y 5
Conjunto 3	41	1	1	fuerte	
	13	2	2	fuerte	
	17	2	2	fuerte	
	18	3	3	fuerte	
	52	3	3	fuerte	
	65	3	3	fuerte	
	16	4	4	moderada	
	37	4	3	fuerte	
	62	5	5	moderada	4 y 5
Conjunto 4	15	1	2	moderada	1 y 2
	7	2	2	débil	1 y 2
	29	2	2	débil	2 y 3
	31	3	3	fuerte	
	39	3	2	débil	1 y 2
	47	3	3	fuerte	
	20	4	3	fuerte	
	25	4	3	fuerte	
	59	5	5	fuerte	
Conjunto 5	11	1	1	fuerte	
	42	1	2	moderada	
	4	2	2	moderada	
	12	2	2	fuerte	
	9	3	3	fuerte	
	24	3	3	fuerte	
	69	3	3	fuerte	
	58	4	4	fuerte	
	61	5	5	débil	4 y 5
Conjunto 6	1	1	1	fuerte	
	3	1	2	moderada	
	30	2	3	fuerte	
	50	2	2	moderada	1 y 2
	23	3	3	fuerte	
	54	3	3	fuerte	
	68	3	3	fuerte	
	73	4	4	fuerte	
	66	5	5	fuerte	
Conjunto 7	5	1	1	fuerte	
	27	1	1	fuerte	
	32	2	3	moderada	
	53	2	2	fuerte	
	14	3	3	moderada	
	22	3	3	moderada	
	45	3	3	moderada	
	40	4	4	fuerte	
	56	5	5	débil	4 y 5
Conjunto 8	2	1	1	fuerte	
	10	1	1	fuerte	
	51	2	2	débil	1 y 2
	70	2	3	débil	
	72	2	5	débil	
	6	3	3	moderada	
	21	3	3	fuerte	
	49	3	2	débil	
	55	4	4	fuerte	
	63	5	5	moderada	

Tabla IV.24 - Resumen de tipos de clasificación en la arquitectura de 3 neuronas.

Tipo	Casos	%
fuerte acierta	38	52,1%
moderada acierta	13	17,8%
débil acierta	8	11,0%
fuerte falla	4	5,5%
moderada falla	5	6,8%
débil falla	5	6,8%
Total	73	100%

Tabla IV.25 - Resumen de tipos de interferencia en la arquitectura de 3 neuronas.

Interferencia	Casos	%
1 - 2	5	6,8%
2 - 3	2	2,7%
3 - 4	0	0,0%
4 - 5	6	8,2%
Total	13	17,8%

Tabla IV.26 - Matriz de confusión de la arquitectura de 3 neuronas.

	1	**2**	**3**	**4**	**5**	**Total**
1	9					9
2	3	13	3			19
3		3	21	3		27
4				8		8
5		1		1	8	10
SC						
Total	12	17	24	12	8	73
PA = 0,81						

Tabla IV.27 - Índices por clase de la matriz de confusión de la arquitectura de 3 neuronas.

Clase	EP	EU
1	0,83	0,71
2	0,69	0,85
3	1,00	0,86
4	0,67	1,00
5	1,00	0,89

Tabla IV.28 - Clasificación efectuada mediante la arquitectura de 4 neuronas

	Sección	Clase	Clasificación de la red		
			Clase	Tipo	Interferencias
Conjunto 1	8	1	1	fuerte	
	19	2	2	fuerte	
	48	2	2	fuerte	
	26	3	3	fuerte	
	33	3	3	fuerte	
	43	3	3	fuerte	
	28	4	4	fuerte	
	67	4	4	fuerte	
	60	5	5	fuerte	
Conjunto 2	44	1	1	fuerte	
	36	2	2	fuerte	
	38	2	2	fuerte	
	34	3	3	moderada	2 y 3
	35	3	3	fuerte	
	36	3	3	fuerte	
	57	4	4	fuerte	
	71	4	5	fuerte	
	64	5	5	fuerte	
Conjunto 3	41	1	1	fuerte	
	13	2	2	moderada	
	17	2	2	moderada	
	18	3	3	fuerte	
	52	3	3	fuerte	
	65	3	3	fuerte	
	16	4	4	fuerte	
	37	4	3	fuerte	
	62	5	5	fuerte	
Conjunto 4	15	1	2	fuerte	
	7	2	2	fuerte	
	29	2	2	fuerte	
	31	3	3	fuerte	
	39	3	2	fuerte	
	47	3	3	débil	3 - 4
	20	4	4	fuerte	
	25	4	5	moderada	4 - 5
	59	5	5	fuerte	
Conjunto 5	11	1	1	moderada	
	42	1	3	débil	2 y 3
	4	2	2	fuerte	
	12	2	2	fuerte	
	9	3	3	fuerte	
	24	3	3	fuerte	
	69	3	3	moderada	
	58	4	4	fuerte	
	61	5	5	fuerte	
Conjunto 6	1	1	1	fuerte	
	3	1	1	fuerte	
	30	2	2	débil	2 y 3
	50	2	1	moderada	1 y 2
	23	3	3	fuerte	
	54	3	3	moderada	
	68	3	2	moderada	
	73	4	3	débil	3 y 4
	66	5	5	fuerte	
Conjunto 7	5	1	1	fuerte	
	27	1	1	fuerte	
	32	2	3	fuerte	
	53	2	3	fuerte	
	14	3	2	débil	2 y 3
	22	3	3	fuerte	
	45	3	3	moderada	
	40	4	4	fuerte	
	56	5	5	moderada	
Conjunto 8	2	1	1	fuerte	
	10	1	2	moderada	1 y 2
	51	2	2	fuerte	
	70	2	3	moderada	
	72	2	1	débil	
	6	3	1	débil	
	21	3	3	débil	
	49	3	3	débil	3 y 4
	55	4	4	fuerte	
	63	5	4	débil	4 y 5

Tabla IV.29 - Resumen de tipos de clasificación en la arquitectura de 4 neuronas.

Tipo		Casos	%
fuerte	acierta	44	60,3%
moderada	acierta	8	11,0%
débil	acierta	4	5,5%
fuerte	falla	6	8,2%
moderada	falla	5	6,8%
débil	falla	6	8,2%
Total		73	100%

Tabla IV.30 - Resumen de tipos de interferencia en la arquitectura de 4 neuronas.

Interferencia	Casos	%
1 - 2	2	2,7%
2 - 3	4	5,5%
3 - 4	3	4,1%
4 - 5	2	2,7%
Total	11	15,1%

Tabla IV.31 - Matriz de confusión de la arquitectura de 4 neuronas.

	1	**2**	**3**	**4**	**5**	**Total**
1	9	2	1			12
2	2	12	3			17
3	1	3	20	2		26
4				8	1	9
5				2	7	9
SC						0
Total	12	17	24	12	8	73
PA = 0,77						

Tabla IV.32 - Índices por clase de la matriz de confusión de la arquitectura de 4 neuronas.

Clase	EP	EU
1	0,75	0,75
2	0,71	0,71
3	0,83	0,77
4	0,67	0,89
5	0,88	0,78

Tabla IV.33 - Clasificación efectuada mediante la arquitectura de 5 neuronas

	Sección	Clase	Clasificación de la red		
			Clase	Tipo	Interferencias
Conjunto 1	8	1	1	fuerte	
	19	2	2	fuerte	
	48	2	2	fuerte	
	26	3	3	moderada	
	33	3	3	fuerte	
	43	3	3	fuerte	
	28	4	3	fuerte	
	67	4	4	fuerte	
	60	5	5	fuerte	
Conjunto 2	44	1	1	débil	
	36	2	2	fuerte	
	38	2	3	débil	
	34	3	3	débil	2 y 3
	35	3	3	fuerte	
	36	3	3	moderada	
	57	4	4	fuerte	
	71	4	4	moderada	
	64	5	5	fuerte	
Conjunto 3	41	1	1	fuerte	
	13	2	2	fuerte	
	17	2	2	moderada	
	18	3	3	fuerte	
	52	3	3	fuerte	
	65	3	3	fuerte	
	16	4	4	fuerte	
	37	4	3	fuerte	
	62	5	5	fuerte	
Conjunto 4	15	1	2	fuerte	
	7	2	2	fuerte	
	29	2	3	débil	2 y 3
	31	3	3	moderada	
	39	3	2	fuerte	
	47	3	3	moderada	3 y 4
	20	4	3	moderada	
	25	4	3	moderada	
	59	5	5	fuerte	
Conjunto 5	11	1	1	débil	1 y 3
	42	1	2	débil	
	4	2	2	fuerte	
	12	2	2	fuerte	
	9	3	3	fuerte	
	24	3	3	fuerte	
	69	3	3	fuerte	
	58	4	4	fuerte	
	61	5	5	moderada	
Conjunto 6	1	1	1	fuerte	
	3	1	1	fuerte	
	30	2	3	fuerte	
	50	2	2	fuerte	
	23	3	3	fuerte	
	54	3	3	moderada	
	68	3	2	fuerte	
	73	4	4	moderada	
	66	5	5	fuerte	
Conjunto 7	5	1	1	fuerte	
	27	1	2	moderada	1 y 2
	32	2	2	fuerte	
	53	2	3	moderada	
	14	3	3	fuerte	
	22	3	SC		
	45	3	4	fuerte	
	40	4	4	fuerte	
	56	5	5	fuerte	
Conjunto 8	2	1	2	moderada	1 y 2
	10	1	2	débil	2 y 5
	51	2	2	fuerte	
	70	2	2	fuerte	
	72	2	2	fuerte	
	6	3	SC		
	21	3	3	fuerte	
	49	3	3	fuerte	
	55	4	4	fuerte	
	63	5	5	fuerte	

Tabla IV.34 - Resumen de tipos de clasificación en la arquitectura de 5 neuronas.

Tipo		Casos	%
fuerte	acierta	43	58,9%
moderada	acierta	9	12,3%
débil	acierta	3	4,1%
fuerte	falla	7	9,6%
moderada	falla	5	6,8%
débil	falla	4	5,5%
Total		71	97,3%

Tabla IV.35 - Resumen de tipos de interferencia en la arquitectura de 5 neuronas.

Interferencia	Casos	%
1 - 2	2	2,7%
2 - 3	2	2,7%
3 - 4	1	1,4%
4 - 5	0	0,0%
1 - 3	1	1,4%
2 - 5	1	1,4%
Total	7	9,6%

Tabla IV.36 - Matriz de confusión de la arquitectura de 5 neuronas.

	1	**2**	**3**	**4**	**5**	**Total**
1	7					7
2	5	13	2			20
3		4	19	4		27
4			1	8		9
5					8	8
SC			2			
Total	12	17	22	12	8	71
PA = 0,77						

Tabla IV.37 - Índices por clase de la matriz de confusión de la arquitectura de 5 neuronas.

Clase	EP	EU
1	0,58	1,00
2	0,76	0,65
3	0,86	0,70
4	0,67	0,89
5	1,00	1,00

Análisis de los resultados sobre las distintas arquitecturas

En la Tabla IV.38 se resumen una serie de medidas derivadas de los resultados de la clasificación realizada mediante cada arquitectura. Las medidas van a permitir comparar los tipos de clasificaciones efectuadas (fuertes, moderadas, débiles), la presencia de interferencias entre clases, así como el grado de acierto en la clasificación teniendo en cuenta su distribución entre los diferentes tipos de clasificación.

Tabla IV.38 - Comparación de medidas de la clasificación realizada por las distintas arquitecturas.

Medida	2 neuronas	3 neuronas	4 neuronas	5 neuronas
Clasificaciones fuertes	34,3%	57,6%	68,5%	68,5%
Clasificaciones moderadas	27,4%	24,6%	17,8%	19,2%
Clasificaciones débiles	37,0%	17,8%	13,7%	9,6%
Interferencias totales	41,1%	17,8%	15,1%	9,6%
Aciertos débiles	24,7%	11,0%	5,5%	4,1%
Aciertos fuertes y moderados	56,2%	69,9%	71,2%	71,2%
Aciertos fuertes, moderados y débiles	80,9%	80,9%	76,7%	75,3%
Fallos débiles	12,3%	6,8%	8,2%	5,5%
Fallos fuertes y moderados	5,5%	12,3%	15,1%	16,4%
Entradas sin clasificar	1,3%	0%	0%	2,7%

Así, de la lectura de la Tabla IV.38 se pueden advertir las siguientes tendencias conforme se aumenta el número de neuronas de la capa oculta.:

- Se observa una clara tendencia a aumentar el número de clasificaciones fuertes, y disminuir el resto, siendo semejantes los resultados de las arquitecturas de 4 y 5 neuronas.
- Las interferencias entre las clasificaciones realizadas disminuyen. Este hecho está relacionado con el aumento de clasificaciones fuertes.
- Los aciertos fuertes y moderados no son elevados en la arquitectura de 2 neuronas, con el 56,2%, pero se estabilizan a partir de 3 neuronas en torno al 70%.
- El número total de aciertos, que incluye los derivados de clasificaciones débiles, es más elevado en el caso de 2 y 3 neuronas (80,9%) que en el de 3 y 4 neuronas (76,7% y 75,3% respectivamente).
- La presencia de fallos fuertes y moderados aumenta, con tendencia a la estabilización en torno al 15% en los casos de 4 y 5 neuronas.
- El número de casos sin clasificar es reducido, existiendo 1 caso en la red de 2 neuronas y 2 casos en la de 5 neuronas.

Particularizando al caso de cada arquitectura, se observan los siguientes resultados:

- **Red de 2 neuronas ocultas.** Aunque se trata de la arquitectura, junto con la de 3 neuronas, en la que el número de aciertos es mayor (80,9%), sin embargo, se caracteriza por mostrar el menor número de clasificaciones de

carácter fuerte o moderado, así como por un elevado número de interferencias (41,1%). A su favor también hay que señalar el reducido número de fallos de carácter fuerte o moderado (5,5%). No obstante, esta arquitectura evidencia, sin lugar a dudas, los peores resultados.

- **Red de 3 neuronas ocultas.** El número de aciertos total es el mayor (80,9%), junto a la de 2 neuronas, con la diferencia de que la proporción de casos fuertes o moderados es mucho mayor (69,9%), y similar a las arquitecturas de 4 y 5 neuronas (71,2%). Otro de sus rasgos positivos es que el número de fallos fuertes o moderados (12,3%) es inferior al caso de 4 ó 5 neuronas. El número de interferencias (17,8%) baja sustancialmente respecto a la arquitectura de 2 neuronas, pero es superior al de las de 4 ó 5 neuronas.
- **Red de 4 neuronas ocultas.** El número de aciertos totales (76,7%) es algo inferior al de las arquitecturas de 2 ó 3 neuronas, aunque la proporción de casos fuertes o moderados es mayor (71,2%) e igual a la presentada por la arquitectura de 5 neuronas. El número de fallos fuertes o moderados (15,1%) es superior al de las arquitecturas de 2 y 3 neuronas, pero el número de interferencias (15,1%) baja levemente respecto a la de 2 neuronas.
- **Red de 5 neuronas ocultas.** El número de aciertos totales (75,3%) es el más bajo de las arquitecturas probadas, aunque la proporción de casos fuertes o moderados es el mayor (71,2%), compartido con la arquitectura de 2 neuronas. Como rasgo positivo destacable, comentar que el número de interferencias totales es el inferior (9,6%), y como rasgo negativo que muestra el mayor porcentaje de fallos fuertes o moderados (16,4%).

A la hora de seleccionar una de las arquitecturas ensayadas, en principio, se podría establecer una serie de criterios de interés:

- Interesa que la red neuronal sea lo más asertiva posible, que no muestre duda a la hora de señalar la clase a la que pertenece la entrada, y por tanto las interferencias entre las neuronas de salida sean mínimas.

- Es obvio que se debe maximizar la presencia de aciertos, sobre todo de fuertes y moderados. Al mismo tiempo se debe minimizar la presencia de fallos, sobre todo de fuertes y moderados.
- Siempre es preferible el menor número de neuronas ocultas posible, porque cada una de ellas supone una mayor carga de procesamiento en el caso de una simulación por software (Hilera y Martínez, 1995), como es el caso de este trabajo.

A la vista de los resultados evidenciados por cada arquitectura, la **red de 3 neuronas ocultas** muestra aspectos que permiten vislumbrar un equilibrio entre la búsqueda del máximo número de aciertos y el mínimo número de fallos, al tiempo que el número de interferencias no se dispara en exceso, y el número de conexiones neuronales es mucho más reducido que en los casos de 4 ó 5 neuronas ocultas.

Análisis de los resultados sobre los distintos patrones

A lo largo de los procesos de entrenamiento de las diferentes arquitecturas se han empleado diferentes patrones de validación en un proceso de validación cruzada, y es interesante detectar y analizar los casos de secciones de líneas que la red ha clasificado en una categoría diferente a la original.

En la Tabla IV.39 se presentan los índices por clase de las matrices de confusión de las arquitecturas de 3 a 5 neuronas, habiéndose descartado analizar la arquitectura de 2 neuronas por sus pobres resultados. Para interpretarla, es adecuado recordar el concepto de exactitud del productor (EP) y del usuario (EU). La EP es el porcentaje de casos, respecto al total que definían una clase a priori, que la red ha clasificado en esa misma clase; la diferencia respecto a la unidad es útil para conocer qué porcentaje de casos de una clase se han fugado a otra tras la clasificación. La EU es el porcentaje de líneas, respecto al total que la red ha clasificado en una clase a posteriori, que habían sido definidas en esa misma clase a priori; la diferencia respecto a la unidad es útil para conocer qué porcentaje de casos que se han asignado a una clase procedían de otras clases.

Tabla IV.39 - Errores del productor y del usuario de las clasificaciones efectuadas.

Clase	3 neuronas		4 neuronas		5 neuronas	
	EP	EU	EP	EU	EP	EU
1	0,83	0,71	0,75	0,75	0,58	1,00
2	0,69	0,85	0,71	0,71	0,76	0,65
3	1,00	0,86	0,83	0,77	0,86	0,70
4	0,67	1,00	0,67	0,89	0,67	0,89
5	1,00	0,89	0,88	0,78	1,00	1,00

Así, la lectura de los resultados de EP y EU viene a señalar las siguientes conclusiones:

- Las arquitecturas de 3 y 4 neuronas muestran resultados más similares entre sí que la de 5 neuronas, que pueden variar sustancialmente para alguna clase.
- Los mejores valores de EP son los referidos a las clases 3 y 5, que por tanto tienden a conservar la clase asignada a priori.
- Los peores valores de EP vienen dados por las clases 2 y 4, que por tanto tienden a emitir mayor cantidad de casos hacia otras clases tras la clasificación.
- Los mejores valores de EU son los relativos a las clases 4 y 5, que por tanto no tienden a recibir casos procedentes de otras clases.
- Según los valores mínimos de EU, no se percibe ninguna clase que sobresalga respecto a las demás en cuanto a un fuerte comportamiento receptor.
- La clase que muestra menos problemas, al tener valores elevados tanto en EP como en EU es la clase 5.
- La clase que muestra más problemas, al tener valores reducidos tanto en EP como en EU es la clase 2. Revisando la clasificación, se comprueba que sus principales fugas se dirigen hacia la clase 3 y sus principales admisiones proceden de las clases 1 y 3. Revisando la clasificación realizada a priori, la clase 2 (líneas suaves) se encuentra entre las clases 1 (muy suaves) y 3 (sinuosas, con direccionalidad estable). Podría pensarse, por tanto, que la eliminación de la clase 2 y la reasignación de sus secciones hacia las clases 1 ó 3 podría aumentar la exactitud de la clasificación realizada por la red.

En la Tabla IV.40 se presenta de forma conjunta para las arquitecturas de 3 a 5 neuronas cuáles han sido las clasificaciones realizadas para cada sección, indicando el tipo de clasificación (fuerte, moderada, débil). Las confusiones evidenciadas en esta tabla permiten la búsqueda de secciones de línea que, según la clasificación efectuada tras el aprendizaje de las tres redes, deberían haber estado asignadas a otra clase en la fase de clasificación preliminar de las secciones mediante el análisis visual

Tabla IV.40 - Clasificación realizada por las arquitecturas de 3 a 5 neuronas para cada sección de la muestra.

	Sección	Clase	3 neuronas		4 neuronas		5 neuronas	
			Clase	Tipo	Clase	Tipo	Clase	Tipo
Conjunto 1	8	1	1	fuerte	1	fuerte	1	fuerte
	19	2	2	fuerte	2	fuerte	2	fuerte
	48	2	2	moderada	2	fuerte	2	fuerte
	26	3	3	fuerte	3	fuerte	3	moderada
	33	3	3	fuerte	3	fuerte	3	fuerte
	43	3	3	fuerte	3	fuerte	3	fuerte
	28	4	4	débil	4	fuerte	3	fuerte
	67	4	4	débil	4	fuerte	4	fuerte
	60	5	5	moderada	5	fuerte	5	fuerte
Conjunto 2	44	1	1	fuerte	1	fuerte	1	débil
	36	2	2	fuerte	2	fuerte	2	fuerte
	38	2	2	moderada	2	fuerte	3	débil
	34	3	2	débil	3	moderada	3	débil
	35	3	3	fuerte	3	fuerte	3	fuerte
	36	3	3	fuerte	3	fuerte	3	moderada
	57	4	4	débil	4	fuerte	4	fuerte
	71	4	5	moderada	5	fuerte	4	moderada
	64	5	5	moderada	5	fuerte	5	fuerte
Conjunto 3	41	1	1	fuerte	1	fuerte	1	fuerte
	13	2	2	fuerte	2	moderada	2	fuerte
	17	2	2	fuerte	2	moderada	2	moderada
	18	3	3	fuerte	3	fuerte	3	fuerte
	52	3	3	fuerte	3	fuerte	3	fuerte
	65	3	3	fuerte	3	fuerte	3	fuerte
	16	4	4	moderada	4	fuerte	4	fuerte
	37	4	3	fuerte	3	fuerte	3	fuerte
	62	5	5	moderada	5	fuerte	5	fuerte
Conjunto 4	15	1	2	moderada	2	fuerte	2	fuerte
	7	2	2	débil	2	fuerte	2	fuerte
	29	2	2	débil	2	fuerte	3	débil
	31	3	3	fuerte	3	fuerte	3	moderada
	39	3	2	débil	2	fuerte	2	fuerte
	47	3	3	fuerte	3	débil	3	moderada
	20	4	3	fuerte	4	fuerte	3	moderada
	25	4	3	fuerte	5	moderada	3	moderada
	59	5	5	fuerte	5	fuerte	5	fuerte
Conjunto 5	11	1	1	fuerte	1	moderada	1	débil
	42	1	2	moderada	3	débil	2	débil
	4	2	2	moderada	2	fuerte	2	fuerte
	12	2	2	fuerte	2	fuerte	2	fuerte
	9	3	3	fuerte	3	fuerte	3	fuerte
	24	3	3	fuerte	3	fuerte	3	fuerte
	69	3	3	fuerte	3	moderada	3	fuerte
	58	4	4	fuerte	4	fuerte	4	fuerte
	61	5	5	débil	5	fuerte	5	moderada
Conjunto 6	1	1	1	fuerte	1	fuerte	1	fuerte
	3	1	2	moderada	1	fuerte	1	fuerte
	30	2	3	fuerte	2	débil	3	fuerte
	50	2	2	moderada	1	moderada	2	fuerte
	23	3	3	fuerte	3	fuerte	3	fuerte
	54	3	3	fuerte	3	moderada	3	moderada
	68	3	3	fuerte	2	moderada	2	fuerte
	73	4	4	fuerte	3	débil	4	moderada
	66	5	5	fuerte	5	fuerte	5	fuerte
Conjunto 7	5	1	1	fuerte	1	fuerte	1	fuerte
	27	1	1	fuerte	1	fuerte	2	moderada
	32	2	3	moderada	3	fuerte	2	fuerte
	53	2	2	fuerte	3	fuerte	3	moderada
	14	3	3	moderada	2	débil	3	fuerte
	22	3	3	moderada	3	fuerte	SC	
	45	3	3	moderada	3	moderada	4	fuerte
	40	4	4	fuerte	4	fuerte	4	fuerte
	56	5	5	débil	5	moderada	5	fuerte
Conjunto 8	2	1	1	fuerte	1	fuerte	2	moderada
	10	1	1	fuerte	2	moderada	2	débil
	51	2	2	débil	2	fuerte	2	fuerte
	70	2	3	débil	3	moderada	2	fuerte
	72	2	5	débil	1	débil	2	fuerte
	6	3	3	moderada	1	débil	SC	
	21	3	3	fuerte	3	débil	3	fuerte
	49	3	2	débil	3	débil	3	fuerte
	55	4	4	fuerte	4	fuerte	4	fuerte
	63	5	5	moderada	4	débil	5	fuerte

Grises: oscuro - clasificaciones fuertes, intermedio - moderadas, claro - débiles

Para detectar un cambio de clase de una sección se atenderá al número de redes que están indicando el cambio a una misma clase y al tipo de clasificación de cada una (fuerte, moderada, débil). Así, el caso de cambio más evidente será aquel en el que las tres redes estén sugiriendo un cambio a una misma clase con clasificaciones fuertes (por ejemplo, la sección 37, del conjunto 3), pero se señalará un cambio en cuanto existan dos redes con relaciones fuertes o moderadas que sugieran el cambio a una misma clase. En la Tabla IV.41 se exponen las líneas sobre las que se ha detectado un posible cambio de clase, que será además sometido a un breve análisis.

Tabla IV.41 - Secciones sobre las que se ha detectado un posible cambio de clase.

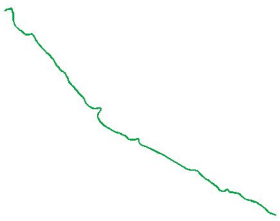
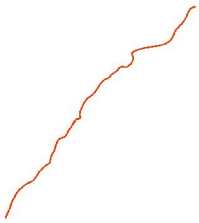
	**Sección 15** Clase anterior: 1 (muy suave) Nueva clase propuesta: 2 (suave) Ésta es una sección de carretera de la Red Intercomarcal con un trazado suave, pero quizá con una longitud de las curvas insuficiente para la categoría 1. **Sí se realizará el cambio de clase propuesto**
	**Sección 30** Clase anterior: 2 (suave) Nueva clase propuesta: 3 (sinuosa, direccionalidad estable) Se trata de una sección de carretera de la Red Provincial, de una clara tendencia direccional y suave, pero que contiene curvas de radio muy reducida en su intersección con la red fluvial. **Sí se realizará el cambio de clase propuesto**
	**Sección 32** Clase anterior: 2 (suave) Nueva clase propuesta: 3 (sinuosa, direccionalidad estable) En este caso la sección es parte de una carretera de la Red Provincial. Su pequeña longitud puede haber resaltado la influencia de la curva pronunciada de uno de sus extremos, pero no cabe calificarla de sinuosa. **No se realizará el cambio de clase propuesto**
	**Sección 53** Clase anterior: 2 (suave) Nueva clase propuesta: 3 (sinuosa, direccionalidad estable) Es una pequeña sección de pista que no cabe calificar como sinuosa, ya que su trazado es moderadamente suave. **No se realizará el cambio de clase propuesto**

Tabla IV.41 - Secciones sobre las que se ha detectado un posible cambio de clase.

	**Sección 39** Clase anterior: 3 (sinuosa, direccionalidad estable) Nueva clase propuesta: 2 (suave) Esta sección de una carretera de la Red Provincial tiene tendencia direccional estable, pero con continuas curvas de radio reducido que impiden calificarla como suave. **No se realizará el cambio de clase propuesto**
	**Sección 68** Clase anterior: 3 (sinuosa, direccionalidad estable) Nueva clase propuesta: 2 (suave) Esta sección de pista tiene tendencia direccional estable, pero con continuas curvas de radio reducido que impiden calificarla como suave. **No se realizará el cambio de clase propuesto**
	**Sección 71** Clase anterior: 4 (sinuosa, direccionalidad variable) Nueva clase propuesta: 5 (muy sinuosa) Se trata de una sección de pista con tendencia direccional muy variable y con radios de curvatura muy reducidos en ocasiones. **Sí se realizará el cambio de clase propuesto**
	**Sección 37** Clase anterior: 4 (sinuosa, direccionalidad variable) Nueva clase propuesta: 3 (sinuosa, direccionalidad estable) La sección de carretera de la Red Provincial muestra una sucesión de curvas de distintos radios de curvatura, pero con una tendencia direccional moderadamente marcada. **Sí se realizará el cambio de clase propuesto**
	**Sección 20** Clase anterior: 4 (sinuosa, direccionalidad variable) Nueva clase propuesta: 3 (sinuosa, direccionalidad estable) Se trata de una sección de carretera de la Red Intercomarcal, que se corresponde con una reforma de un antiguo trazado. No muestra radios de curvatura muy reducidos y su direccionalidad puede no ser tan variable como para pertenecer a la categoría 4. **Sí se realizará el cambio de clase propuesto**
	**Sección 25** Clase anterior: 4 (sinuosa, direccionalidad variable) Nueva clase propuesta: 3 (sinuosa, direccionalidad estable) La sección de esta pista muestra cambios bruscos de dirección que no inducen a apuntar a una direccionalidad estable. **No se realizará el cambio de clase propuesto**

Así, de igual manera que la red ha aprendido a clasificar secciones en función del aprendizaje a que ha sido sometida, es posible aprender de la red y modificar la entrada según lo expuesto en la Tabla IV.41. Bajo este supuesto se procederá a modificar los patrones con los que ha sido realizada la validación cruzada y se volverá a entrenar la red, en este caso la arquitectura elegida, de 3 neuronas ocultas.

Se deberán modificar las tablas IV.15 y IV.16, para establecer la nueva estratificación. Esta modificación de la estratificación se alterará lo menos posible, procurando además mantener el mismo número de secciones en cada uno de los 8 conjuntos. Así, la nueva estratificación viene dada en las tablas IV.42 y IV.43.

Tabla IV.42 - Nueva estratificación del número de secciones de cada clase en cada conjunto.

	Conj. 1	**Conj. 2**	**Conj. 3**	**Conj. 4**	**Conj. 5**	**Conj. 6**	**Conj. 7**	**Conj. 8**	**TOTAL**
Clase 1	1	1	1	1 (-1) (+1)	1 (-1)	2	2	2	11 (-1)
Clase 2	2	2	2	2	2	2 (-1) (+1)	2	3	17
Clase 3	3	4 (+1)	4 (+1)	3	4 (+1)	3	3	3	27 (+3)
Clase 4	2	1 (-1)	1 (-1)	1 (-1)	1	1	1	1	9 (-3)
Clase 5	1	1	1	2 (+1)	1	1	1	1	9 (+1)
TOTAL	9	9	9	9	9	9	9	10	73

Tabla IV.43 - Nueva distribución de secciones para cada conjunto.

	Conj. 1	**Conj. 2**	**Conj. 3**	**Conj. 4**	**Conj. 5**	**Conj. 6**	**Conj. 7**	**Conj. 8**	**TOTAL**
Clase 1	8	44	41	~~**15**~~, **11**	~~**11**~~, 42	1, 3	5, 27	2, 10	10
Clase 2	19, 48	36, 38	13, 17	7, 29	4, 12	**15**, ~~**30**~~, 50	32, 53	51, 70, 72	17
Clase 3	26, 33, 43	34, 35, 46, **37**	18, 52, 65, **20**	31, 39, 47	9, 24, 69, **30**	23, 54, 68	14, 22, 45	6, 21, 49	30
Clase 4	28, 67	57, ~~**71**~~	16, ~~**37**~~	~~**20**~~, 25	58	73	40	55	6
Clase 5	60	64	62	59, **71**	61	66	56	63	10

IV.3.3.4. Re-entrenamiento de la red de 3 neuronas ocultas

Una vez elegida como definitiva la estructura de 3 neuronas ocultas, y tras modificar los patrones de entrenamiento y de prueba según lo expuesto en las tablas IV.42 y IV.43, se ha procedido de nuevo a la validación cruzada de los 8 conjuntos de secciones. Así, en las tablas IV.44 a IV.49 se presentan los resultados de la nueva clasificación obtenida. Al final del Anexo C se presentan las gráficas de error correspondientes.

En la Tabla IV.49 se comparan las dos redes de 3 neuronas entrenadas por validación cruzada, de la misma forma que se ha hecho en la Tabla IV.38. En líneas generales el nuevo proceso de entrenamiento tras la modificación del patrón de entrada ha supuesto una mejora de los resultados:

- El número de clasificaciones fuertes ha pasado del 57,6% al 67,1%, reduciéndose el número de interferencias del 17,8% al 13,7%. Por tanto la red es ahora más asertiva.
- El número de aciertos fuertes y moderados ha aumentado, pasando del 69,9% al 71,2%, así como el número de aciertos totales, que sube del 80,9% al 82,2%.
- La presencia de fallos fuertes y moderados ha disminuido del 12,3% al 9,6%.
- 4 de las 5 secciones que habían sido sometidas a un cambio de clase han sido correctamente clasificadas (secciones 15, 37, 20, 71, frente a la 30).

Observando qué ha sucedido con cada uno de los patrones a través de los índices por clase de la exactitud temática, así como de la observación de la matriz de confusión se pueden derivar las siguientes conclusiones:

- Los mejores valores de EP son los referidos a las clases 2, 3 y 5, que por tanto tienden a conservar la clase asignada a priori.
- Los peores valores de EP vienen dados por la clase 1, que por tanto tiende a emitir mayor cantidad de casos hacia otras clases tras la clasificación.

Tabla IV.44 - Clasificación efectuada tras el nuevo entrenamiento de la arquitectura de 3 neuronas.

	Sección	Clase	Clasificación de la red		
			Clase	Tipo	Interferencias
Conjunto 1	8	1	1	fuerte	
	19	2	2	fuerte	
	48	2	2	fuerte	
	26	3	3	fuerte	
	33	3	3	fuerte	
	43	3	3	moderada	
	28	4	4	fuerte	
	67	4	4	débil	
	60	5	5	fuerte	
Conjunto 2	44	1	SC		
	36	2	2	fuerte	
	38	2	2	débil	
	34	3	3	débil	
	35	3	3	fuerte	
	46	3	3	fuerte	
	37	3	3	fuerte	
	57	4	4	fuerte	
	64	5	5	fuerte	
Conjunto 3	41	1	3	fuerte	
	13	2	2	moderada	
	17	2	2	moderada	
	18	3	3	fuerte	
	52	3	3	fuerte	
	65	3	3	fuerte	
	20	3	3	moderada	
	16	4	4	fuerte	
	62	5	5	fuerte	
Conjunto 4	11	1	3	fuerte	
	7	2	2	débil	1 - 2
	29	2	2	débil	2 - 3
	31	3	3	fuerte	
	39	3	2	débil	1 - 2
	47	3	3	fuerte	
	25	4	4	fuerte	
	59	5	5	fuerte	
	71	5	5	moderada	
Conjunto 5	42	1	1	débil	1 - 3
	4	2	2	fuerte	
	12	2	2	fuerte	
	9	3	3	fuerte	
	24	3	3	fuerte	
	69	3	3	fuerte	
	30	3	2	débil	1 - 2
	58	4	5	moderada	
	61	5	5	moderada	
Conjunto 6	1	1	1	fuerte	
	3	1	1	fuerte	
	15	2	2	fuerte	
	50	2	3	fuerte	
	23	3	3	fuerte	
	54	3	3	fuerte	
	68	3	1	débil	1 - 2
	73	4	4	fuerte	
	66	5	5	fuerte	
Conjunto 7	5	1	1	débil	1 - 2
	27	1	2	moderada	
	32	2	3	débil	2 - 3
	53	2	2	débil	2 - 3
	14	3	3	fuerte	
	22	3	3	fuerte	
	45	3	3	fuerte	
	40	4	4	fuerte	
	56	5	5	fuerte	
Conjunto 8	2	1	2	fuerte	
	10	1	1	fuerte	
	51	2	2	fuerte	
	70	2	2	fuerte	
	72	2	2	moderada	
	6	3	2	moderada	
	21	3	3	fuerte	
	49	3	3	fuerte	
	55	4	5	débil	4 - 5
	63	5	5	fuerte	

Tabla IV.45 - Resumen de tipos de clasificación tras el nuevo entrenamiento de la arquitectura de 3 neuronas.

Tipo		Casos	%
fuerte	acierta	43	61,6%
moderada	acierta	9	9,6%
débil	acierta	3	11,0%
fuerte	falla	7	5,5%
moderada	falla	5	4,1%
débil	falla	4	6,8%
Total		72	98,6%

Tabla IV.46 - Resumen de tipos de interferencia tras el nuevo entrenamiento de la arquitectura de 3 neuronas.

Interferencia	Casos	%
1 - 2	5	6,8%
1 - 3	1	1,4%
2 - 3	3	4,1%
3 - 4	0	0,0%
4 - 5	1	1,4%
Total	10	13,7%

Tabla IV.47 - Matriz de confusión tras el nuevo entrenamiento de la arquitectura de 3 neuronas.

	1	**2**	**3**	**4**	**5**	**Total**
1	6		1			7
2	2	15	3			20
3	2	2	23			27
4				7		7
5				2	9	11
SC	1					
Total	10	17	27	9	9	72
PA = 0,83						

Tabla IV.48 - Índices por clase de la matriz de confusión tras al nuevo entrenamiento de la arquitectura de 3 neuronas.

Clase	EP	EU
1	0,60	0,86
2	0,88	0,75
3	0,85	0,85
4	0,78	1,00
5	1,00	0,82

Tabla IV.49 - Comparación de medidas de la clasificación realizada por las arquitecturas de 3 neuronas previa y nueva.

Medida	3 neuronas previo	3 neuronas nuevo
Clasificaciones fuertes	57,6%	67,1%
Clasificaciones moderadas	24,6%	13,7%
Clasificaciones débiles	17,8%	17,8%
Interferencias totales	17,8%	13,7%
Aciertos débiles	11,0%	11,0%
Aciertos fuertes y moderados	69,9%	71,2%
Aciertos fuertes, moderados y débiles	80,9%	82,2%
Fallos débiles	6,8%	6,8%
Fallos fuertes y moderados	12,3%	9,6%
Entradas sin clasificar	0%	1,37%

- Los mejores valores de EU son los relativos a las clases 1, 3, 4 y 5, que por tanto no tienden a recibir casos procedentes de otras clases.
- Los peores valores de EU son los mostrados por la clase 2, que por tanto muestra un comportamiento receptor más intenso que el resto de clases.
- La clases que muestran menos problemas, al tener valores elevados tanto en EP como en EU son las clases 4 y 5.
- La clase que muestra más problemas es la clase 1, por el reducido valor de EP que presenta. Revisando la clasificación, se comprueba que sus fugas se dirigen hacia las clases 2 y 3. En la Tabla IV.50 se han revisado las secciones correspondientes a esta clase, pero no se ha creído oportuno efectuar modificación alguna.

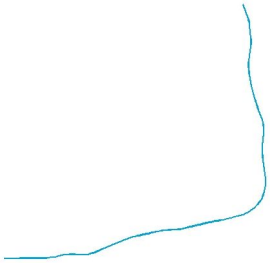
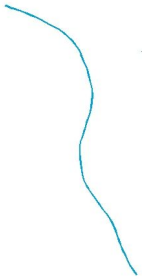
Elección de un aprendizaje de la validación cruzada

La mejora de resultados obtenidos tras el re-entrenamiento de la arquitectura de 3 neuronas ocultas confirma que esta estructura puede ser eficiente en un proceso de clasificación tal como el que se persigue. La validación cruzada con los 8 conjuntos de secciones ha permitido efectuar 8 entrenamientos de esta red. Se podría pensar en efectuar un nuevo entrenamiento con el total de 73 secciones, pero se perdería la sensibilidad que ofrece el error en el patrón de validación a la hora de garantizar la capacidad de generalización de la red a otros casos diferentes a los del patrón de entrenamiento.

Otra utilidad de los procesos de validación cruzada es la de una selección de un subconjunto de los datos de entrada. Un subconjunto que contiene todos los da-

tos relevantes se puede calificar como bueno; un subconjunto que contiene exclusivamente los datos relevantes se puede calificar como el mejor (Sarle, 1997)

Tabla IV.50 - Secciones de la clase 1 que han sido mal clasificadas.

	**Sección 41** Clase anterior: 1 (muy suave) Nueva clase propuesta: 3 (sinuosa, direccionalidad estable) Ésta es una sección de carretera de la Red Provincial con un trazado muy suave, pero su tendencia principal forma un gran arco, lo cual puede inducir a la red a entender que debería ser una línea sinuosa. Es preferible dejarla en la clase 1 para no disminuir la capacidad de generalización de la red. **No se realizará el cambio de clase propuesto**
	**Sección 11** Clase anterior: 1 (muy suave) Nueva clase propuesta: 3 (sinuosa, direccionalidad estable) Se trata de una sección de carretera de la Red Básica Autonómica con un trazado muy suave, pero al igual que la sección 41, forma un gran arco. Por el mismo motivo de dejará en la clase 1. **No se realizará el cambio de clase propuesto**
	**Sección 27** Clase anterior: 1 (muy suave) Nueva clase propuesta: 2 (suave) Ésta sección de carretera de la Red Provincial es muy suave, no hay curvas de radio reducido. Parece correcto dejarla en la clase 1. **No se realizará el cambio de clase propuesto**
	**Sección 2** Clase anterior: 1 (muy suave) Nueva clase propuesta: 2 (suave) Ésta es una sección de autovía de la Red Básica Autonómica con un trazado muy suave, con curvas de gran radio y un trazado moderno. Se dejará en la clase 1. **No se realizará el cambio de clase propuesto**

Así, se escogerá como definitivo uno de los 8 entrenamientos efectuados en el proceso de validación cruzada. En principio interesa que los casos conflictivos, es decir, aquellas secciones que no han sido bien clasificadas, formen parte del patrón de entrenamiento, pues serían datos relevantes en el aprendizaje, dejando para el patrón de validación casos que no presenten confusiones entre clases. Esto, junto con un reducido error en el patrón de validación, garantizará un entrenamiento con una capacidad de generalización lo mayor posible. Los cuatro

casos en los que no se han presentado confusiones entre clases son los siguientes:

- Patrón 1. Existe 1 clasificación moderada y 1 débil.
- Patrón 2. No clasifica 1 de las secciones y existen 2 clasificaciones débiles.
- Patrón 5. Existen 2 clasificaciones moderadas y 2 débiles.
- Patrón 6. Existe 1 clasificación débil.

Por tanto son los patrones 1 y 6 los que muestran mayor número de clasificaciones correctas y fuertes. Si se observan las gráficas de error de los correspondientes entrenamientos (Figura IV.12) se advierte que es el patrón 1 el que presenta un error claramente más reducido en el patrón de validación, siendo parecido el error en el patrón de entrenamiento.

Patrón 1 Patrón 6

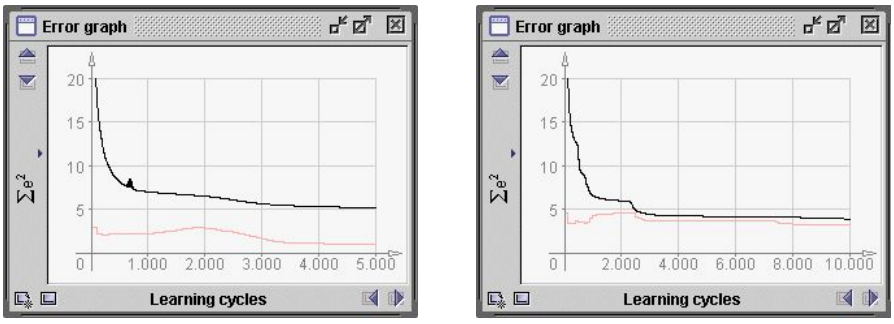


Figura IV.12 - Gráficas de error del re-entrenamiento de la arquitectura de 3 neuronas ocultas.

De esta manera, puede concluirse que la red neuronal elegida para efectuar la clasificación automática perseguida tiene las siguientes características:

- Red de retropropagación de 3 capas.
- Capa de oculta de 3 neuronas.
- Función de activación sigmoidal.
- Función de salida identidad

- Entrenamiento realizado con el patrón 1, dando lugar a los umbrales de las neuronas expuestos en la Tabla IV.51 y a los pesos de las conexiones entre neuronas mostradas en las tablas IV.52 y IV.53.

Tabla IV.51 - Umbrales de las neuronas de la red

Capa de entrada		**Capa oculta**		**Capa de salida**	
neurona	**umbral**	**neurona**	**umbral**	**neurona**	**umbral**
1 (*LB*)	-0,5359	15	-1,0477	18 (Clase 1)	5,6375
2 (l_m)	0,9288	16	2,9086	19 (Clase 2)	-3,8503
3 (b_{cv})	0,4787	17	-5,8887	20 (Clase 3)	-18,6383
4 (lb_{me})	-0,3166			21 (Clase 4)	-4,7415
5 (lb_{cv})	0,4461			22 (Clase 5)	-9,2446
6 (sb_{cv})	0,2068				
7 (a_m)	0,2429				
8 (a_{cv})	0,7885				
9 (c_{cv})	0,3650				
10 (C1)	-0,5287				
11 (C2)	-0,7824				
12 (C3)	0,0633				
13 (C4)	0,4310				
14 (C5)	0,1359				

Tabla IV.52 - Peso de las conexiones entre la capa de entrada y la capa oculta.

Neurona de la capa de entrada	**Peso**		
	neurona 15	**neurona 16**	**neurona 17**
1	10,3621	-25,8668	5,5321
2	-10,4430	-20,5286	-13,4178
3	-2,9882	0,4889	-3,4695
4	-1,2674	-15,2069	3,7535
5	-0,8197	2,7309	5,4949
6	4,1091	-10,0791	-10,4526
7	16,5481	-1,6369	-2,0531
8	-2,4491	2,2311	-3,9147
9	-2,3790	-7,6604	1,8344
10	-1,8988	-3,3535	5,7156
11	-2,3841	-0,8740	5,0274
12	0,8351	-0,4784	5,9302
13	-3,7033	-1,2410	2,8551
14	6,6988	0,6183	1,1494

Tabla IV.53 - Peso de las conexiones entre la capa oculta y la capa de salida.

Neurona de la capa oculta	**Peso**				
	neurona 18	**neurona 19**	**neurona 20**	**neurona 21**	**neurona 22**
15	-20,6582	17,8050	-2,7163	-2,0655	4,9821
16	-10,1760	-19,2261	14,6542	6,2478	6,7187
17	-0,8283	-5,2342	16,5498	-2,8187	-34,8262

IV.4. SEGMENTACIÓN MEDIANTE LA RED NEURONAL ARTIFICIAL

Como se apuntó en el apartado III.5, la red neuronal artificial establecida con los resultados del apartado IV.3.3.4, creada para clasificar los elementos lineales, puede emplearse para segmentar un elemento lineal, puesto que es capaz de reconocer diferencias entre secciones que pertenecen a clases diferentes.

El método consiste en utilizar una ventana móvil de longitud *L* que se desplaza en pasos de longitud *l*. En cada paso de la ventana, la sección de línea incluida dentro de ella es enriquecida y a continuación clasificada por la red neuronal. Por tanto son dos los parámetros, *L* y *l*, los que se proponen para esta metodología de segmentación.

Primeramente se ha pretendido fijar el parámetro *l*. Debe ser lo suficientemente pequeño como para que no influya sustancialmente en el proceso de segmentación; pero no debe ser tan reducido que ralentice excesivamente el proceso de cálculo. Se ha tanteado el valor de *l* desde valores pequeños, como 25 m hasta grandes valores, como 500 m, con una diferencia de tiempos de procesado sustanciales, así como diferencias en la segmentación resultante. El tanteo de diferentes valores dentro del intervalo entre ambos, ha permitido advertir mediante el análisis visual que valores del orden de 200 ó 250 m proporcionan resultados plenamente satisfactorios en prácticamente toda la muestra de elementos lineales, con resultados prácticamente idénticos a los obtenidos con el valor de 25 m.

En cuanto al parámetro *L*, éste fija la ventana que se va a presentar a la red neuronal y es el parámetro que realmente tiene relevancia Su valor está relacionado con la longitud de las secciones que han servido para entrenar la red. La sección más pequeña que se empleó para entrenar la red es de 711 m. La media se sitúa en 3578 m y la desviación típica en 2272 m. Así, se ha tanteado algún valor que ofrezca resultados satisfactorios para la mayoría de casos, probando valores desde 1000 m hasta 3500 m. Los resultados del análisis visual han mostrado que un valor en torno a 1500 m se comporta correctamente, siendo ade-

cuado elevarlo hasta unos 3000 m en el caso de vías de comunicación de alta capacidad (*A-44*, *N-323*, *A-316*, *A-316A*).

La aplicación de los parámetros sugeridos a las líneas de la muestra da lugar a las segmentaciones que se presentan en el Anexo D.

IV.5. EVALUACIÓN POR EXPERTOS

En este apartado de van a analizar los resultados de la evaluación que los expertos han realizado acerca de las distintas soluciones de segmentación y clasificación, según la metodología expuesta en el apartado III.6. El análisis de estos resultados se realizará tanto del propio panel de expertos como de sus valoraciones. El análisis de estas últimas se realizará tanto de forma global, como por cada línea, y según agrupaciones de líneas. Además, para su posible consulta, en el Anejo E se han resumido las respuestas de cada experto al responder el cuestionario de la Figura III.23.

IV.5.1. Resultados bajo análisis

En la prueba se van a incluir todas las líneas de la muestra, segmentadas mediante cuatro metodologías diferentes:

a) Segmentación semiautomática (véase el apartado IV.3.1.1) con la que se ha entrenado la red neuronal artificial (RNA). Se ha empleado la técnica de la suma acumulada de áreas efectivas según los parámetros de la Tabla IV.54.

b) Segmentación mediante la RNA. Se utiliza el proceso, cuyos resultados han sido analizados en el apartado IV.4, según los parámetros de la Tabla IV.55.

c) Segmentación mediante suma acumulada de áreas efectivas. Se aplica la técnica, cuyos resultados han sido analizados en el apartado IV.1, según los parámetros de la Tabla IV.56.

d) Segmentación mediante wavelets. Se emplea la metodología, cuyos resultados han sido analizados en el apartado IV.2, según los parámetros de la Tabla IV.57.

Además, en la misma prueba se someterá a evaluación la clasificación de todas las secciones presentadas. Esta clasificación procede de dos fuentes: la clasificación manual con la que se entrenó la red neuronal y la clasificación automática que la red neuronal ha efectuado, una vez entrenada (véase esta RNA en el apartado IV.3.3.4), sobre todas las secciones extraídas por cada metodología de segmentación:

a) Clasificación manual de las secciones extraídas por segmentación semiautomática (véase el apartado IV.3.1.2), con la que se ha entrenado la RNA.

b) Clasificación automática mediante la RNA, de la segmentación realizada por ésta.

c) Clasificación automática mediante la RNA, de la segmentación realizada mediante la suma acumulada de áreas efectivas.

d) Clasificación automática mediante la RNA, de la segmentación realizada mediante wavelets.

Tabla IV.54 - Parámetros para la segmentación semiautomática (caso a)

Línea		L (m)	l (m)	nº secciones
1	A-44	4000	400	3
2	N-323	4000	450	3
3	A-316A	4000	400	2
4	A-316	2000	350	3
5	A-311	2000	400	1
6	A-320	2000	450	3
7	A-324	2000	400	5
8	A-1102	1500	400	3
9	JV-2222	2000	275	5
10	JV-2223	2500	400	1
11	JV-2224	2000	400	2
12	JV-2225	2500	100	2
13	JV-2226	2000	400	2
14	JV-3012	1500	200	3
15	JV-3241	1500	300	3
16	JV-3242	2000	300	5
17	JP-2332	1400	200	4
18	P-CaminoAncho	2000	400	1
19	P-CaminoAzadillas	2000	75	5
20	P-CerroAlmaden	2000	200	4
21	P-CerroJabalcuz	1000	130	6
22	P-CerroSantin	1500	400	1
23	P-Pegalajar-Central	1500	300	2
24	P-SierraPeñaÁguila	2500	500	4

Tabla IV.55 - Parámetros para la segmentación mediante la RNA (caso b)

Línea		L (m)	l (m)	nº secciones
1	A-44	3000	250	2
2	N-323	3000	250	4
3	A-316A	3000	250	2
4	A-316	3000	250	2
5	A-311	1500	250	1
6	A-320	1500	250	5
7	A-324	1500	250	6
8	A-1102	1500	250	5
9	JV-2222	1500	250	4
10	JV-2223	1500	250	6
11	JV-2224	1500	250	3
12	JV-2225	1500	250	2
13	JV-2226	1500	250	3
14	JV-3012	1500	250	2
15	JV-3241	1500	250	2
16	JV-3242	1500	250	4
17	JP-2332	1500	250	4
18	P-CaminoAncho	1500	250	1
19	P-CaminoAzadillas	1500	250	4
20	P-CerroAlmaden	1500	250	4
21	P-CerroJabalcuz	1500	250	3
22	P-CerroSantin	1500	250	4
23	P-Pegalajar-Central	1500	250	1
24	P-SierraPeñaÁguila	1500	250	6

Tabla IV.56 - Parámetros para la segmentación mediante la suma acumulada de áreas efectivas (caso c)

Línea		σ	L (m)	DP	nº secciones
1	A-44	2	4000	250	4
2	N-323	3	4000	600	2
3	A-316A	2	4000	250	2
4	A-316	2	2000	200	4
5	A-311	2	2000	250	1
6	A-320	3	2000	500	3
7	A-324	2	2000	900	3
8	A-1102	1	2000	500	3
9	JV-2222	1	2000	400	3
10	JV-2223	1	2500	250	4
11	JV-2224	1	2000	300	2
12	JV-2225	1	2500	250	1
13	JV-2226	2	2000	400	2
14	JV-3012	2	2000	300	3
15	JV-3241	3	2000	450	2
16	JV-3242	3	2000	200	6
17	JP-2332	2	1500	200	3
18	P-CaminoAncho	2	2000	300	3
19	P-CaminoAzadillas	1	2000	200	3
20	P-CerroAlmaden	2	3000	200	4
21	P-CerroJabalcuz	1	2500	200	5
22	P-CerroSantin	1	2500	300	3
23	P-Pegalajar-Central	1	2500	250	4
24	P-SierraPeñaÁguila	3	2500	700	3

Tabla IV.57 - Parámetros para la segmentación mediante wavelets (caso d)

Línea		L (m)	K (%)	nº secciones
1	A-44	2000	40	4
2	N-323	2000	40	4
3	A-316A	2000	40	3
4	A-316	2000	40	4
5	A-311	2000	40	1
6	A-320	2000	40	4
7	A-324	2000	35	3
8	A-1102	1000	40	4
9	JV-2222	1000	45	5
10	JV-2223	1000	40	3
11	JV-2224	1000	40	2
12	JV-2225	1000	40	3
13	JV-2226	1000	40	3
14	JV-3012	1000	35	3
15	JV-3241	1000	40	5
16	JV-3242	1000	40	4
17	JP-2332	1000	40	2
18	P-CaminoAncho	1000	40	3
19	P-CaminoAzadillas	1000	40	4
20	P-CerroAlmaden	1000	35	4
21	P-CerroJabalcuz	1000	40	5
22	P-CerroSantin	1000	40	2
23	P-Pegalajar-Central	1000	45	3
24	P-SierraPeñaÁguila	1000	40	5

IV.5.2. Panel de expertos

Respecto al panel inicialmente previsto, compuesto por un total de 20 expertos, solamente en un caso no se ha recibido su evaluación. Cada miembro del panel de expertos ha respondido a la prueba de forma independiente. Aunque la prueba ha sido guiada mediante la carta de presentación, las instrucciones y la tabla de respuestas (y mediante entrevista personal, en algunos casos), es de interés el estudiar cuál ha sido la forma en que cada experto ha evaluado las segmentaciones y clasificaciones que se le han presentado. En las tablas IV.58, IV.59 y IV.60 se incluyen la estadística de la puntuación, la cantidad de problemas indicados, y la estadística de la clasificación de cada miembro del panel de expertos, respectivamente.

Con la Tabla IV.58 se puede analizar la respuesta dada por los expertos en cuanto a la puntuación de la segmentación, que se realiza según una escala entre 1 (peor puntuación) y 5 (mejor puntuación). Observando la última fila (media), se puede decir que los valores medios son los siguientes: para la media, 3,1; para la moda, 2,8; para la desviación típica, 1,1; para el valor máximo, 4,9; y para el valor mínimo, 1,4. Esto indica que por regla general, los expertos han empleado toda la escala de puntuación que se les permitía (entre 1 y 5). No obstante, le-

yendo los datos de cada columna se pueden detectar casos que destacan por presentar un valor superior o inferior al habitual. Así, se comprueba que:

- El experto 1 muestra una moda elevada, de 4.
- El experto 3 presenta la puntuación más baja, junto con los expertos 14 y 18, con una media de 2,4.
- Los expertos 7 y 9 manifiestan una tendencia a puntuar alto, con media 3,8 y 3,7, y moda 5 y 4, respectivamente. El experto 9 presenta una dispersión reducida.
- El experto 10, presenta una tendencia a puntuar alto, con la media más elevada de todas, de 3,9, y moda 5, con más dispersión que los expertos 7 y 9.
- Los expertos 11 y 13 puntúan algo bajo, con media 2,7 y 2,9 respectivamente, y moda 2. Destacan por presentar una desviación elevada, de 1,4 y 1,6 respectivamente.
- El experto 14 presenta la puntuación más baja, junto con los expertos 3 y 18, con una media de 2,4.
- El experto 16 puntúa con una media baja, de 2,6.
- El experto 18 presenta la puntuación más baja, junto con los expertos 3 y 14, con una media de 2,4. Además, es el único que no puntúa ningún caso con 5 puntos, siendo 4 la mayor puntuación que otorga. Esto, junto con una dispersión reducida, indica que puede ser el experto menos satisfecho con los resultados que se le presentan.

Tabla IV.58 - Estadística de la puntuación de la segmentación de cada miembro del panel de expertos.

Experto	N líneas	Media	Moda	Desv.	Máx.	Mín.
1	7	3,3	**4**	1,0	5	1
2	4	3,1	3	1,1	5	1
3	8	***2,4***	2	1,1	5	1
4	7	3,0	2	1,2	5	1
5	4	2,9	2	1,3	5	1
6	7	3,1	3	0,9	5	2
7	7	**3,8**	**5**	1,1	5	2
8	7	3,2	3	0,9	5	2
9	3	**3,7**	**4**	0,9	5	2
10	3	**3,9**	**5**	1,2	5	2
11	3	***2,7***	2	**1,4**	5	1
12	3	3,4	3	1,3	5	1
13	4	2,9	2	**1,6**	5	1
14	4	***2,4***	2	1,2	5	1
15	4	3,5	3	1,1	5	2
16	6	***2,6***	2	1,0	5	1
17	4	3,1	3	1,0	5	2
18	4	***2,4***	2	0,9	***4***	1
19	3	3,1	2	1,3	5	1
Media	4,8	3,1	2,8	1,1	4,9	1,4

Nota 1: la númeración y orden de los expertos no coinciden con los de la Tabla III.11.

Nota 2: en **negrita** se indican los valores que destacan por ser de mayor valor al resto; en ***negrita y cursiva*** los que destacan por ser de menor valor.

Tabla IV.59 - Número de problemas indicados por cada miembro del panel de expertos.

Experto	N líneas	Sum Pr1	Sum Pr2	Sum Pr3	Sum Pr4	Sum Pr5	Prob / línea
1	7	5	9	9	4	4	4,4
2	4	3	7	3	4	0	4,3
3	8	4	8	16	7	0	4,4
4	7	3	5	5	1	6	2,9
5	4	0	6	0	0	1	***1,8***
6	7	8	5	14	1	1	4,1
7	7	11	0	3	0	9	3,3
8	7	5	1	2	5	5	2,6
9	3	5	0	6	0	0	3,7
10	3	1	3	6	0	0	3,3
11	3	3	2	7	2	1	**5,0**
12	3	2	2	4	0	0	2,7
13	4	1	4	4	2	1	3,0
14	4	5	3	9	0	0	4,3
15	4	0	1	3	0	0	1,0
16	6	1	1	17	8	6	**5,5**
17	4	6	2	8	0	4	**5,0**
18	4	1	7	6	7	1	**5,5**
19	3	0	2	3	0	1	***2,0***
Media	4,8	-	-	-	-	-	3,6

Nota 1: la númeración y orden de los expertos no coinciden con los de la Tabla III.11.

Nota 2: en **negrita** se indican los valores que destacan por ser de mayor valor al resto; en ***negrita y cursiva*** los que destacan por ser de menor valor.

En cuanto al número de problemas que indica cada experto, dado que cada uno analiza un número diferente de líneas, lo interesante es estudiar cómo se distribuye el número de problemas por línea que señala cada experto, indicado en la última columna de la Tabla IV.59. Así, se observa que el valor medio de todo el panel de expertos es de 3,6 problemas por línea. Destacan por indicar pocos

problemas por línea el experto 5 y el 19. Destacan por indicar un número elevado de problemas por línea los expertos 11, 16, 17 y 18.

Con la Tabla IV.60 se puede analizar la respuesta dada por los expertos en cuanto a la puntuación de la clasificación, que se realiza según una escala entre 1 (peor puntuación) y 5 (mejor puntuación). Observando la última fila (media), se puede decir que los valores medios son los siguientes: para la media, 3,5; para la moda, 3,7; para la desviación típica, 1,1; para el valor máximo, 5,0; y para el valor mínimo, 1,5. Esto indica que por regla general, los expertos han empleado toda la escala de puntuación que se les permitía (entre 1 y 5), con puntuaciones preferentemente elevadas. No obstante, leyendo los datos de cada columna se pueden detectar casos que destacan por presentar un valor superior o inferior al habitual. Así, se comprueba que:

- El experto 4 muestra una media baja, de 2,8 y una moda baja, de 2.
- El experto 5 presenta una moda baja, de 2.
- Los expertos 7 y 10 muestran una media elevada, de 3,9.
- El experto 9 manifiesta una tendencia a puntuar alto, ya que su media es elevada, de 3,9 y su desviación típica es claramente inferior a las demás, de 0,5. Además, el valor mínimo de sus puntuaciones es de 3.
- El experto 12 manifiesta una tendencia a puntuar alto, ya que su media es la más elevada del panel de expertos y su moda es 5.
- El experto 13 es el que muestra una desviación claramente más elevada que el resto. Dado que su moda es 5, esto indica que tiende a puntuar en los extremos del intervalo entre 1 y 5.
- El experto 18 presenta la media más baja de todas, de 2,7.

Para sintetizar todo lo comentado hasta ahora sobre el panel de expertos y tenerlo en cuenta, si se cree conveniente, a la hora de valorar los resultados obtenidos en la prueba, se ha elaborado la Tabla IV.61. En ella se han incluido los expertos que habían destacado en el análisis de alguna de las tablas anteriores. Para cada experto, se indica mediante una flecha si los valores de la media, mo-

da y desviación son significativamente altos o bajos (y el número de problemas en el caso de la segmentación). Finalmente se incluye una columna en la que se valora al experto como crítico o satisfecho con el proceso de segmentación y de clasificación que ha tenido que valorar.

Tabla IV.60 - Estadística de la puntuación de la clasificación por cada miembro del panel de expertos.

Experto	N líneas	Media	Moda	Desv.	Máx.	Mín.
1	7	3,6	4	1,1	5	2
2	4	3,0	3	1,0	5	1
3	8	3,8	3	1,0	5	2
4	7	***2,8***	***2***	1,1	5	1
5	4	3,0	***2***	1,3	5	1
6	7	3,4	4	1,0	5	2
7	7	**3,9**	4	1,0	5	2
8	7	3,7	**5**	1,1	5	2
9	3	**3,9**	4	***0,5***	5	**3**
10	3	**3,9**	4	1,0	5	2
11	3	3,2	3	1,2	5	1
12	3	**4,1**	**5**	1,2	5	1
13	4	3,3	**5**	**1,8**	5	1
14	4	3,3	4	1,2	5	1
15	4	3,6	4	1,2	5	1
16	6	3,4	4	1,1	5	2
17	4	3,8	4	0,9	5	2
18	4	***2,7***	3	1,1	5	1
19	3	3,4	4	1,2	5	1
Media	4,8	3,5	3,7	1,1	5,0	1,5

Nota 1: la númeración y orden de los expertos no coinciden con los de la Tabla III.11.

Nota 2: en **negrita** se indican los valores que destacan por ser de mayor valor al resto; en ***negrita y cursiva*** los que destacan por ser de menor valor.

Tabla IV.61 - Resumen de expertos que han sido significativamente críticos o satisfechos con los procesos evaluados.

Experto	Segmentación				Clasificación			Valoración del experto	
	Media	Moda	Desv.	NºProb	Media	Moda	Desv.	Segmentación	Clasificación
3	↓							Crítico	-
4					↓	↓		-	Crítico
5				↓		↓		Satisfecho (NºProb)	Crítico
7	↑	↑			↑			Satisfecho	Satisfecho
9	↑	↑	↓		↑		↓	Satisfecho	El más satisfecho
10	↑	↑			↑			El más satisfecho	Satisfecho
11	↓	↓	↑	↑				Crítico	-
12					↑	↑		-	Satisfecho
13			↑			↑	↑	-	Satisfecho
14	↓							Crítico	-
16	↓			↑				Crítico	-
17				↑				Crítico (NºProb)	-
18	↓		↓	↑	↓			El más crítico	El más crítico
19				↓				Satisfecho (NºProb)	-

Nota 1: un valor significativamente bajo se ha señalado con ↓.
un valor significativamente elevado se ha señalado con ↑.

Nota 2: La valoración del experto es satisfecho/crítico. Se indicado cuál es el más satisfecho y cuál el más crítico.
Si un experto sólo destaca por el número de problemas indicados, se ha señalado entre paréntesis.

IV.5.3. Análisis global

Primeramente es interesante observar los resultados globales que se pueden obtener teniendo en cuenta todas las evaluaciones efectuadas por los expertos, para comprobar si ya de forma general se pueden detectar diferencias entre las distintas técnicas de segmentación y su posterior clasificación.

En la Tabla IV.62 se presenta el promedio de todas las puntuaciones del total de expertos según el tipo de caso (a, b, c, d) de segmentación y clasificación. En la valoración de la segmentación, la media global es de 3,1 puntos, siendo el caso (a) el más valorado, con 3,5 puntos, siendo la puntuación del resto de casos bastante inferior y de valores similares (b: 2,8; c: 3,0; d: 3,0). En la valoración de la clasificación, la media global es de 3,4 puntos, siendo el caso (a) el más valorado con 3,9 puntos, seguido del caso b con 3,4 puntos, el caso c con 3,3 y el caso d con 3,1.

Tabla IV.62 - Puntuación media de cada caso de segmentación y clasificación

Caso	segmentación	clasificación
a	3,5	3,9
b	2,8	3,4
c	3,0	3,3
d	3,0	3,1
Media global	3,1	3,4

Por tanto en primera instancia se puede afirmar que la opción (a) es la preferida para segmentación y clasificación. Este resultado es de mucho interés, ya que evidencia que la solución de segmentación semiautomática, y posterior clasificación de las secciones extraídas, con la que se ha entrenado la RNA, es la preferida por los expertos, frente al resto de casos propuestos. Esto confirma que el entrenamiento de la RNA es aprobado en general por los expertos y da fortaleza a la propuesta de RNA del apartado IV.3.

Dejando aparte las opciones (a) de segmentación y clasificación, pues son las empleadas para entrenar la RNA, es interesante observar qué sucede entre el resto de casos, pues son precisamente las propuestas de segmentación y clasificación automáticas que sería conveniente comparar entre sí. Centrando el análisis en la segmentación, las puntuaciones obtenidas no permiten destacar una

valoración sobre las demás, ya que son muy similares. En cuanto a la clasificación por la RNA, las puntuaciones son de nuevo muy similares. Quedaría por ver lo que sucede en análisis más detallados (por línea o por clases de líneas), que se expondrán en subapartados posteriores.

Asimismo se podría observar qué sucede en cuanto a los problemas detectados en cada solución de segmentación por el panel de expertos. En la Tabla IV.63 se resume la cantidad total de problemas de cada tipo señalados por los expertos en cada una de las cuatro propuestas de segmentación.

Tabla IV.63 - Número de problemas de cada tipo indicados por el panel de expertos

	Pr1	Pr2	Pr3	Pr4	Pr5	Total
a	9	18	23	8	5	58
b	25	22	32	14	19	93
c	11	22	27	12	7	72
d	19	6	43	7	14	75
Total	64	68	125	41	45	343

Pr1 - Problema 1: Nº de secciones excesivo.
Pr2 - Problema 2: Nº de secciones insuficiente
Pr3 - Problema 3: Existen cambios de sección en lugares incorrectos
Pr4 - Problema 4: Existen secciones excesivamente largas.
Pr5 - Problema 5: Existen secciones excesivamente cortas.

A partir de la última columna de la Tabla IV.63 se observa que el caso (b) concentra más problemas que los demás, que los casos (c) y (d) muestran un número similar, y que la propuesta (a) es la que menos problemas presenta. Leyendo la fila que suma el total de problemas de cada tipo, se comprueba que el más frecuente es el problema 3, que señala que la segmentación se ha realizado en lugares inadecuados de la línea; a continuación se encuentran los problemas 1 y 2, que permiten indicar si el número de secciones no es adecuado; por último aparecen como menos frecuentes los problemas 4 y 5, que señalan si las secciones se consideran excesivamente largas o cortas.

Haciendo una lectura por filas y luego por columnas se puede comprobar que:

- El caso (a), el que menos problemas presenta, concentra sus problemas en las tipologías 2 (número de secciones insuficiente) y 3 (segmentaciones en lugares inadecuados). Se critica una cantidad de secciones insuficiente antes que el exceso.

- El caso (b), el que más problemas presenta, muestra una distribución bastante homogénea entre los diferentes tipos de problemas, siguiendo la distribución general que se ha comentado.
- El caso (c) concentra sus problemas en las tipologías 2 (número de secciones insuficiente) y 3 (segmentaciones en lugares inadecuados). Se critica una cantidad de secciones insuficiente antes que el exceso. Se critica un exceso de longitud de las secciones frente al defecto.
- El caso (d) muestra una gran incidencia en el problema de tipo 3 (segmentaciones en lugares inadecuados). Se critica una cantidad de secciones excesiva antes que el defecto. Se critica un defecto de longitud de las secciones frente al exceso.
- El problema 1 se da sobre todo en los casos de tipo (b) y (d).
- El problema 2 se distribuye homogéneamente entre los casos (a), (b) y (c), pero disminuye en los casos de tipo (d).
- El problema 3 incide sobre todo en casos de tipo (d), disminuyendo progresivamente en este orden: (b), (c), (a), presentando este último prácticamente la mitad de problemas que (d).
- El problema 4 se concentra en casos de tipo (b) y (c).
- El problema 5 se concentra en casos de tipo (b) y (d).

IV.5.4. Análisis por línea

El resumen completo de resultados de la evaluación por los expertos, estructurado por líneas, se incluye en el Anexo E. En la Tabla IV.64 se presenta un resumen de los mismos, incluyendo:

- Cuál es la mejor segmentación (a, b, c, d), según la media de las puntuaciones de los cuatro expertos para cada solución. Además se incluyen cuántos problemas, de cada una de las 5 tipologías, han sido señalados para ella por los expertos, indicando también la suma del total de problemas.

- Media de la puntuación en la segmentación de las cuatro soluciones por los cuatros expertos, que permitiría distinguir qué líneas son, en general, más fáciles o difíciles de segmentar.
- Cuál de las soluciones de segmentación (a, b, c, d) ha sido mejor clasificada según la media de las puntuaciones de los expertos para esa solución.
- Media de la puntuación en la clasificación de las cuatro soluciones por los cuatro expertos, que permitiría distinguir qué líneas son, en general, más fáciles o difíciles de clasificar.

Tabla IV.64 - Evaluación de los expertos. Resultados por cada línea

Línea		Segmentación						Clasificación		
		Mejor caso[1]					Punt. Media	Mejor caso		Punt. Media
		Caso y puntuación		Problemas				Caso y puntuación		
				1	2	3	4	5	Tot				
1	A-44	d	4,00	0	1	3	0	0	4	3,25	d	**4,25**	3,44
2	N-323	a c	3,50	0	1	0	2	0	3	3,22	a	3,50	***2,81***
3	A-316A	d	3,25	2	0	1	0	0	3	3,00	a b	**5,00**	4,00
4	A-316	a c	3,67	1	0	1	0	0	2	3,08	b	3,67	3,08
5	A-311	a b c d	4,00	0	0	0	0	0	0	4,00	a b c d	4,00	4,00
6	A-320	a	**4,75**	0	0	1	0	0	1	3,75	a	**4,50**	3,50
7	A-324	a	**4,37**	1	0	1	0	1	3	3,16	b	**4,25**	3,41
8	A-1102	a	3,33	0	1	1	0	0	2	***2,50***	b	3,33	4,00
9	JV-2222	a	**4,33**	0	1	1	0	0	2	3,25	a	4,00	3,08
10	JV-2223	d	3,25	1	0	2	0	0	3	***2,75***	a	**5,00**	3,38
11	JV-2224	d	3,50	0	0	1	1	0	2	***2,88***	c	3,75	3,31
12	JV-2225	a	4,00	0	1	0	0	1	2	3,25	a b	**4,75**	4,00
13	JV-2226	b d	3,75	0	0	1	0	0	1	3,50	d	**4,50**	4,00
14	JV-3012	a d	**4,50**	0	0	0	0	1	1	3,63	a	3,75	3,19
15	JV-3241	a	**4,25**	0	0	0	0	0	0	***2,95***	a	**5,00**	3,63
16	JV-3242	a	4,00	0	0	2	0	0	2	3,13	a c	**4,50**	3,56
17	JP-2332	b	**4,25**	1	0	1	0	2	4	***2,81***	d	3,75	***2,94***
18	P-CaminoAncho	a b c	3,50	0	2	0	2	0	4	3,00	a b c	3,50	3,19
19	P-CaminoAzadillas	a	3,75	2	0	1	0	1	4	3,00	c	**4,25**	3,75
20	P-CerroAlmaden	c	3,25	0	0	3	0	0	3	***2,25***	d	**4,25**	3,63
21	P-CerroJabalcuz	b	3,75	0	3	1	0	0	4	3,31	b	**4,50**	**4,13**
22	P-CerroSantin	c	4,00	0	0	2	0	0	2	***2,67***	c	4,00	3,25
23	P-Pegalajar-Central	a	3,75	0	0	1	0	0	1	***2,88***	a	3,75	***2,94***
24	P-SierraPeñaÁguila	d	3,75	1	0	3	0	0	4	3,00	a	3,75	3,44
Media		- - - -	3,85	0,38	0,42	1,13	0,21	0,25	2,38	3,09	- - - -	4,15	3,49
Desviación típica		- - - -	0,42	-	-	-	-	-	1,28	0,39	- - - -	0,50	0,39
Frecuencia		12 4 6 8	-	9	10	27	5	6	-	-	12 8 6 5	-	-
Máximo		- - - -	4,75	2	3	3	2	2	4	4,00	- - - -	5,00	4,13
Mínimo		- - - -	3,25	0	0	0	0	0	0	2,25	- - - -	3,33	2,81

En **negrita** se han marcado aquellos valores de puntuación superiores a 4,00.
En ***negrita y cursiva*** se han marcado aquellos valores de puntuación inferiores a 3,00.

[1] En caso de presentarse soluciones con la misma media, se elegirá aquella cuya mediana sea mayor, que aparece subrayada. Si también fueran las medianas iguales, se indican las soluciones sin resaltar ninguna de ellas.

La propuesta de segmentación que ha sido elegida como la mejor en mayor número de ocasiones ha sido claramente la (a), 12 veces. Le sigue la solución (d) con 8, la (c) con 6 y la (b) con 5. Además es interesante calcular una puntuación media por cada propuesta de segmentación, sólo con aquellas líneas donde esa propuesta ha sido elegida como la mejor, obteniendo los siguientes resultados: a: 4,04; b: 3,88; c: 3,65; d: 3,75. Así, la propuesta (a) es la más valorada cuando es elegida en primer lugar, seguida por la (b), (d) y (c). Existen seis líneas en la que la mejor opción se ha valorado con más de 4. Ninguna se ha valorado con menos de 3.

La propuesta de clasificación que ha sido elegida como la mejor en mayor número de ocasiones ha sido la (a), 12 veces. Le sigue la solución (b) con 8, la (c) con 6 y la (d) con 5. Calculando para la también para la clasificación la puntuación media por cada propuesta, sólo mediante las líneas donde esa propuesta ha sido elegida como la mejor, se obtiene: a: 4,21; b: 4,13; c: 4,00; d: 4,15. Por tanto, no existen grandes discrepancias en la valoración de las distintas propuestas cuando éstas son elegidas en primer lugar. Existen doce líneas en la que la mejor opción se ha valorado con más de 4 (incluso tres han recibido 5, que es el máximo posible) y ninguna con menos de 3.

Observando la columna con la media de la segmentación para las cuatro alternativas, se puede detectar qué líneas tienden a ser más fáciles de segmentar, en caso de que la media sea elevada (que quiere decir que las cuatro opciones han sido puntuadas con valor alto), o cuáles más difíciles (el caso contrario). En rojo se pueden observar los valores de las líneas cuya media es inferior a 3 y que en principio son más difíciles de segmentar de forma automática. Se trata de carreteras de la red provincial o de pistas. Haciendo lo mismo para la clasificación, se detectan tres líneas con valor inferior a 3: una carretera nacional, otra de la red provincial y una pista; además existe una pista con valor superior a 4. Se puede concluir, por tanto, que es más frecuente encontrar líneas con dificultad para ser segmentadas que para ser clasificadas.

IV.5.5. Análisis por categorías de líneas

En la Tabla III.10 se hizo una distinción de categorías de líneas para alimentar la red neuronal, la cual se vuelve a reproducir a continuación en la Tabla IV.65. Es interesante estudiar si la categoría administrativa de la línea marca alguna diferencia a la hora de valorar los resultados de la encuesta. En las tablas IV.66 a IV.70 se presenta el mismo resumen general de la Tabla IV.64, pero esta vez desagregado por las cinco categorías definidas en la Tabla IV.65.

Tabla IV.65 - Categorías de vías de comunicación para alimentar la red neuronal.

Categoría	Nombre	Redes incluidas
1	Autovías	Red de Carreteras del Estado. Red Autonómica. Red Básica.
2	Convencionales 1er orden	Red de Carreteras del Estado. Red Autonómica. Red Básica.
3	Convencionales 2º orden	Red Autonómica. Red Intercomarcal.
4	Convencionales 3er orden	Red Autonómica. Red Complementaria. Red Provincial. Red Comarcal.
5	Otras	Ninguna. Se incluyen las pistas.

Tabla IV.66 - Evaluación de los expertos. Resultados por cada línea (categoría 1).

Línea		Segmentación				Clasificación		
		Mejor caso			Punt. Media	Mejor caso		Punt. Media
		Caso y puntuación		Problemas		Caso y puntuación		
				1 2 3 4 5 Tot				
1	A-44	d	4,00	0 1 3 0 0 4	3,25	d	**4,25**	3,44
3	A-316A	d	3,25	2 0 1 0 0 3	3,00	a b	**5,00**	4,00
Media		- - - -	3,63	1 0,5 2 0 0 3,5	3,13		4,63	3,72
Desviaclón típica			0,53		0,71	0,18		0,53	0,4
Frecuencia		0 0 0 2	-	2 1 4 0 0	-	-	1 1 0 1	-	-
Máximo		- - - -	4	2 1 3 0 0	4	3,25	- - - -	5	4
Mínimo		- - - -	3,25	0 0 1 0 0	3	3	- - - -	4,25	3,44

Tabla IV.67 - Evaluación de los expertos. Resultados por cada línea (categoría 2).

Línea		Segmentación				Clasificación		
		Mejor caso			Punt. Media	Mejor caso		Punt. Media
		Caso y puntuación		Problemas		Caso y puntuación		
				1 2 3 4 5 Tot				
2	N-323	a c	3,50	0 1 0 2 0 3	3,22	a	3,50	***2,81***
4	A-316	a c	3,67	1 0 1 0 0 2	3,08	b	3,67	3,08
Media		- - - -	3,59	0,5 0,5 0,5 1 0 2,5	3,15		3,59	2,95
Desviación típica			0,12		0,71	0,1		0,12	0,19
Frecuencia		0 0 2 0	-	1 1 1 2 0	-	-	1 1 0 0	-	-
Máximo		- - - -	3,67	1 1 1 2 0 3	3,22	- - - -	3,67	3,08
Mínimo		- - - -	3,5	0 0 0 0 0 2	3,08	- - - -	3,5	2,81

Tabla IV.68 - Evaluación de los expertos. Resultados por cada línea (categoría 3).

Línea		Segmentación				Clasificación		
		Mejor caso		Punt. Media		Mejor caso		Punt. Media
		Caso y puntuación			Problemas	Caso y puntuación		
					1 2 3 4 5 Tot			
5	A-311	a b c d	4,00	4,00	0 0 0 0 0 0	a b c d	4,00	4,00
6	A-320	a	**4,75**	3,75	0 0 1 0 0 1	a	**4,50**	3,50
7	A-324	a	**4,37**	3,16	1 0 1 0 1 3	b	**4,25**	3,41
Media		- - - -	4,37	3,64	0,33 0 0,67 0 0,33 1,33		4,25	3,64
Desviación típica			0,38	0,43	1,53		1,48	1,24
Frecuencia		3 1 1 1	-	-	1 0 2 0 1 -	2 2 1 1	-	-
Máximo		- - - -	4,75	4	1 0 1 0 1 3	- - - -	4,5	4
Mínimo		- - - -	4	3,16	0 0 0 0 0 0	- - - -	4	3,41

Tabla IV.69 - Evaluación de los expertos. Resultados por cada línea (categoría 4).

Línea		Segmentación				Clasificación		
		Mejor caso		Punt. Media		Mejor caso		Punt. Media
		Caso y puntuación			Problemas	Caso y puntuación		
					1 2 3 4 5 Tot			
8	A-1102	a	3,33	***2,50***	0 1 1 0 0 2	b	3,33	4,00
9	JV-2222	a	**4,33**	3,25	0 1 1 0 0 2	a	4,00	3,08
10	JV-2223	d	3,25	***2,75***	1 0 2 0 0 3	a	**5,00**	3,38
11	JV-2224	d	3,50	***2,88***	0 0 1 1 0 2	c	3,75	3,31
12	JV-2225	a	4,00	3,25	0 1 0 0 1 2	a b	**4,75**	4,00
13	JV-2226	b d	3,75	3,50	0 0 1 0 0 1	d	**4,50**	4,00
14	JV-3012	a d	**4,50**	3,63	0 0 0 0 1 1	a	3,75	3,19
15	JV-3241	a	**4,25**	***2,95***	0 0 0 0 0 0	a	**5,00**	3,63
16	JV-3242	a	4,00	3,13	0 0 2 0 0 2	a c	**4,50**	3,56
17	JP-2332	b	**4,25**	***2,81***	1 0 1 0 2 4	d	3,75	***2,94***
Media		- - - -	3,92	3,07	0,2 0,3 0,9 0,1 0,4 1,9		4,23	3,51
Desviación típica			0,44	0,35	1,1		0,59	0,4
Frecuencia		6 1 0 4	-	-	2 3 9 1 4 -	5 2 2 2	-	-
Máximo		- - - -	4,5	3,63	1 1 2 1 2 4	- - - -	5	4
Mínimo		- - - -	3,25	2,5	0 0 0 0 0 0	- - - -	3,33	2,94

Tabla IV.70 - Evaluación de los expertos. Resultados por cada línea (categoría 5).

Línea		Segmentación				Clasificación		
		Mejor caso		Punt. Media		Mejor caso		Punt. Media
		Caso y puntuación			Problemas	Caso y puntuación		
					1 2 3 4 5 Tot			
18	P-CaminoAncho	a b c	3,50	3,00	0 2 0 2 0 4	a b c	3,50	3,19
19	P-CaminoAzadillas	a	3,75	3,00	2 0 1 0 1 4	c	**4,25**	3,75
20	P-CerroAlmaden	c	3,25	***2,25***	0 0 3 0 0 3	d	**4,25**	3,63
21	P-CerroJabalcuz	b	3,75	3,31	0 3 1 0 0 4	b	**4,50**	**4,13**
22	P-CerroSantin	c	4,00	***2,67***	0 0 2 0 0 2	c	4,00	3,25
23	P-Pegalajar-Central	a	3,75	***2,88***	0 0 1 0 0 1	a	3,75	***2,94***
24	P-SierraPeñaÁguila	d	3,75	3,00	1 0 3 0 0 4	a	3,75	3,44
Media		- - - -	3,68	2,87	0,43 0,71 1,57 0,29 0,14 3,14		4	3,48
Desviación típica			0,24	0,33	1,21		0,35	0,4
Frecuencia		3 2 3 1	-	-	3 5 11 2 1 -	3 2 3 1	-	-
Máximo		- - - -	4	3,31	2 3 3 2 1 4	- - - -	4,5	4,13
Mínimo		- - - -	3,25	2,25	0 0 0 0 0 1	- - - -	3,5	2,94

En la Tabla IV.71 se sintetizan algunos resultados de las tablas IV.66 a IV.70 para poder detectar de forma más cómoda distintos comportamientos que pudieran detectarse en las distintas categorías de línea consideradas. Se pueden extraer las siguientes conclusiones:

- Las 2 líneas de la categoría 1 se consideran mejor segmentadas con el caso (d). Las 2 líneas de la categoría 2 se consideran mejor segmentadas con el caso (c). La mayor parte de líneas de las categorías 3 y 4 se consideran mejor segmentadas con el caso (a). La categoría 5 tiene sus mejores segmentaciones repartidas entre los 4 casos.
- En segmentación, la categoría en la que el mejor caso suele ser más puntuado es la 3 (4,37). Las 1, 2 y 5 tienen puntuaciones similares e inferiores. La 4 (3,92) se encuentra en una posición intermedia. Observando las puntuaciones medias, la categoría 3 obtiene la mejor puntuación (3,64), siendo la peor la de la categoría 5 (2,87).
- Las 2 líneas de la categoría 1 tienen su mejor clasificación repartida entre los casos (a), (b) y (d), y las 2 líneas de la categoría 2, repartidas entre los casos (a) y (b). Los casos más frecuentes en la categoría 3 residen en los casos (a) y (b). La mayor parte de líneas de la categoría 4 se consideran mejor clasificadas con el caso (a). La categoría 5 tiene sus mejores clasificaciones repartidas entre los 4 casos.
- En clasificación, la categoría en que el mejor caso suele ser más puntuado es la 1 (4,63). Las categorías 3 y 4 siguen teniendo una puntuación elevada (4,25 y 4,23) respectivamente, mientras la categoría 5 tiene el valor más bajo (3,59). Observando las puntuaciones medias, ninguna destaca sobre las demás por un valor alto, aunque sí destaca la categoría 2 por su baja puntuación.

Tabla IV.71 - Resumen de resultados por categorías.

Categoría	n	Segmentación				Clasificación			
		Mejor caso		Media		Mejor caso		Media	
		Freq. a b c d	Punt	Punt		Freq. a b c d	Punt	Punt	
1	2	0 0 0 2	3,63	3,13		1 1 0 1	4,63	3,72	
2	2	0 0 2 0	3,59	3,15		1 1 0 0	3,59	2,95	
3	3	3 1 1 1	4,37	3,64		2 2 1 1	4,25	3,64	
4	10	6 1 0 4	3,92	3,07		5 2 2 2	4,23	3,51	
5	7	3 2 3 1	3,68	2,87		3 2 3 1	4,00	3,48	

También es interesante realizar un análisis cluster para comprobar cómo se pueden agrupar las líneas según la puntuación de la segmentación o la clasificación. Así, se ha realizado además un análisis cluster no jerárquico de 3 grupos que permita distinguir líneas con puntuación alta (cluster 1), media (cluster 2) y baja (cluster 3). Esta operación ha sido efectuada tanto a partir de la puntuación media de las 4 soluciones (a, b, c, d) como a partir de la puntuación media de la solución con valor más alto (mejor solución).

En la Tabla IV.72 se resume el resultado de los 4 análisis cluster (2 para la segmentación y 2 para la clasificación), indicando el valor de cada cluster y señalando con una "x" qué líneas pertenecen al cluster. Se puede observar que, en cada análisis, la diferencia del cluster 1 al cluster 2 y del cluster 2 al cluster 3, suele ser del orden de 0,5 puntos. También se comprueba que en todos los análisis el cluster 2, que aglutina las líneas con puntuación media, siempre presenta un mayor número de líneas que los cluster 1 y 3. Estos cluster, 1 y 3, suelen presentar un número de líneas bastante inferior y similar entre sí (excepto el análisis cluster de clasificación con los mejores valores, donde el cluster 3 tiene asignadas 9 líneas y el cluster 1 sólo 4). Además, en dicha tabla se han indicado en color gris aquellas líneas que coinciden en el mismo cluster tanto en el análisis que toma el valor medio como el de la mejor solución; en el caso de la segmentación hay 12 líneas (50%) que se encuentran en el mismo cluster y 14 en la clasificación (58%). Por tanto se comprueba la diferencia que exhiben los resultados considerando un análisis con un conjunto de valores u otro (media o mejor solución).

Tabla IV.72 - Análisis cluster de la segmentación y clasificación según la mejor puntuación y la media.

		Cluster	Valor	Casos	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24
segmentación	mejor	1	4,4	6						x	x		x					x	x		x							
		2	3,9	11	x			x	x							x	x			x			x		x	x	x	x
		3	3,4	7		x	x					x		x	x							x		x				
	media	1	3,7	4					x	x							x	x										
		2	3,1	16	x	x	x	x			x		x		x	x			x	x	x	x	x		x		x	x
		3	2,5	4								x		x										x		x		
clasificación	mejor	1	4,9	4			x							x		x				x								
		2	4,3	11	x				x	x	x		x				x			x			x	x	x	x		
		3	3,6	9		x		x				x			x			x			x	x					x	x
	media	1	4,0	7			x		x			x				x	x						x		x			
		2	3,5	10	x					x	x			x	x				x	x				x		x		x
		3	3,0	7		x		x					x					x			x	x					x	

Como principal conclusión de este análisis cluster, se va a fijar la atención en los análisis realizados con la media y en los cluster extremos (1 y 3), para así detectar líneas que tienen tendencia a ser difíciles o fáciles de ser segmentadas o clasificadas, según se presenta en la Tabla IV.73.

Tabla IV.73 - Detección de líneas fáciles y difíciles de segmentar y clasificar según el análisis cluster de valores medios.

Segmentación			Clasificación		
Fáciles	5 - A-311	(3)	Fáciles	3 - A-316A	(1)
	6 - A-320	(3)		5 - A-311	(3)
	13 - JV-2226	(4)		8 - A-1102	(4)
	14 - JV-3012	(4)		12 - JV-2225	(4)
				13 - JV-2226	(4)
				19 - P-CaminoAzadillas	(5)
				21 - P-CerroJabalcuz	(5)
Difíciles	8 - A-1102	(4)	Difíciles	2 - N-323	(2)
	10 - JV-2223	(4)		4 - A-316	(2)
	20 - P-CerroAlmaden	(5)		9 - JV-2222	(4)
	22 - P-CerroSantin	(5)		14 - JV-3012	(4)
				17 - JP-2332	(4)
				18 - P-CaminoAncho	(5)
				23 - P-Pegalajar-Central	(5)
Nota: en paréntesis se indica la categoría a la que pertenece cada línea					

A la vista de la Tabla IV.73 son fáciles de segmentar algunas líneas de las categorías 3 y 4, y difíciles algunas líneas de las categorías 4 y 5. Serían fáciles de clasificar algunas líneas de las categorías 1, 3, 4 y 5, y difíciles algunas líneas de las categorías 2, 4 y 5. Así, no parece poder establecerse una relación entre líneas fáciles o difíciles de segmentar y las cinco categorías de líneas de la Tabla IV.5. Si acaso las principales deducciones que se pueden extraer indican que las líneas de las categorías 4 y 5 son tan heterogéneas como para mostrar casos

considerados fáciles y difíciles tanto en segmentación como en clasificación; las categorías 1 y 3 no presentan ningún caso que se considera problemático para segmentar o clasificar. En cualquier caso, el número de líneas de la muestra debería ser más amplio para tratar de extraer conclusiones en este sentido.

IV.5.6. Conclusiones de la evaluación de expertos

En primer lugar se ha de decir que el número de expertos ha sido de 19 de los 20 inicialmente previstos, detectando comportamientos más críticos o satisfechos en cuanto a la segmentación y clasificación. Las principales conclusiones que se pueden extraer son:

- La red neuronal ha sido bien entrenada, es decir, el patrón de entrenamiento se ha considerado adecuado, tanto por la muestra de secciones presentada, como por la clasificación de estas secciones.
- En general, se valoran más positivamente los resultados de las tareas de clasificación que las de segmentación.
- Existen líneas que son más fáciles de segmentar y clasificar, que tienen tendencia a ser mejor valoradas.
- La segmentación más valorada es la del caso (a) (semiautomática con la que se entrena la red neuronal). La menos valorada es la del caso (b) (red neuronal), pero con valoración similar a los casos c (áreas efectivas) y d (wavelet).
- La segmentación en la que se indican más problemas es la del caso (b) (red neuronal). La de menos problemas es la del caso (a) (semiautomática). El problema más frecuente es la segmentación en lugares inadecuados. El caso (d) (wavelet) es el que presenta más problemas de esta tipología.
- La clasificación más valorada es la del caso (a) (clasificación manual para el entrenamiento de la red neuronal). La menos valorada es la del caso d (wavelet).
- Tanto en segmentación como en clasificación, el caso (a) es el que ha sido elegido como el mejor en mayor número de ocasiones, con una puntuación

muy elevada. El resto de propuestas también presentan puntuaciones elevadas en las ocasiones en que han sido elegidas como las mejores.

- Observando los valores medios de puntuación por cada línea, se detectan líneas con dificultad para ser segmentadas, no tanto así para ser clasificadas.
- Atendiendo a las categorías de las líneas, destaca como más valorada en segmentación la categoría 3 (carreteras convencionales 2º orden); la menos valorada es la categoría 2 (carreteras convencionales 1er orden) pero con valores similares al resto de categorías. Como más valorada en clasificación destaca la categoría 1 (autovías); destaca como menos valorada la categoría 2 (carreteras convencionales 1er orden). El análisis cluster ha permitido detectar líneas que a priori han sido fáciles o difíciles de segmentar o clasificar, pero no ha podido establecer un vínculo claro con las categorías establecidas.

Capítulo V
Conclusiones

Las hipótesis de partida que se fijaron al principio del trabajo se han confirmado en tanto que se han alcanzado los objetivos que se plantearon:

- Se han concebido, desarrollado y analizado tres técnicas diferentes de segmentación de elementos lineales: segmentación mediante áreas efectivas (apartado IV.1), segmentación mediante wavelets (apartado IV.2) y segmentación mediante una red neuronal (apartado IV.4).
- Mediante Análisis de Componentes Principales, se ha obtenido un conjunto de medidas caracterizadoras incorreladas para enriquecer la información de un elemento lineal (apartado IV.3.2).
- Se ha propuesto, a partir de un análisis de resultados con distintas estructuras, un modelo de red neuronal para la clasificación automática de secciones según su sinuosidad (apartado IV.3.3).
- Todos los resultados, tanto de las técnicas de segmentación como la de clasificación por la red neuronal, se han sometido a un análisis externo por parte de un panel de expertos (apartado IV.5).

Así, la principal aportación al campo de la generalización cartográfica es la concepción de las tres técnicas de segmentación de elementos lineales indicadas y de una estructura de una red neuronal artificial para la clasificación de estas secciones, a partir de un enriquecimiento basado en medidas cuantitativas no correladas. Esto permite disponer de más información para tomar decisiones sobre los operadores de generalización a aplicar sobre esta información, según la escala y propósito del producto final.

Además, los resultados obtenidos permiten realizar las siguientes puntualizaciones, recomendaciones o limitaciones, comenzando por las relativas a la segmentación automática:

- Si bien cada técnica de segmentación propuesta viene gobernada por uno o varios parámetros, en cada una de ellas se ha realizado una proposición de valores para su aplicación sobre la fuente de datos de partida (vías de comunicación MTN25). Esto permitiría la automatización del proceso de segmentación, aunque siempre se pueden manejar estos parámetros para obtener un resultado semiautomático.
- La valoración de los expertos ha sido muy positiva para la segmentación que ha servido para entrenar la red neuronal artificial. Su puntuación ha sido superior a la obtenida por las tres propuestas automáticas, lo que confirma que este conjunto de secciones ha sido acertado para entrenar la red. Dado que aquella segmentación es semiautomática, esto viene a decir que el manejo interactivo de los parámetros de control de la segmentación permiten mejorar una solución que sea totalmente automática.
- La utilización de cada técnica de segmentación mediante los parámetros propuestos ha sido valorada por el panel de expertos. Las tres propuestas han recibido una valoración parecida, si bien se ha preferido en mayor número de veces la técnica de segmentación por wavelet, seguida por la de las áreas efectivas y por último por la realizada por la red neuronal. Además, para ésta última es para la que se indica un mayor número de problemas; no obstante, esta técnica se puede mejorar en tanto se mejore el entrenamiento de la red neuronal propuesta para la tarea de clasificación automática.
- Como limitación a los resultados, son aplicables a vías de comunicación del MTN25, por lo que en principio no serían extrapolables a otra fuente diferente. Lo mismo ocurre con los valores propuestos para los parámetros de los métodos de segmentación.
- En cualquier caso, dicho esto último, se ha demostrado la viabilidad de las metodologías de segmentación, por lo que se podrían aplicar sobre otros datos (hidrografía por ejemplo), para lo que se deberían analizar los valores que serían más adecuados para los parámetros en cada caso.

En cuanto a la clasificación automática:

- El patrón de entrenamiento de la red neuronal ha sido muy bien valorado por los expertos, por encima de otras propuestas de segmentación y clasificación que se presentaban para su valoración, lo que redunda en la confianza del entrenamiento efectuado.
- La clasificación automática efectuada por la red neuronal sobre cualquiera de las tres soluciones de segmentación automática ha sido bien valorada, siguiendo el siguiente orden: segmentación mediante la red neuronal, mediante áreas efectivas y mediante wavelets.
- La red neuronal artificial se ha creado para realizar las tareas de clasificación de vías de comunicación del MTN25, por lo que sería conveniente entrenar la red con otro tipo de elementos si se quisiera aplicarla sobre ellos. Además, no se puede asegurar que las medidas caracterizadoras utilizadas para enriquecer la información sean exactamente las mismas para otro tipo de elementos lineales. Aunque es de presuponer que habría poca variación, sería adecuado revisar el estudio para la selección de las medidas.
- Otra limitación a la red derivada es que se ha entrenado con un conjunto de datos relativamente reducido. Para poder asimilar esta red como herramienta para clasificar cualquier vía de comunicación, o una de sus secciones, del MTN25 se hace necesario ampliar el patrón de entrenamiento para aumentar la capacidad de adaptación de la red a diferentes situaciones (capacidad de generalización de la red).
- Se ha ensayado la aplicación práctica de la red neuronal para una tarea diferente como es la de la segmentación automática (dependiente del proceso de clasificación automática). Los resultados, y su valoración por los expertos, no han sido tan positivos como se esperaba, pero son susceptibles de mejora en tanto se mejore el entrenamiento de la propia red neuronal con un patrón más amplio.

Finalmente, se indica a continuación cómo podría darse continuación al trabajo desarrollado en esta tesis doctoral, bien para mejorar los resultados, o para

aplicarlos, como es el caso de dar continuidad al proceso de generalización de elementos lineales o emplear la red neuronal sobre otros trabajos:

- El desarrollo de medidas que indiquen el grado de satisfacción con el que se ha realizado la segmentación permitiría mejorar la automatización de la segmentación, ya que se podría escoger la mejor solución entre la ofrecida mediante diferentes metodologías o diferentes valores de los parámetros. Se trataría de medidas evaluadoras de la segmentación, diferentes a las medidas caracterizadoras empleadas en este trabajo, que deberían ser acordes con las valoraciones realizadas por el patrón de expertos.
- Como continuación lógica y aprovechamiento directo de este trabajo, se debería estudiar qué operadores de generalización, y con qué valor de sus parámetros, se han de aplicar en cada sección para derivar diferentes cartografías a menor escala y/o de propósito diferente.
- Una vez comprobada la utilidad de una red neuronal artificial para segmentación y clasificación automáticas de elementos lineales, se propone investigar la aplicación de otras estructuras neuronales utilizadas en otros campos como el del reconocimiento de voz, en los que la tecnología está plenamente asentada, para efectuar una transferencia al campo de la generalización cartográfica.
- También se propone explotar la red neuronal obtenida para su aplicación en otros trabajos de investigación, como es el caso del Proyecto de Investigación Nacional *Control posicional de cartografía mediante elementos lineales*, del cual es responsable el director de esta tesis. Se trata de un estudio que persigue el desarrollo de metodologías de evaluación de la exactitud posicional de la cartografía a partir de vías de comunicación. En tanto que la sinuosidad de las vías podría influir en la calidad de la captura de los datos, la exactitud posicional, planimétrica y/o altimétrica podría ser sensible a esta variable.
- Además, sería de interés, la aplicación de la segmentación y clasificación automáticas sobre mapas de carreteras. Por un lado permitiría poner a disposición del usuario información sobre la sinuosidad de la ruta de su elección. Por otro lado, permitiría mejorar los motores de búsqueda de la mejor ruta en los

mapas interactivos en línea, ya que la velocidad nominal de cada vía se vería reducida según la clase a la que perteneciera cada una de las secciones que la forman.

- Por último, a través del programa académico sobre generalización (GAP, Generalisation Academic Programme) de Laser-Scan, se ha contactado con esta compañía para integrar los resultados obtenidos en su producto Clarity, que recientemente ha salido al mercado y del que se dispondrá de licencia gratuita. El objetivo final de este programa es el de transferir al usuario los resultados de la investigación básica realizada en el seno de la comunidad académica.

Referencias

Affholder, J. G. (1993). Road modelling for generalization. NCGIA Research Initiative 8. Formalizing Cartographic Knowledge. Specialist Meeting Buffalo.

AGENT (1999). *Report D C1. Selection of Basic Measures.* Project AGENT (ESPRIT / LTR / 24 939).

Allouche, M. K.; Moulin, B. (2002). Una approche à base de cartes de Kohonen pour la généralisation cartographique de zones de points de forte densité. En: Ruas, A. (dir.). *Généralisation et représentation multiple*. Lavoisier, Paris. pp 337-352.

Allouche, M. K.; Moulin, B. (2005). Amalgamation in cartographic generalization using Kohonen's feature nets. *International Journal of Geographical Information Science*, 19(8-9): 957-973.

Arkin, E.; Chew, P.; Huttenlocher, D.; Kedem, K.; Mitchell, J. (1991). An efficient computable metric for comparing polygonal shapes. *IEEE transactions on pattern analysis and machine intelligence*, 13(3): 209-216.

Ariza, F. J. (2002). *Calidad en la Producción Cartográfica*. Ra-Ma. Madrid.

Ariza, F. J.; García, J. L.; Reinoso, J. F. (2005). Segmentation of lines by means of Douglas Peucker applied to effective areas of the Visalingam and Whyatt algorithm. *Proceedings 22th International Cartographic Conference*. La Coruña (Spain).

Ariza, F. J.; Pinilla, C. (1996). Control de calidad del proceso de clasificación de imágenes de satélite. *Mapping*, 34: 74-86.

Asonov, D.; Agrawal, R. (2004). Keyboard Acoustic Emanations. 2004 *IEEE Symposium on Security and Privacy*. Oakland, California, mayo de 2004.

Attneave, F. (1954). Some informational aspects of visual perception. *Psychological Review*, 61(3): 183-93.

Australian Survey (1992). *TOPO-250k Data User Guide*. Belconnen: Australian Surveying and Land Information Group.

Ballard, D. H. (1981). Strip trees: A hierarchical representation for curves. *Communications of the Association for Computing Machinery*, 24(5): 310-321.

Ballard, D. H.; Brown, C. M. (1982). *Computer Vision*. Englewood Cliffs (New Jersey): Prentice-Hall Inc.

Barrault, M. (1998). *Le placement cartographique des ecritures: resolution d'un probleme a forte combinatoire et presentant un grand nombre de contraintes variees.* PhD Dissertation. Director: Jean-Yves Thibom. Marne-la-Vallee University, France.

Barber, C.; Cromley, R.; Andrle, R. (1995). Evaluating alternative line simplification strategies for multiple representations. *Cartography and Geographic Information Systems*, 22(4): 276-290.

Beard, M. K. (1991a). Theory of the cartographic line revisited: Implications for automated generalization. *Cartographica*, 28(4): 32-58

Beard, M. K. (1991b). Constraints on rule formation. En: Buttenfield B. P.; McMaster, R. B. (eds.). *Map generalization: Making rules for knowledge representation*. Harlow (England): Lognman Scientific & Technical. pp. 132-135.

Bel Hadj Ali, A. (1997). *Appariement géométrique des objets géographiques et étude des indicateurs de qualité* (Mémoire de fin de stage, DEA SIG / GIS Masterthesis, ed. Vauglin). COGIT, IGN, Paris, France.

Bernhardt, M. C. (1992). *Quantitative Characterization of Cartographic Lines for Generalization*. Report no. 425. Columbus, OH: Department of Geodetic Science and Surveying. Ohio State University.

Bisquerra, R. (1989). *Introducción conceptual al análisis multivariable. Un enfoque informático con los paquetes SPSS-X, BMDP, LISREL y SPAD* (2 vols.). Barcelona: PPU.

Bjørke, J. T.; Midtbø, T. (1993). Generalization of digital surface models. *Proceedings 9th International Cartographic Conference*. Cologne. pp 363-371.

Boesch, R. (1993). *Modellierung von Niederschlagsverlagerungen mit Radardaten*. Geo-Processing Reihe, 21, Geographisches Institut der Universität Zürich.

Bortolan, G.; Degani, R.; Willems, J. (1990). Neural Networks for ECG Classification. *Proceedings of the IEEE Conference on Computers in Cardiology*: 269-272. Chicago.

Boutoura, C. (1989). Line generalization using spectral techniques. *Cartographica*, 26(3&4): 33-48.

Boyle, A. R. (1970). The Quantised Line. *The Cartographic Journal*, 7(2): 91-94.

Brassel, K. E. (1985). Strategies and data models for computer-aided generalization, *Annuaire International de Cartographie*, vol. XXV: 11-29.

Brassel, K. E.; Weibel, R. (1988). A review and framework of automated map generalization. *International Journal of Geographical Information Systems*, 2(3): 229-244.

Broscoe, D.; Prashker, S. (1991). The incorporation of the fractal dimension in cartographic line simplification algorithms. *AutoCarto 90*, Vol 2: 26-35.

Burghardt, D. (2002). Smoothing of line objects with optimization techniques. Abstract. *ISPRS/ICA Workshop on Multi-Scale Representations of Spatial Data*. Ottawa.

Buttenfield, B. P. (1986). Digital definitions of scale-dependent line structure. *Proceedings AUTO-CARTO*. London: Royal Institution of Chartered Surveyors. Vol. 1: 497-506.

Buttenfield, B. P. (1989). Scale-dependence and self-similarity in cartographic lines. *Cartographica*, 26(2): 79-100.

Buttenfield, B. P. (1991). A rule for describing line feature geometry. En: Buttenfield B. P.; McMaster, R. B. (eds.). *Map generalization: Making rules for*

knowledge representation. Harlow (England): Lognman Scientific & Technical. pp. 150-171.

Campbell, J. (1993). *Map use and analysis;* 2nd edition. Dubuque (Iowa): Wm. C. Brown Publishers.

Cañada, A. (1994). *Series y Transformada de Fourier y Aplicaciones*. Universidad de Granada.

Christensen, A. H. J. (1999). Cartographic Line Generalization with Waterlines and Medial-Axes. *Cartography and Geographic Information Science*, 26(1): 19, 32.

Christensen, A. H. J. (2000). Line Generalization by Waterlining Anda Medial-Axis Transformation. Successes and Issues in an Implementation of Perkal's Proposal. *The Cartographic Journal*, 37(1): 19-28.

Clarke, K. C.; Cippoletti, R.; Olsen, G. (1993). Empirical Comparison of Two Line Enhancement Methods. *AutoCarto 11 Proceedings.* Minneapolis: ACSM-ASPRS, 1: 73-81.

Clayton, V. H. (1985). *Cartographic Generalization: A review of feature simplification and systematic point elimination algorithms*. NOAA Technical Report NOS 112. National Oceanic and Atmospheric Administration U.S. Department of Commerce. Rockville, MD.

Cromley, R. G. (1992). *Digital cartography*. Englewood Cliffs (New Jersey): Prentice Hall Inc.

Cromley, R. G.; Campbell, G. M. (1990). A geometrically efficient bandwidth line simplification algorithm. En: *Proceedings of the 4th International Symposium on Spatial Data Handling*. Zurich, August 1990. Vol. 1, 77-84.

Cromley, R. G.; Campbell, G. M. (1992). Integrating quantitative and qualitative aspects of digital line simplification. *The Cartographic Journal*, 29(1): 25-30.

Davis, J. C. (1986). *Statistics and Data Analysis in Geology*; 2nd Edition. USA: John Wiley & Sons, USA.

Demazeau, Y. (1997). Steps towards Multi-Agent Oriented Programming. *1st International Workshop on Multi-Agent Systems*, IWMAS 97, Boston, 1997.

Denis, S.; McAuley, D. (1998). The BackPropagation Network: Learning by Example. En: Denis, S.; McAuley, D. *Connectionist Models of Cognition* [en línea]. Disponible en Internet en la URL [consulta 20/12/2005]. <http://www.itee.uq.edu.au/~cogs2010/cmc>.

Dirección General de Carreteras (2000). *Trazado: instrucción de carreteras. Norma 3.1-IC*. Dirección General de Carreteras. Ministerio de Fomento. Madrid.

Douglas, D. H.; Peucker, T. K. (1973). Algorithms for the reduction of the number of points required to represent a digitized line or its character. *The American Cartographer*, 10(2): 112-123.

Dutton, G. (1998). *A Hierarchical Coordinate System for Geoprocessing and Cartography*. Lecture Notes in Earth Sciences, vol. 79. Springer-Verlag, 230 pp.

Dutton, G. (1999). Scale, Sinuosity, and Point Selection in Digital Line Generalization. *Cartography and Geographic Information Science*, 26(1): 33-53.

Esri (1994). *ARCEDIT Commands*. ARC/INFO version 7 Manual. ESRI, Inc.

Feito, F.; Conde, F. de A.; Segura, R. J. (1995). *Informática Gráfica Teoría y Práctica.* Servicio de Publicaciones e Intercambio Científico. Universidad de Jáen.

Fico, F. J. (1992). *Opportunities for Generalization in the Digital Chart of the World*. NCGIA Technical Report 92-2. Buffalo: State University of New York.

Finke, M., Müller, K.-R. (1994). Estimating a-posteriori probabilities using stochastic network models. En: Mozer, M., Smolensky, P., Touretzky, D.S., Elman, J.L. and Weigend, A.S. (Eds.), *Proceedings of the 1993 Connectionist Models summer school*. Hillsdale, NJ: Erlenbaum Associates, 324-331.

Freeman, H. (1978). Shape description via the use of critical points. *Pattern Recognition*, 10: 2-14.

Fritsch, E. (1994). Recherche d'outils et de représentations pour la généralisation. *Technical report IGN-ENSG.*

Fritsch, E. (1997). *Représentation de la géométrie et des contraintes cartographiques pour la généralisation du linéaire routier*. Ph. D. Dissertation. Director: Jacques Désarménien. France: Université de Marne la Vallée.

Fritsch, E.; Lagrange, J. P. (1995). Spectral representations of linear features for generalization. En: Frank, A. U.; Kühn, W. (eds.). *COSIT'95, a theoretical basis for GIS*. Berlin: Springer Verlag, 157-171.

García, J. L. (1998). *Generalización de elementos lineales mediante algoritmos en el dominio espacial y de la frecuencia*. Proyecto Fin de Carrera. Director: Ariza, F. J. Departamento de Ingeniería Cartográfica, Geodésica y Fotogrametría. Universidad de Jaén.

García, J. L.; Ariza, F. J. (1999). Metodología para el Filtrado Frecuencial de Elementos Lineales mediante Wavelet*. Mapping*, 55: 40-49.

García, J. L.; Ariza, F. J. (2000a). Arcos Cúbicos en la Generalización de Elementos Lineales. Método y Aplicación. *Mapping*, 59: 6-16*.*

García, J. L.; Ariza, F. J. (2000b). Frequency Filtering of Linear Features by Means of Wavelets. A method and an Example. *The Cartographic Journal*, 37(1): 39-49*.*

García, J. L.; Ariza, F. J. (2005). Road line segmentation for cartographic generalization: a wavelet based procedure. *Proceedings 22th International Cartographic Conference*. La Coruña (Spain).

García, J. L.; Ariza, F. J.; López, R. (2005). Road line classification for cartographic generalization: a neural net approach. *Proceedings 22th International Cartographic Conference*. La Coruña (Spain).

García, J. L.; Reinoso, J. F.; Ureña, M. A.; Ariza, F. J. (2001). El algoritmo de Thapa Bidireccional Recursivo en el filtrado de elementos lineales en la generalización cartográfica. *Actas del XIII Congreso Internacional de Ingeniería Gráfica*. Badajoz: Universidad de Extremadura.

García, J. L.; Ureña, M. A.; Reinoso, J. F.; Ariza, F. J. (1999). Comparación entre Dos Algoritmos de Generalización de Elementos Lineales: Douglas-Peucker

y Visvalingam. *Actas del XI Congreso Internacional de Ingeniería Gráfica.* Logroño - Pamplona: Universidad Pública de Navarra / Universidad de La Rioja, 1003-1010.

Goodchild, M. F.; Mark, D. M. (1987). The fractal nature or natural phenomena. *Annals of the Association of American Geographers*, 77(2): 265-278.

Greenwald, L.; Artz, D. (2004). Teaching Artificial Intyelligence with Low-Cost Robots. *AAAI symposium on AI and Robotics education*. Stanford University. California, marzo de 2004.

Hangouët, J. F. (1995). Computation of the Hausdorff distance between plane vector polylines. *AutoCarto12. ACSM/ASPRS Annual Convention & Exposition Technical Papers*. Bethesda: ACSM/ASPRS, vol. 4:1-10.

Hangouët, J. F. (1998). *Approche et méthodes pour l'automatisation de la généralisation cartographique; application en bord de ville*. Ph. D. Thesis. Director: Jean-Claude Müller. France: Université de Marne la Vallée.

Hardy, P. G. (1998). Map Production from An Active Object Database, Using Dynamic Representation and Automated Generalisation. *The Cartographic Journal*, 35(2): 181-189.

Harman, H. H. (1980). *Análisis factorial moderno*. Saltés, Madrid.

Herbert, G.; João, E. M.; Rhind (1992). Use of an Artificial Intelligence Approach to Increase User Control of Automatic Line Generation. *Proceedings of EGIS '92.* Munich: EGIS Foundation, 1: 554-563.

Hilera, J. R.; Martínez, V. J. (1995). *Redes Neuronales Artificiales. Fundamentos, modelos y aplicaciones*. RA-MA, Madrid.

Institut Cartogràphic de Catalunya (1997). Aplicación de herramientas de generalización automática para el Mapa topogràfic de les comarques de l'Ebre 1:100.000. *Hoja informativa del Institut Cartogràfic de Catalunya*, 5 (diciembre 1997): 2.

Instituto de Cartografía de Andalucía (1996). Hoja 94712. *Mapa Topográfico de Andalucía 1:10.000*. Instituto de Cartografía de Andalucía. Consejería de Obras Públicas y Transportes. Junta de Andalucía. Sevilla.

Instituto de Cartografía de Andalucía (2003). Jaén. *Mapa oficial de carreteras de Andalucía*. *Serie provincial 1:200.000*. Instituto de Cartografía de Andalucía. Consejería de Obras Públicas y Transportes. Junta de Andalucía. Sevilla.

Instituto Geográfico y Catastral (1971). Hoja 947. Jaén. *Mapa Topográfico Nacional de España 1:50.000.* Instituto Geográfico y Catastral. Madrid.

Instituto Geográfico Nacional (1996a). Hoja 947-II. Mancha Real. *Mapa Topográfico Nacional de España 1:25.000.* Instituto Geográfico Nacional. Ministerio de Fomento. Madrid.

Instituto Geográfico Nacional (1996b). Hoja 947-III. Los Villares. *Mapa Topográfico Nacional de España 1:25.000.* Instituto Geográfico Nacional. Ministerio de Fomento. Madrid.

Instituto Geográfico Nacional (1996c). Hoja 947-IV. Cambil. *Mapa Topográfico Nacional de España 1:25.000.* Instituto Geográfico Nacional. Ministerio de Fomento. Madrid.

Instituto Geográfico Nacional (1997). Hoja 947-I. Jaén. *Mapa Topográfico Nacional de España 1:25.000.* Instituto Geográfico Nacional. Ministerio de Fomento. Madrid.

Instituto Geográfico Nacional (1999). Hoja 947. Jaén. *Mapa Topográfico Nacional de España 1:50.000.* Instituto Geográfico Nacional. Ministerio de Fomento. Madrid.

Ip, H. H. S.; Wong, W. H. (1997). Detecting Perceptually Parallel Curves: Criteria and Force-Driven Optimization. *Computer Vision and Image Understanding*, 68(2): 190-208.

Iribas, J. (1997). Obtención del MTN50 por generalización del MTN25 Digital. *Mapping*, 38: 22-28.

Iribas, J. (1999). *Diseño y elaboración de un procedimiento interactivo de obtención del mapa topográfico nacional a escala 1:50.000 por generalización cartográfica del MTN25*. Tesis doctoral. Director: Ferrer, R. Departamento de Ingeniería Geográfica y Técnicas de Expresión Gráfica. Universidad de Cantabria.

Jaakkola, O. (1998). Multi-scale Categorical Data Bases with Automatic Generalization Transformation Based on Map Algebra. *Cartography and Geographic Information Systems*, 24(4): 195-207.

Jacobs, C. (2003). *Average speed prediction using Artificial Neural Networks*. Master thesis. Delf University of Technology. Faculty of Information Technology and Systems. Data and Knowledge Engineering Group.

Jansen, M.; vanKreveld, M. (1998). Evaluating the consistency of cartographic generalization. *Spatial Data Handling '98 Conference Proceedings*. Vancouver (BC), Canada, 668-678.

Jasinski, M. J. (1990). *The comparison of complexity measures for cartographic lines*. Technical Report 90-1. Buffalo, New York: National Center for Geographic Information and Analysis.

Jenks, G. F. (1981). Lines, computers and human frailties. *Annals of the Association of American Geographers*, 71(1):1-10.

João, E. M. (1995). The importance of quantifying the effects of generalization. En: Müller, J. C.; Lagrange, J. P.; Weibel, R. (eds.). *Gis and generalization: Methodology and practice*. London: Taylor & Francis.

Keates, J. (1989). *Cartographic Design and Production*. Longman Scientific & Technical. London.

Kohonen, T. (1984). *Self-Organization and Associative Memory*. Springer. Berlin.

Lamy, S.; Ruas, A.; Demazeau, Y.; Baejis, C.; Jackson, M.; Mackaness, W.; Weibel, R. (1999). AGENT Project: Automated Generalisation New Technology. *5th EC-GIS Workshop*, Stresa, Italy.

Lang, T. (1969). Rules for the robot draughtsmen. *The Geographical Magazine*, 42(1): 50-51.

Lecordix, F.; Plazanet, C.; Lagrange, J. P. (1997). A Platform for Research in Generalization: Application to Caricature. *GeoInformatica*, 1(2): 161-182.

Lehto, L.; Sarjakoski, L. T. (2005). Real-time generalization of XML-encoded spatial data for the Web and mobile devices. *International Journal of Geographical Information Science*, 19(8-9): 957-973.

Li, Z.; Openshaw, S. (1992). Algorithms for automated line generalization based on a natural principle of objective generalization. *International Journal of Geographical Information Systems*, 6(5): 373-389.

Li, Z.; Sui, H. (2000). An Integrated Technique for Automated Generalization of Contour Maps. *The Cartographic Journal*, 37(1): 29-37.

Longley, P. A.; Batty, M. (1989). Fractal measurement and line generalization. *Computer & Geosciences*, 15(2): 167-183.

Lowe, D. G. (1988). Organization of smooth image curves at multiple scales. *Proceedings 2nd International Conference on Computer Vision,* Tarpon Springs, Florida (December 1988), pp. 558-567.

Mackaness, W. (1991). Integration and evaluation of map generalizaction. En: Buttenfield B. P.; McMaster, R. B. (eds.). *Map generalization: Making rules for knowledge representation*. Harlow (England): Lognman Scientific & Technical. p. 217-226.

Mackaness, W. (1995). Analysis of urban networks to support cartographic generalization. *Cartography and Geographic Information Systems*, 22(4): 306-316.

Mandelbrot, B. B. (1967). How long is the coastline of Britain? Statistical self-similarity and fractal dimension. *Science*, 154: 636-638.

Mandelbrot, B. B. (1982). *The Fractal Geometry of Nature*. San Francisco: W. H. Freeman and Co.

Matos, L.; Goncalves, A. (1998). Measurement and Analysis of Positional Error. *Spatial Data Handling '98 Conference Proceedings*. Vancouver (BC), Canada, 151-160.

McMaster, R. B. (1983). *A Quantitative Analysis of Mathematical Measures in Linear Simplification*. Tesis doctoral, Department of Geography-Meteorology, University of Kansas.

McMaster , R. B. (1986). A statistical analysis of mathematical measures for linear simplification. *The American Cartographer*, 13(2): 103-117.

McMaster, R. B. (1987). Automated line generalization. *Cartographica*, 24(2): 74-111.

McMaster, R. B. (1989). Integration of simplification and smoothing algorithms in line generalization. *Cartographica*, 26(1): 101-121.

McMaster, R. B. (1991). Conceptual frameworks for geographical knowledge. En: Buttenfield B. P.; McMaster, R. B. (eds.). *Map generalization: Making rules for knowledge representation*. Harlow (England): Lognman Scientific & Technical. p. 21-39.

McMaster, R. B. (1995). Knowledge acquisition for cartographic generalization: experimental methods. En: Müller, J. C.; Lagrange, J. P.; Weibel, R. (eds.). *Gis and generalization: Methodology and practice*. London: Taylor & Francis.

McMaster, R. B.; Shea, K. S. (1992). *Generalization in Digital Cartography*. Association of American Geographers. Washington D.C.

Moktharian, F.; Mackworth, A. K. (1986). Scale-based description and recognition of planar curves and two-dimensional shapes. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 8(1): 34-43.

Moktharian, F.; Mackworth, A. K. (1992). A theory of multi-scale, curvature based shape representation for planar curves. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 14(8): 789-805.

Morisset, B.; Ruas, A. (1997). Simulation and agent modelling for road selection in generalization. *Proceedings 18th ICA/ACI*. Stockholm. Vol. 3: 1376-1380.

Morrison, J. L. (1974). A theoretical framework for cartographic generalization with emphasis on the process of symbolization. *International Yearbook of Cartography*, 14: 115-127.

Müller, J. C. (1986). Fractal dimension and consistencies in cartographic line representations. *The Cartographic Journal*, 23: 123-130.

Müller, J. C. (1987). Fractal and automatic line generalization. *The Cartographic Journal*, 24: 27-34.

Müller, J. C. (1990). The removal of spatial conflicts in line generalization; *Cartography and Geographic Information Systems*, 17(2): 141-149.

Müller, J. C. (1991). Generalization of spatial data bases. En: Maguire, D.; Goodchild, M.; Rhind, D. (eds.). *Geographical Information Systems: Principles and Applications*, 1: 457-475. London: Longman, Ltd.

Mustiere, S. (1995). *Mesures de la qualité de la généralisation du linéaire*. Université Paris I/ENSG. France.

Mustiere, S. (1998). *Détection et résolution des conflits d'empâtement: une approche adaptative de la généralisation du linéaire routier*. Bulletin d'information n.67, IGN, France.

Mustiere, S. (2001). *Apprentissage supervisé pour la généralisation cartographique.* PhD Dissertation. Director: Jean-Gabriel Ganascia. Université Pierre et Marie Curie, Paris, France.

Mustière, S. (2005). Cartographic generalization of roads in a local and adaptative approach: A knowledge acquistion problem. *International Journal of Geographical Information Science*, 19(8-9): 937-955.

Opheim, H. (1982). Fast reduction of a digitized curve. *GeoProcessing*, 2: 33-40.

Ormsby, D.; Mackaness, W. (1999). The Development of Phenomenological Generalization Within an Object-oriented Paradigm. *Cartography and Geographic Information Science*, 26(1): 70-80.

Perkal, J. (1966). *An attempt at Objective Generalization*. En: Michigan Inter-University Community of Mathematical Geographers, Discussion Paper 10. University of Michigan.

Pinilla, C. (1997). *Transformaciones de Fourier en Teledetección.* Servicio de Publicaciones e Intercambio Científico. Universidad de Jaén.

Plazanet, C. (1995). Measurements, characteristaion and classification for automated linear features generalisation. *Proceedings AutoCarto 12*. Charlotte, NC (USA). Vol 4: 59-68.

Plazanet, C. (1996). *Enrichissement des bases de données geographiques: analyse de la géométrie des objets lineaires pour la généralisation cartographique (application aux routes)*. Ph. D. Dissertation. Director: Jacques Désarménien. France: Université de Marne la Vallée.

Plazanet, C. (1997). Modelling Geometry for linear feature generalisation. En: Craglia, M.; Coucleis, H. (eds.). *Geographic Information Research: Bridging the Atlantic*. London: Taylor and Francis. Part 3, Chapter 17, p. 264-279.

Plazanet, C.; Affholder, J. G.; Fritsch, E. (1995). The importance of geometric modeling in linear feature generalization. *Cartography and Geographic Information Systems*, 22(4): 291-305.

Plazanet, C.; Bigolin, N. M.; Ruas, A. (1998). Experiments with Learning Techniques for Spatial Model Enrichment and Line Generalization. *Geoinformatica*, 2(4): 315-333.

Price, D.; Knerr, S.; Personnaz, L.; Dreyfus, G. (1994). Pairwise Neural Network Classifiers with Probabilistic Outputs. *Neural Information Processing Systems*, 7.

Ramer, U. (1972). An iterative procedure for the polygonal approximation of plane curves. *Computer Graphics and Image Processing*, 1: 244-256.

Ratajski, L. (1967). Phenomenes des points de generalisation. *International Yearbook of Cartography*, 7: 143-151.

Regnauld, N. (1998). *Generalisation du bati: structure spatiale de type graph et representation cartographique*. Ph. D. Thesis. Director: Robert Jeansoulin. Université de Marne la Vallée.

Reichenbacher, T. (1995). Knowledge Acquisition in Map Generalization Using Interactive Systems and Machine Learning. *Proceedings ICA '95*. Barcelona: International Cartographic Association, 2221-30.

Reinoso, J. F. (1998). *Proceso de Generalización de las Vías de Comunicación de la BCN25 para la Derivación Automatizada de la BCN50*. Proyecto Fin de Carrera. Director: Ariza, F. J. Departamento de Ingeniería Cartográfica, Geodésica y Fotogrametría. Universidad de Jaén.

Reinoso, J. F.; García, J. L.; Ureña, M. A.; Ariza, F. J. (1999). Suavizado de líneas, operación necesaria para la obtención de cartografía derivada. *Actas del XI Congreso Internacional de Ingeniería Gráfica.* Logroño - Pamplona: Universidad Pública de Navarra / Universidad de La Rioja, 741-749.

Reinoso, J. F.; Ureña, M. A.; García, J. L.; Ariza, F. J. (2001). Comportamiento del algoritmos de Visvalingam en niveles altos de generalización. *Actas del XIII Congreso Internacional de Ingeniería Gráfica, Badajoz*. Universidad de Extremadura.

Reumann, K.; Witkam A. P. M. (1974). Optimizing curve segmentation in computer graphics. *International Computing Symposium*. Amsterdam: North-Holland Publishing Company, 467-472.

Richardson, L. F. (1961). The problem of contiguity: An appendiz to the statistics of deadly quarrels. *General Systems Yearbook*, 6: 139-187.

Richardson, D. E.; Mackaness, W. A. (1999). Computational Processes for Map Generalization. *Cartography and Geographic Information Science*, 26(1): 3-5.

Robinson, A. H.; Sale, R. D.; (1969). *Elements of Cartography*. 3th edition. New York: John Wiley & Sons, Inc.

Robinson, A. H.; Sale, R. D.; Morrison, J. L. (1978). *Elements of Cartography*. 4th edition. New York: John Wiley & Sons, Inc.

Rosin, P. L. (1993). Multiscale representation and matching of curves using codons. *CVGIP: Graphical Models and Image Processing*, 55(4): 286-310.

Rosin, P. L. (1994). Determining local natural scales of curves. *Proceedings 12th International Conference on Pattern Recognition*. Jerusalem, Israel, vol. 1, p. 185-189.

Ruas, A. (1998). A method for building displacement in automated map generalisation. *International Journal of Geographical Information Science*, 12(8): 789-803.

Ruas, A. (1999). *Modèle de généralisation de données géographiques à base de contraintes et d'autonomie*. Ph. D. Dissertation. Director: Jacques Désarménien. France: Université de Marne la Vallée.

Ruas, A. (2002). Les problématiques de l'automatisation de la généralisation. En: Ruas, A. (dir.). *Généralisation et représentation multiple*. Lavoisier, Paris. pp 75-90.

Ruas, A.; Lagrange, J. P. (1995). Data and knowledge modelling for generalization. En: Müller, J. C.; Lagrange, J. P.; Weibel, R. (eds.). *Gis and generalization: Methodology and practice*. London: Taylor & Francis. pp. 73-90.

Ruas, A.; Plazanet, C. (1996). Strategies for automated map generalization. *Proceedings 7th International Symposium on Spatial Data Handling*. Faculty of Geodetic Engineering, Delft University of Technology. Delft, Netherlands, vol. 2: 319-336.

Rumelhart, D.; Hinton, G.; Williams, R. (1986). Learning representations by back-propagating errors. *Nature*, 323: 533-536.

SAALFELD, A. (1999). Topologically Consistent Line Simplification with the Douglas-Peucker Algorithm. *Cartography and Geographic Information Science*: 26(1): 7-18.

SARLE, W. S. (1995). Stopped Training and Other Remedies for Overfitting. *Proceedings of the 27th Symposium on the Interface of Computing Science and Statistics,* 352-360

SARLE, W. S., ed. (1997), *Neural Network FAQ* [en línea] Periodic posting to the Usenet newsgroup comp.ai.neural-nets. Disponible en Internet en la URL [consulta 06/08/2004] <ftp://ftp.sas.com/pub/neural/FAQ.html>

SAUX, E. (1998). B-spline curve fitting: application to cartographic generalization of maritime lines. *Graphicon'98. Proceedings 8th International Conference on Computer Graphics and Visualization*. Moscow.

SCHUURMAN, N. (1999). Critical GIS: theorizing an emerging discipline. *Cartographica*, 36(4): 1-108.

SESTER, M. (2005). Optimization approaches for generalization and data abstraction. *International Journal of Geographical Information Science*, 19(8-9): 871-897.

SKOPELITI, A.; TSOULOS, L. (1999). On the Parametric Description of the Shape of the Cartographic Line. *Cartographica*, 36(3): 53-65.

SHANNON, C. E.; WEAVER, W. (1948). A Mathematical Theory of Communication. *Bell System Technical Journal*, 27: 379-423, 623-656.

SHEA, K. S. (1991). Design considerations for an artificially intelligent system. En: Buttenfield B. P.; McMaster, R. B. (eds.). *Map generalization: Making rules for knowledge representation*. Harlow (England): Lognman Scientific & Technical. pp.3-20.

SHELBERG, M. C.; MOELLERING, H.; LAM, N. (1982). Measuring the fractal dimension of empirical curves. *Proceedings, AUTO-CARTO 5*, 481-490.

Stollnitz, E. J.; Derose, T. D.; Salesin, D. H. (1996). *Wavelets for Computer Graphics. Teory and applications.* San Francisco: Morgan Kaufmann Publishers, Inc.

Swiss Society of Cartography (1977). *Cartographic generalizaton*. Cartographic Publication Series No. 2. English translation by Allan Brown and Arie Kers, ITC Cartography Department. Enschede, The Netherlands.

Thapa, K. (1988). Automatic line generalization using zero-crossings. *Photogrammetric Engineering and Remote Sensing*, 54(4): 511-517.

Thapa, K. (1989). Data compression and critical points detection using normalized symmetric scattered matrix. *AutoCarto 9*. Bethesda, Md.: American Congress on Surveying and Mapping, 78-89.

Thapa, K. (1990). Data Compressión in Digitized Lines. *Photogrammetric Engineering and Remote Sensing*, 56(4): 517-518.

Tobler, W. R. (1964). *An Experiment in the Computer Generalization of Maps.* Technical Report No. 1, Office of Naval Research Task No. 389-137, Contract No. 1224(48), Office of Naval Research, Geography Branch.

Töpfer, F., y W. Pillewizer (1966). The principles of selection. *The Cartographic Journal*, 3(1): 10-16.

Unisys (1993). *System 9 - D. Operator's Manual*. Unisys Corporation.

Urteaga, L.; Nadal, F. (2001). *Las series del mapa topográfico de España a escala 1:50.000*. Dirección General del Instituto Geográfico Nacional. Subdirección General de Producción Cartográfica. Ministerio de Fomento. Madrid.

U.S. Geological Survey (2001). *The National Map: Topographic Mapping for the 21st Century. Final Report.* Reston, Va., Office of the Associate Director for Geography, U.S. Geological Survey. Disponible en Internet en la URL [consulta 29/03/2005]
<http://nationalmap.usgs.gov/report/national_map_report_final.pdf>

van Oosterom, P. (1995). The GAP-tree, an approach to "on-the-fly" map generalization of an area partitioning. En: Müller, J. C.; Lagrange, J. P.; Weibel,

R. (eds.). *Gis and generalization: Methodology and practice*. London: Taylor & Francis. p. 120-132.

Van der Poorten, P. M.; Jones, C. B. (2002). Characterisation and generalisation of cartographic lines using Delaunay triangulation. *International Journal of Geographical Information Science*, 16(8): 773-794.

Veregin, H. (1999). Line Simplification, Geometric Distorsion, and Positional Error. *Cartographica*, 36(1): 25-39.

Veregin, H. (2000). Quantifying positional error induced by line simplification. *International Journal of Geographical Information Science*, 14(2): 113-130.

Visvalingam, M.; Brown, C. I. (1999). The deconstruction of teragons into decogons. *Computers & Graphics*, 23: 155-167.

Visvalingam, M.; Herbert, S. (1999). A Computer Science Perspective on the Bendsimplification Algorithm. *Cartography and Geographic Information Science*, 26(4): 253-270.

Visvalingam, M.; Whyatt, J. D. (1990). The Douglas-Peucker algorithm for line simplification: Re-evaluation through visualisation. *Computer Graphics Forum*, 9(3): 213-228.

Visvalingam, M.; Whyhatt, J. D. (1991). Cartographic algorithms: Problems of implementation and evaluation and the impact of digitising errors. *Computer Graphics Forum*, 10(3): 225-235.

Visvalingam, M.; Whyatt, J. D. (1993). Line generalization by repeated elimination of points. *The Cartographic Journal*, 30(1): 46-51.

Visvalingam, M.; Williamson, P. J. (1995). Simplification and generalization of large scale data for roads: A comparison of two filtering algorithms. *Cartography and Geographic Information Systems*, 22(4): 264-275.

Wang, Z.; Müller, J. C. (1993). Complex coastline generalization. *Cartography and Geographic Information Systems*, 20(2): 96-106.

Wang, Z.; Müller, J. C. (1998). Line Generalization Based on Analysis of Shape Characteristics. *Cartography and Geographic Information Systems*, 25(1): 3-15.

Weibel, R. (1991). Amplified intelligence and rule-based systems. En: Buttenfield B. P.; McMaster, R. B. (eds.). *Map generalization: Making rules for knowledge representation*. Harlow (England): Lognman Scientific & Technical. p. 172-186.

Weibel, R. (1995a). Map generalization in the context of digital systems. *Cartography and Geographic Information Systems*, 22(4): 259-263.

Weibel, R. (1995b). Three essential building blocks for automated generalization. En: Müller, J. C.; Lagrange, J. P.; Weibel, R. (eds.). *Gis and generalization: Methodology and practice*. London: Taylor & Francis. pp 56-69.

Weibel, R.; Dutton, G. (1998). Constraing-based automated map generalization. *Spatial Data Handling'98*: 214-224. Vancouber, Canada,

Weibel, R.; Jones, C. B. (1998). Computational Perspectives on Map Generalization. *GeoInformatica*, 2(4): 307-314.

Werschlein, T; Weibel, R. (1994). Use of neural networks in line generalization. *Proceedings EGIS'94*, pp. 76-85. Paris.

Werschlein (1995). First Experiments with Neural Networks in Line Generalization. *17th International Cartographic Conference.* Poster Sessions. Barcelona.

White, E. R. (1985). Assessment of line generalization algorithms using characteristic points. *The American Cartographer*, 12(1): 17-28.

Young, I. T.; Walker, J. E.; Bowie, J. E. Bowie. (1974). An analysis technique for biological shape I. *Info Control*, 25: 357-370.

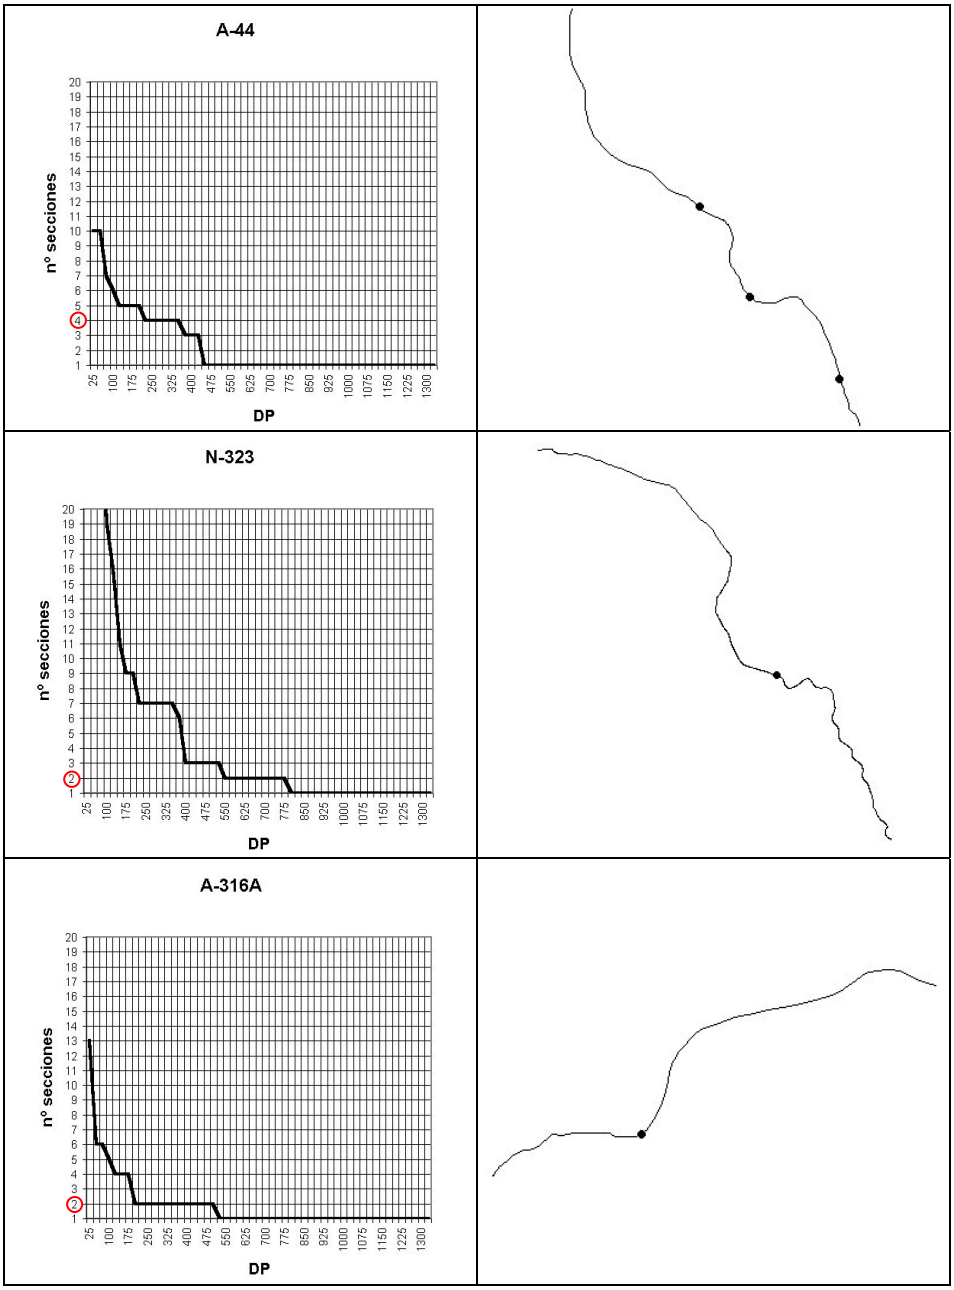
Zhan, F. B.; Buttenfield, B. P. (1996). Multi-scale representation of a digital line. *Cartography and Geographic Information Systems*, 23(4): 206-228.

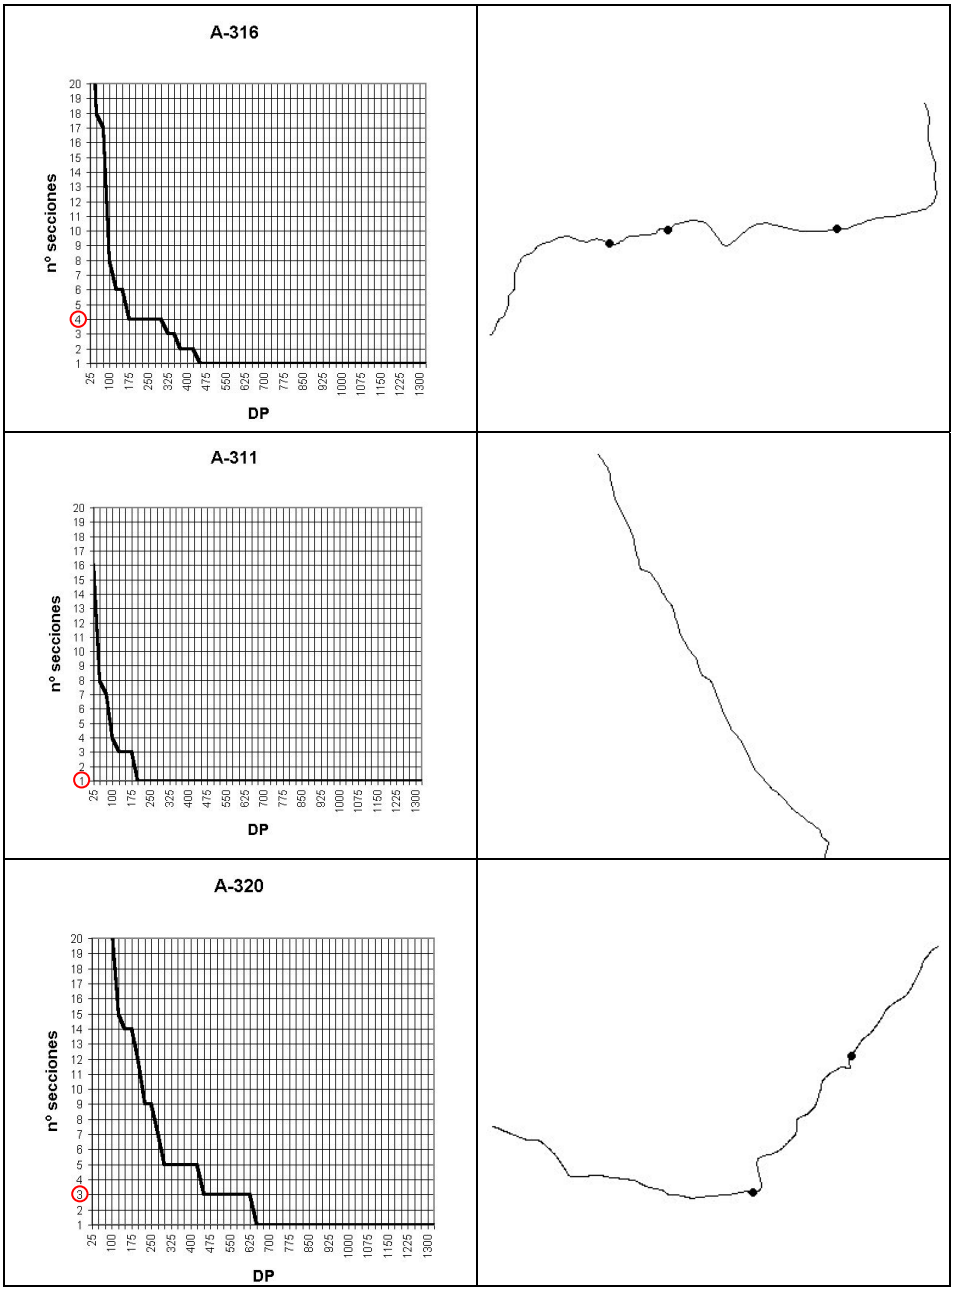
Zhao, H.; Li, X.; Jiang, L. (2001). A Modified Douglas-Peucker Simplification Algorithm. *IEEE 2001 International*, 4: 1968-1970. Geoscience and Remote Sensing Symposium. IGARSS'01.

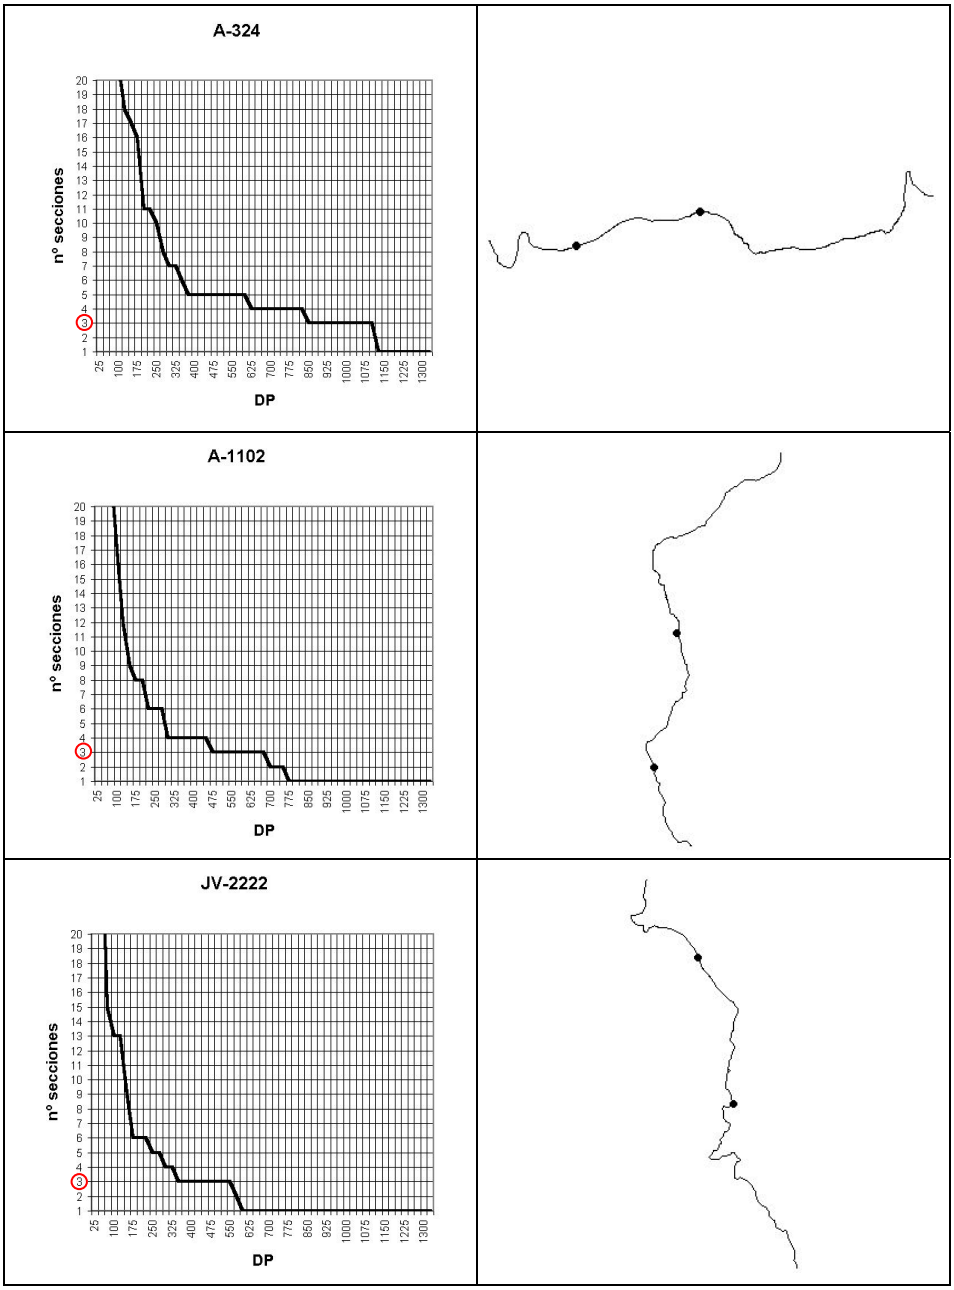
Zhou, C.; Nelson, P.C. (2002). Predicting traffic congestion using recurrent neural networks. En: *Proceedings of the 9th World Congress on Intelligent Transport* Systems, Chicago, octubre de 2002.

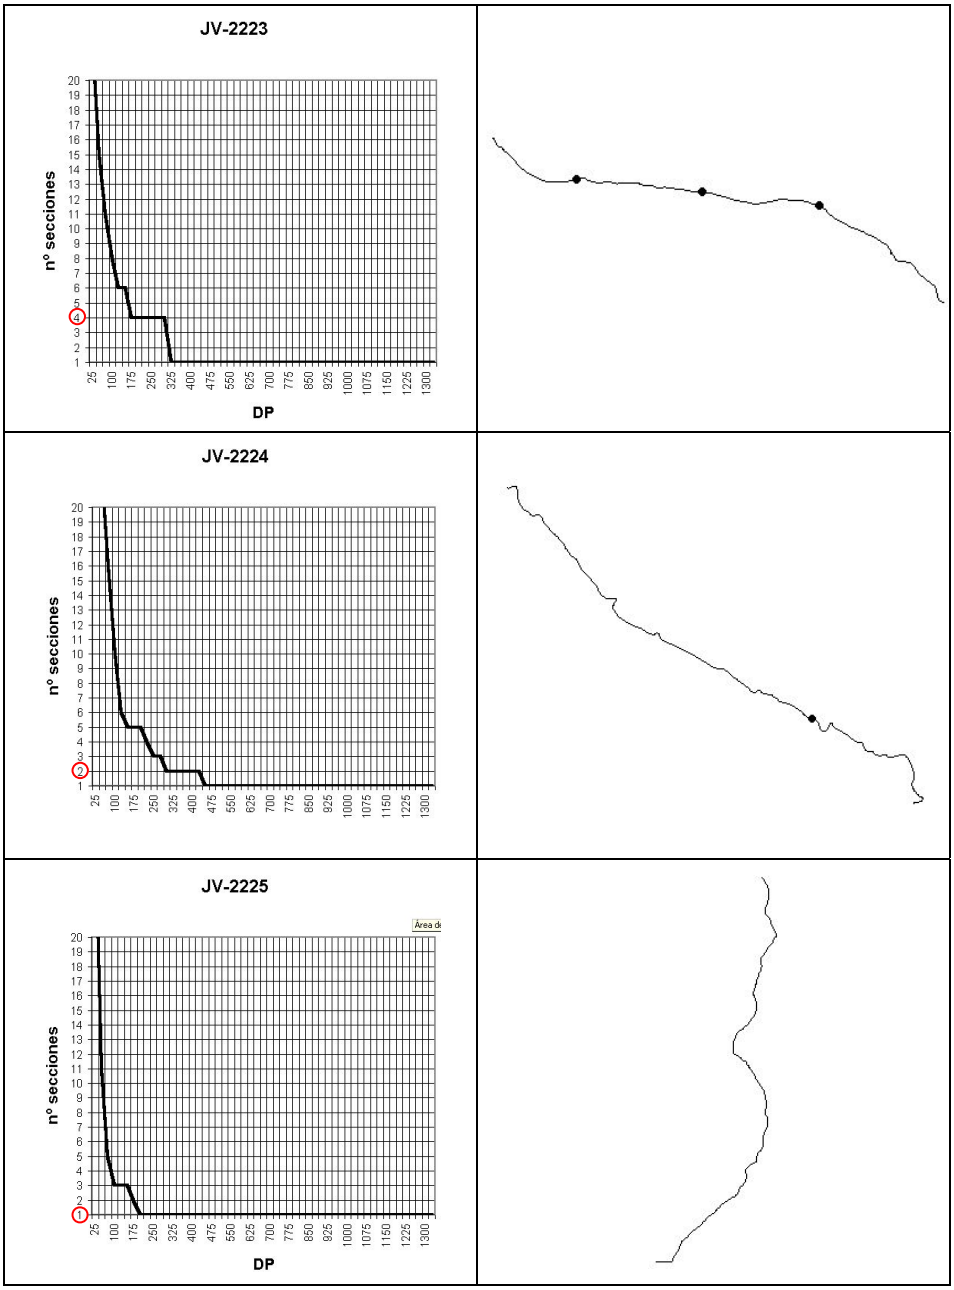
Anexos

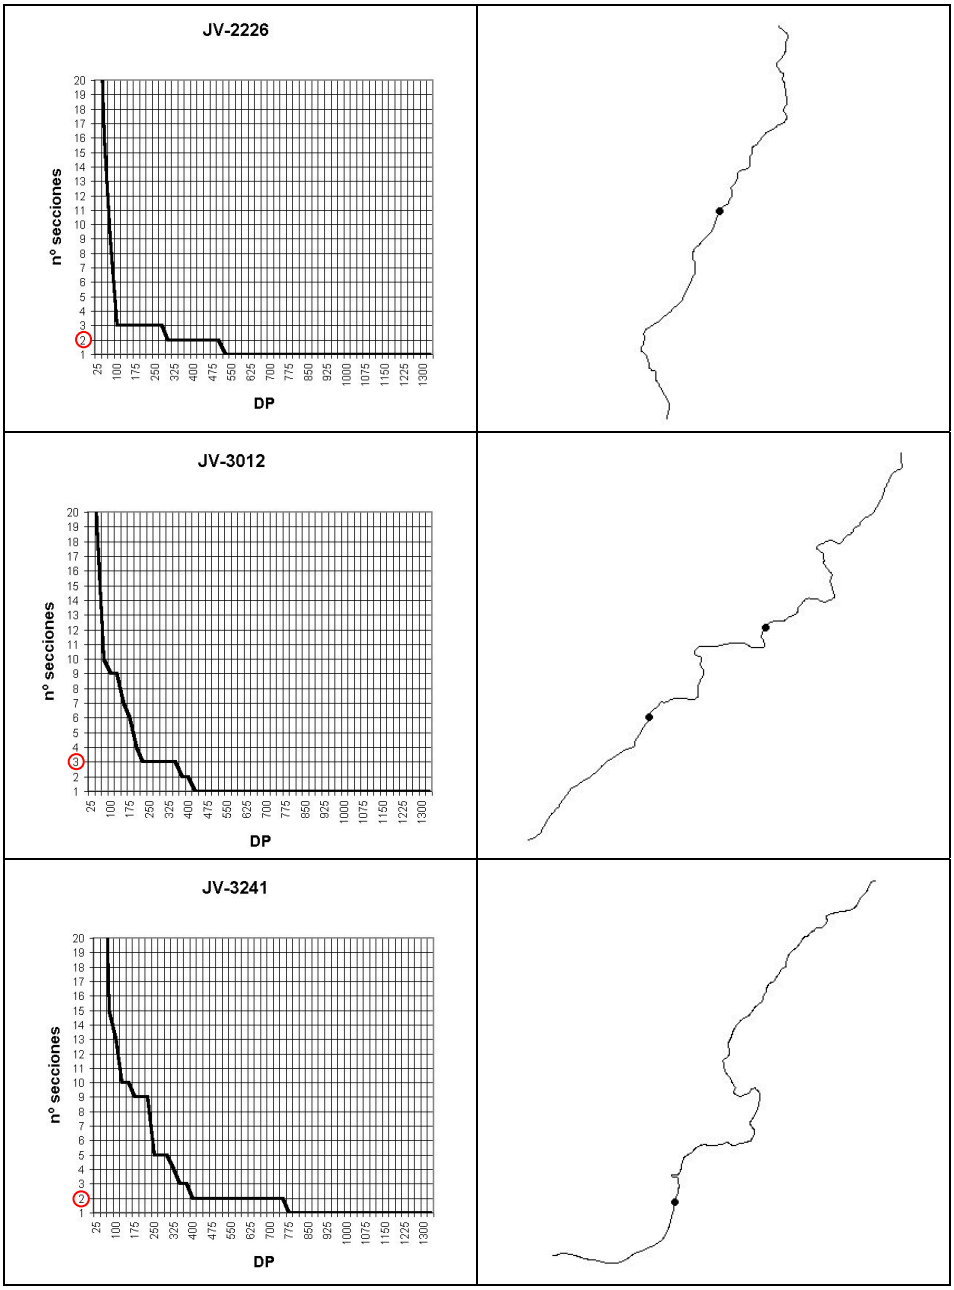
Anexo A. Gráficas de evolución del nº de secciones de cada línea de la muestra con el parámetro DP

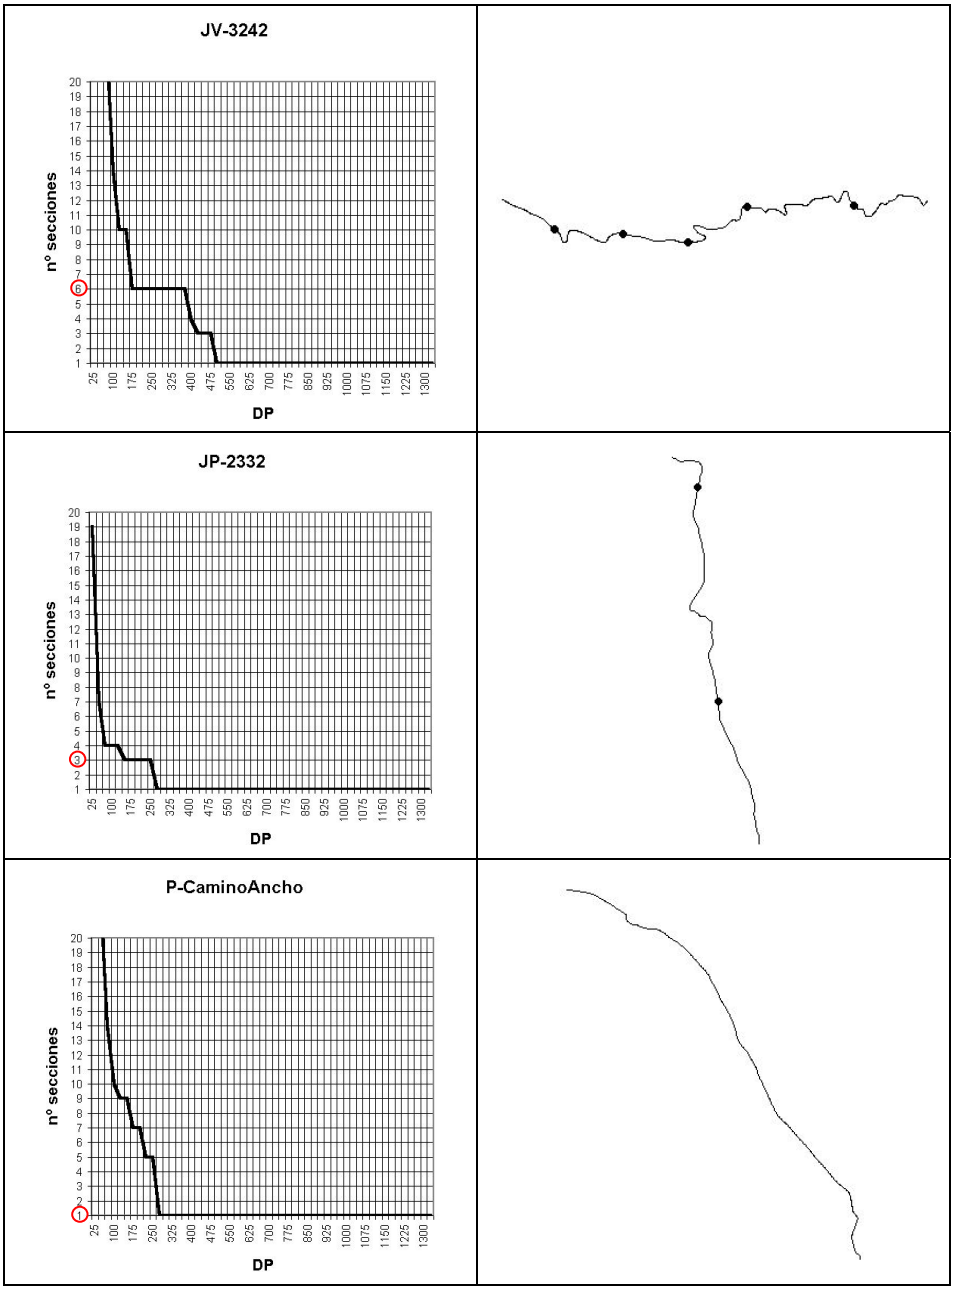


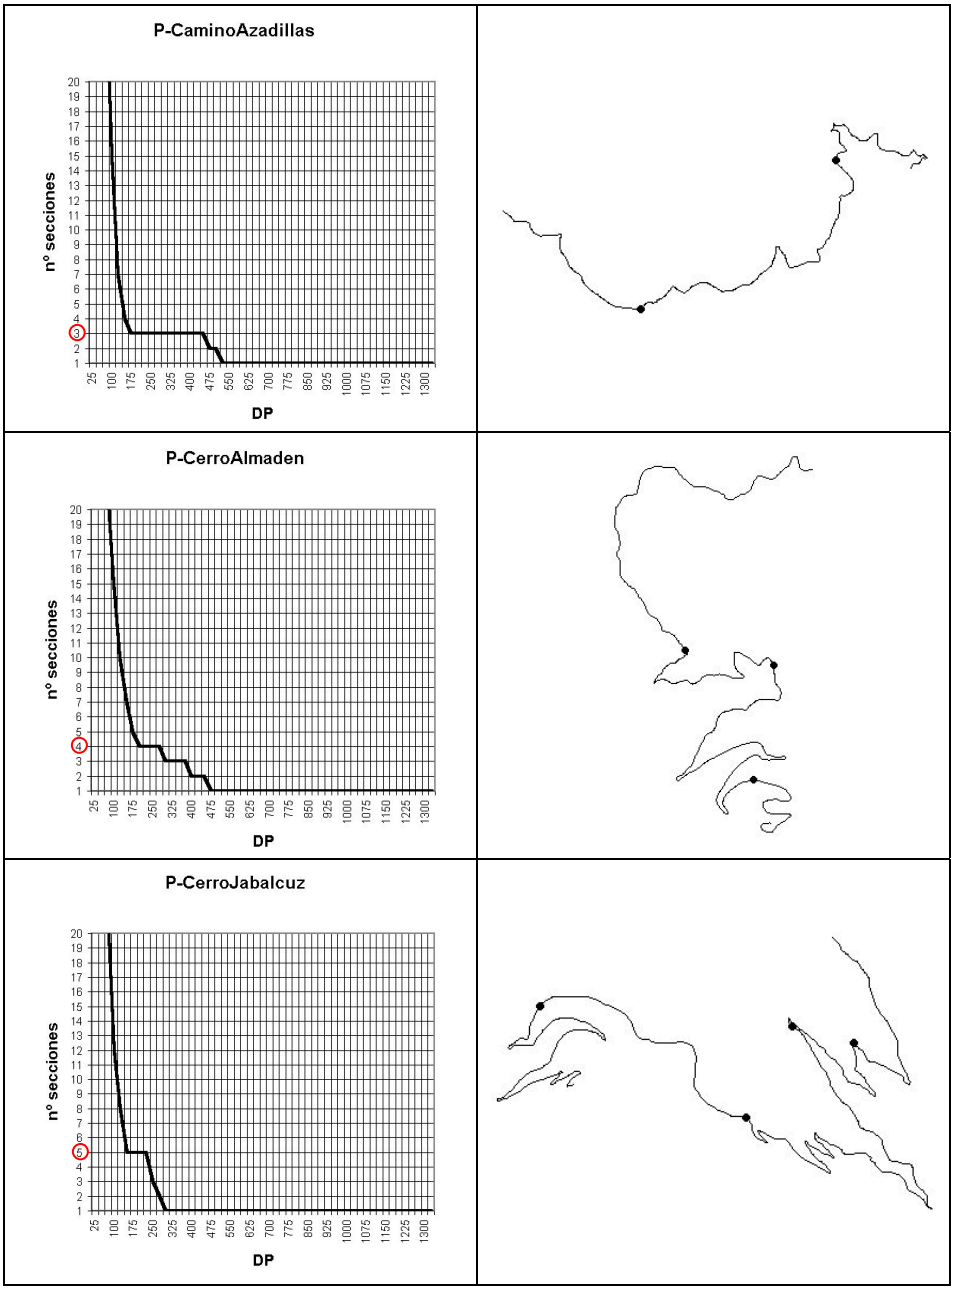

A-316
nº secciones
DP
A-311
nº secciones
DP
A-320
nº secciones
DP

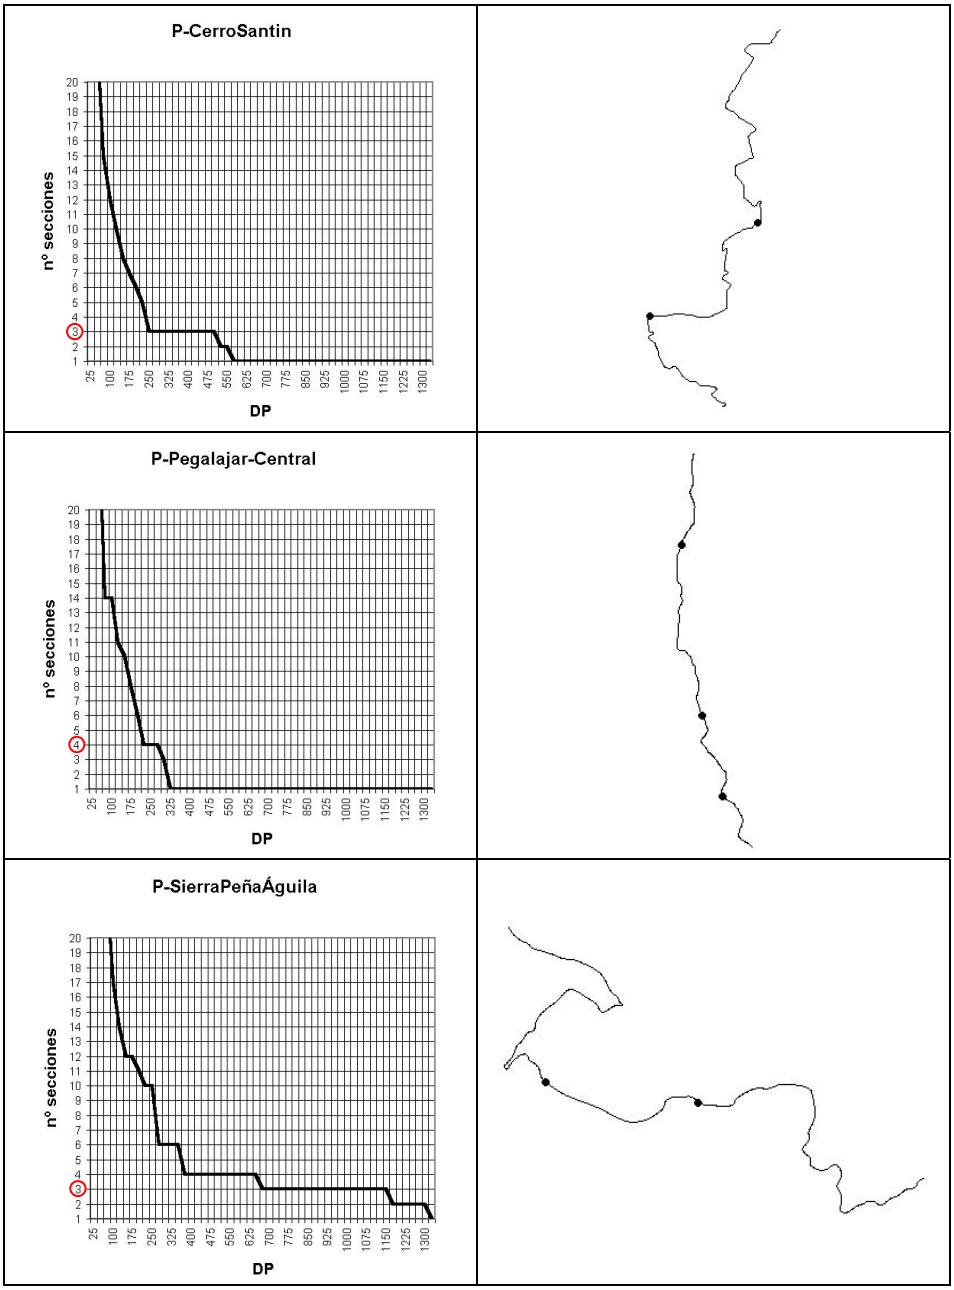

A-324
nº secciones
DP
A-1102
nº secciones
DP
JV-2222
nº secciones
DP


JV-2223
nº secciones
DP
JV-2224
nº secciones
JV-2225
nº secciones
DP


JV-2226
nº secciones
DP
JV-3012
nº secciones
DP
JV-3241
nº secciones
DP


JV-3242
nº secciones
DP
JP-2332
nº secciones
DP
P-CaminoAncho
nº secciones
DP

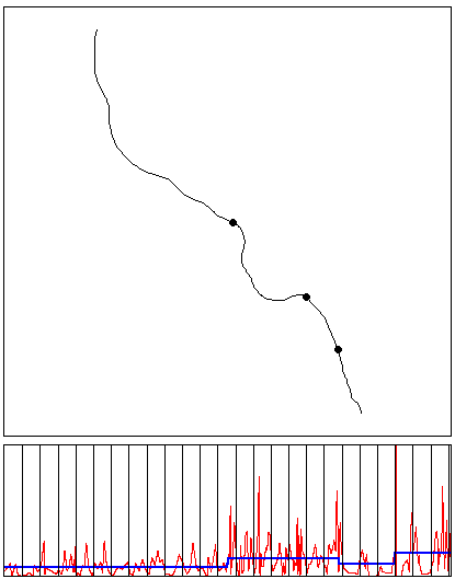

P-CaminoAzadillas
nº secciones
DP
P-CerroAlmaden
nº secciones
DP
P-CerroJabalcuz
nº secciones
DP


P-CerroSantin
nº secciones
DP
P-Pegalajar-Central
nº secciones
DP
P-SierraPeñaÁguila
nº secciones
DP

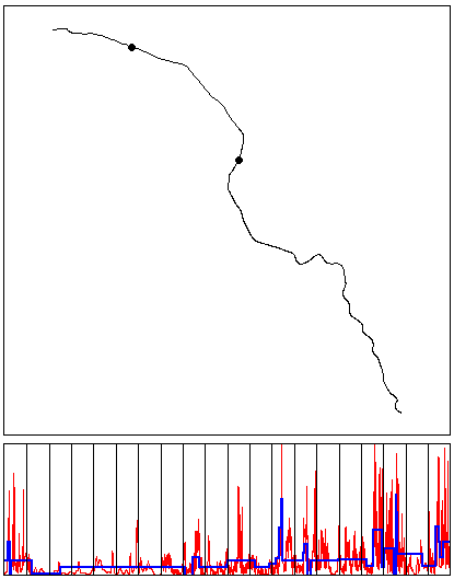
Anexo B. Trazados de la segmentación mediante wavelets

K = 40%; L = 2000 m

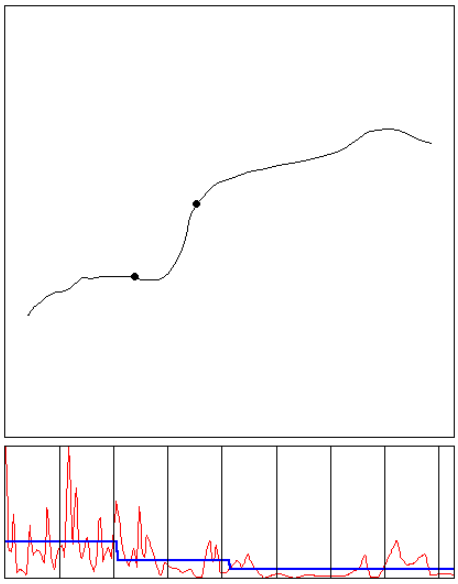
A-44



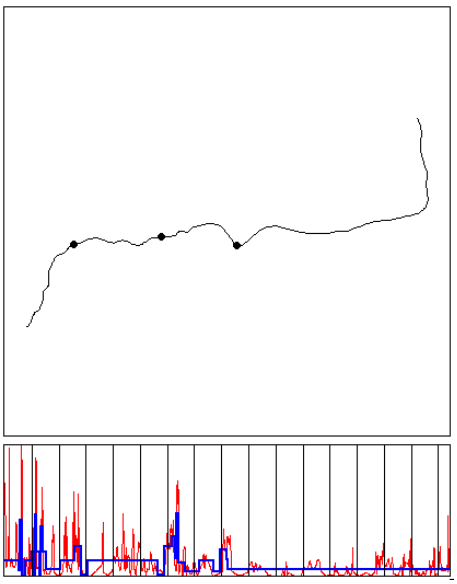
N-323



A-316A



A-316



K = 40%; L = 2000 m

Anexo C. Gráficas de error del entrenamiento de las redes neuronales

En este Anexo se incluyen todas las gráficas de error derivadas de los procesos de entrenamiento, mediante validación cruzada, de las distintas arquitecturas planteadas (2, 3, 4 y 5 neuronas ocultas). Así, en cada una de las páginas de este anexo se incluirá una tabla con las gráficas de entrenamiento de dos patrones, uno en cada columna, en cada una de las 4 arquitecturas planteadas, una por cada fila (*N* es el número de neuronas de la arquitectura).

Cada gráfica de error permite comprobar cuál ha sido la evolución del error que se produce en la capa de salida conforme se somete la red a entrenamiento. En el eje X se muestra el número de iteraciones, y en el eje Y el error alcanzado en cada momento del entrenamiento conforme el número de iteraciones aumenta (véase la Figura C.1).

Además, es interesante destacar que en la gráfica se muestran dos funciones diferentes que representan, en cada caso, el error que se produce en la capa de salida si, con los pesos existentes en la red en una iteración dada del entrenamiento, la red neuronal se alimenta con el patrón de entrenamiento (línea negra) o con el patrón de validación (línea roja).

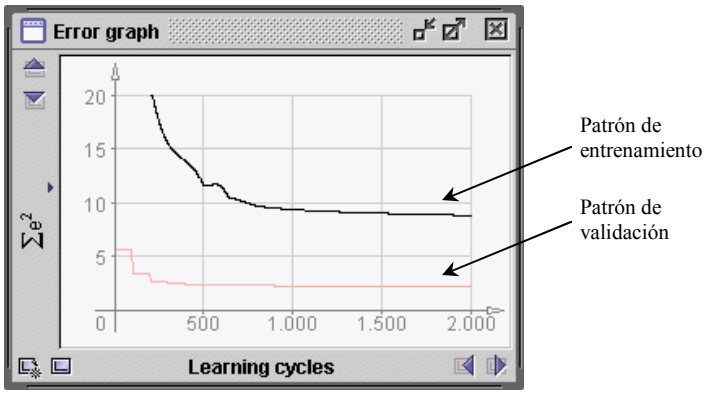


Figura C.1 - Ejemplo de gráfica de error proporcionada por JavaNNS durante el proceso de aprendizaje

C.1. Entrenamientos entre 2 y 5 neuronas ocultas

Tabla C.1 - Gráficas de error de los patrones 1 y 2 en las distintas arquitecturas.

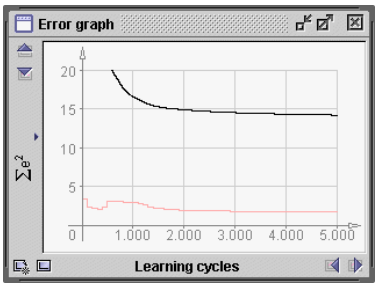
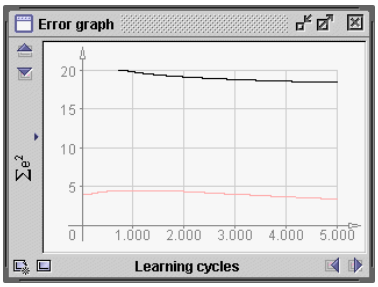
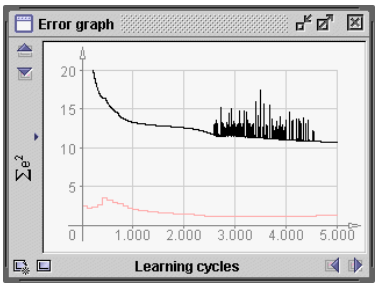
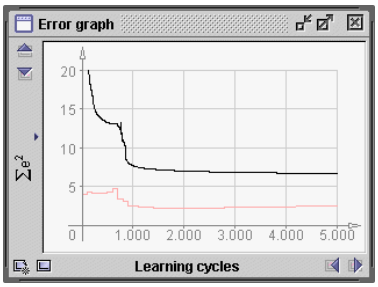
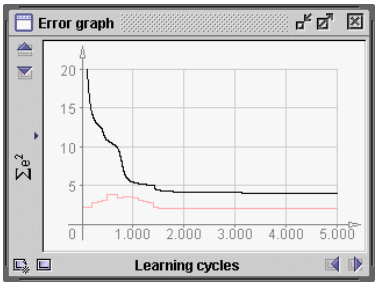
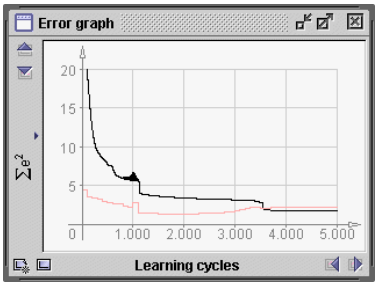
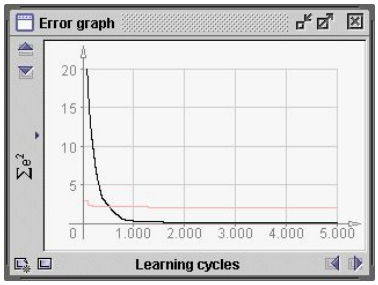
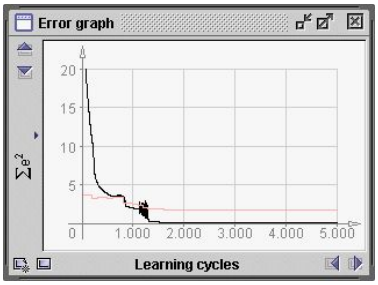
N	**Patrón entrenamiento: 1** **Patrón de validación: 1**	**Patrón entrenamiento: 2** **Patrón de validación: 2**
2		
3		
4		
5		

Tabla C.2 - Gráficas de error de los patrones 3 y 4 en las distintas arquitecturas.

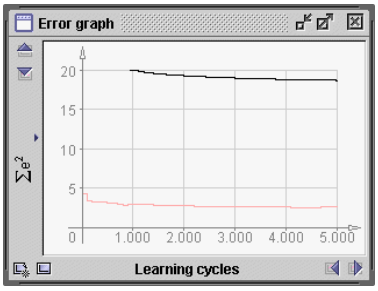
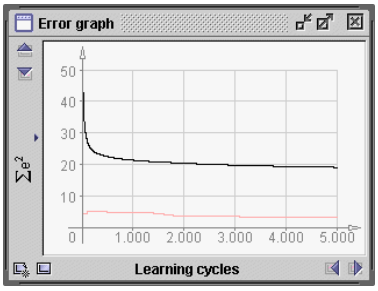
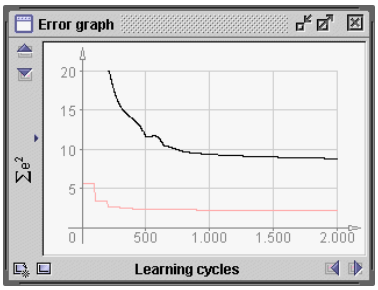
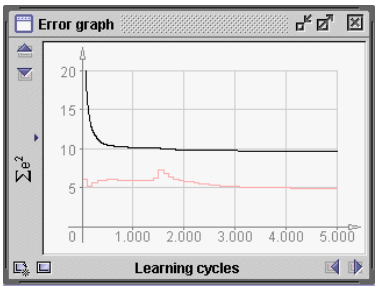
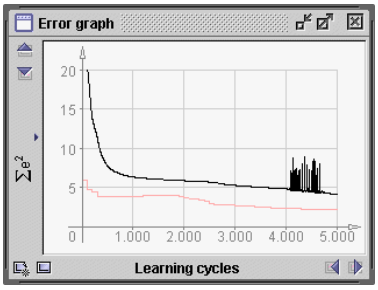
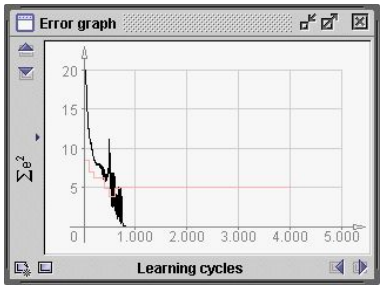
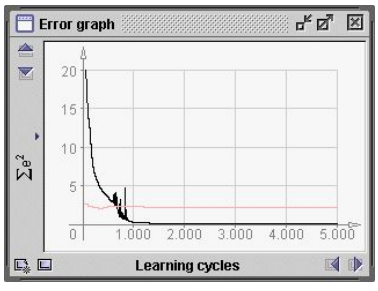
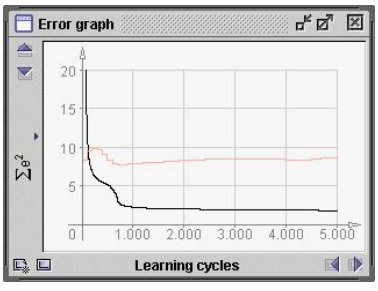
N	**Patrón entrenamiento: 3** **Patrón de validación: 3**	**Patrón entrenamiento: 4** **Patrón de validación: 4**
2		
3		
4		
5		

Tabla C.3 - Gráficas de error de los patrones 5 y 6 en las distintas arquitecturas.

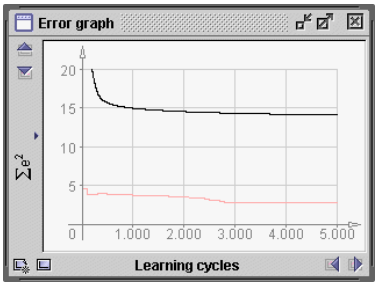
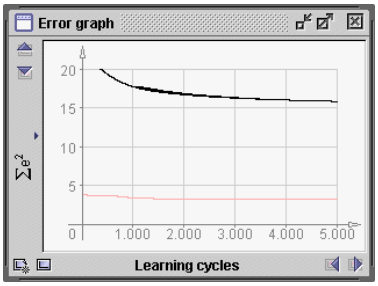
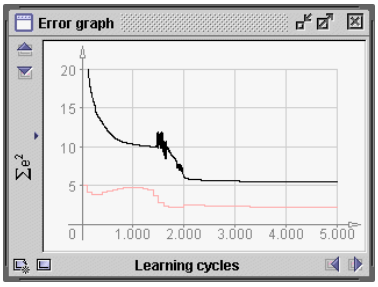
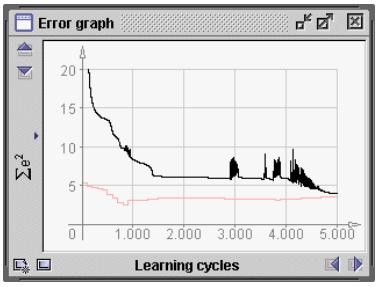
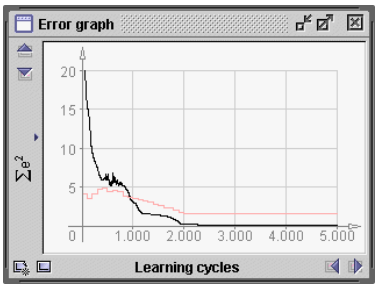
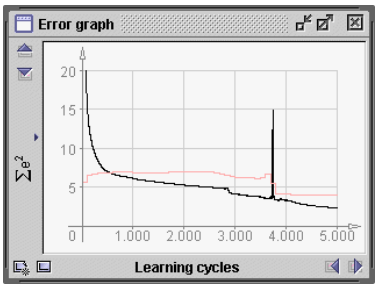
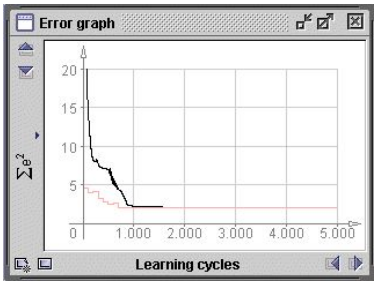
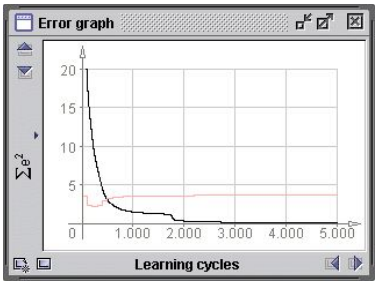
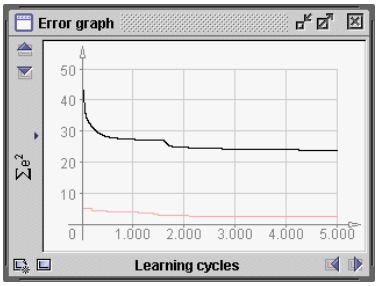
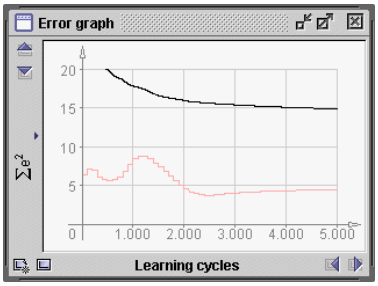
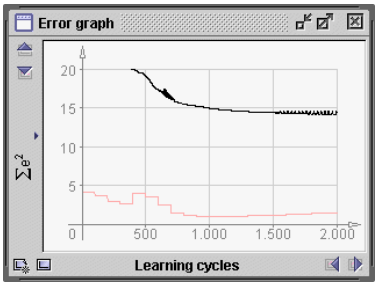
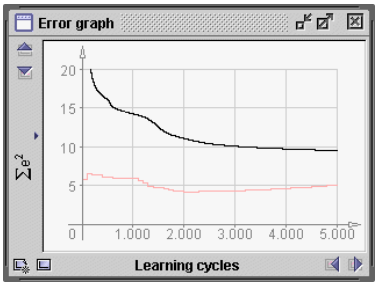
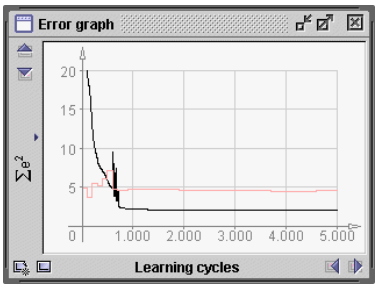
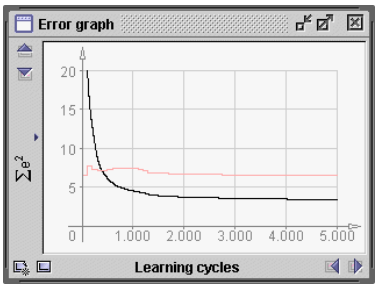
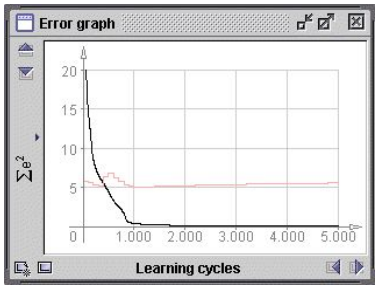
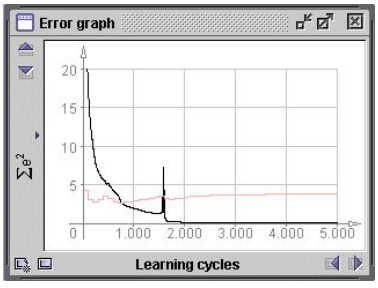
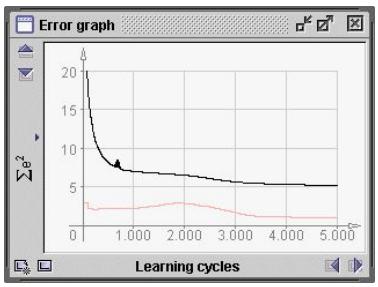
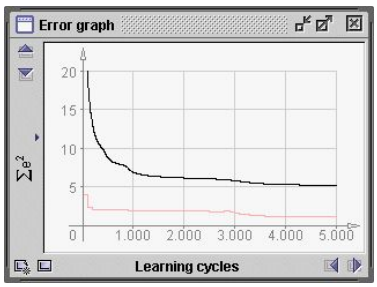
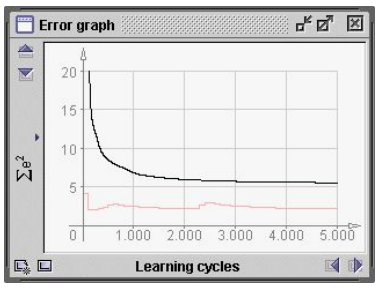
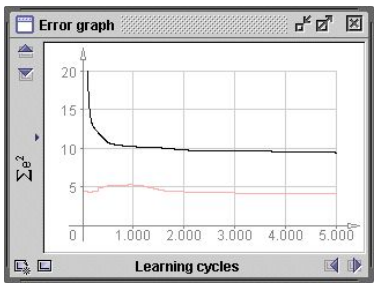
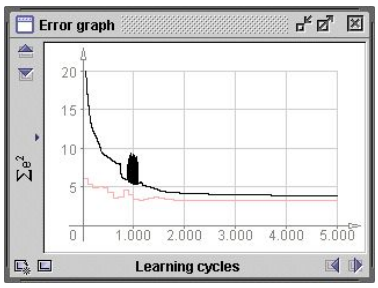
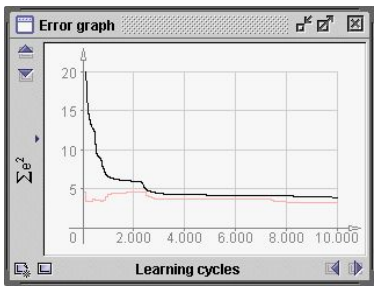
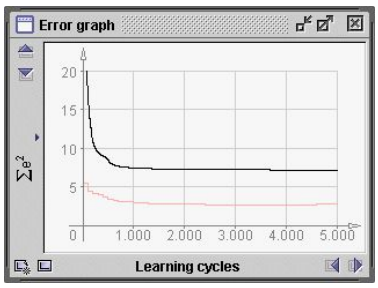
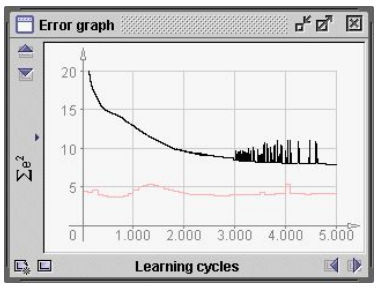
N	**Patrón entrenamiento: 5** **Patrón de validación: 5**	**Patrón entrenamiento: 6** **Patrón de validación: 6**
2		
3		
4		
5		

Tabla C.4 - Gráficas de error de los patrones 7 y 8 en las distintas arquitecturas.

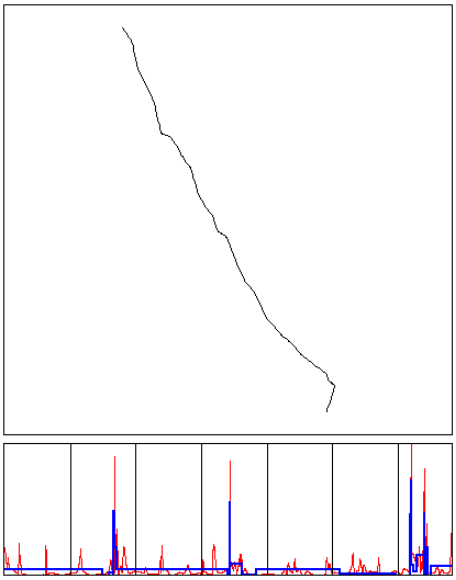
N	**Patrón entrenamiento: 7** **Patrón de validación: 7**	**Patrón entrenamiento: 8** **Patrón de validación: 8**
2		
3		
4		
5		

C.2. Re-entrenamiento de la red de 3 neuronas ocultas

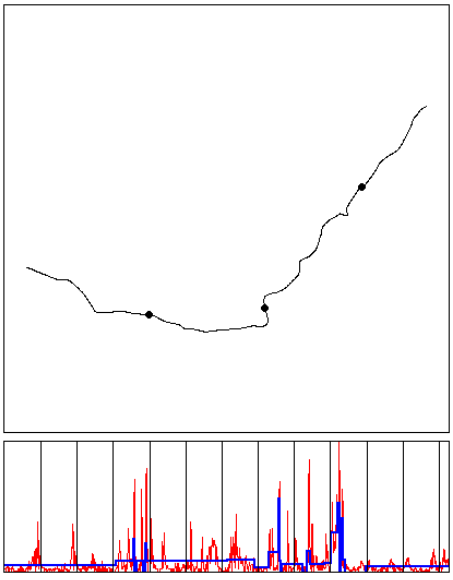
Tabla C.5 - Gráficas de error del re-entrenamiento de la arquitectura de 3 neuronas ocultas.

Patrón 1	Patrón 2
	
Patrón 3	Patrón 4
	
Patrón 5	Patrón 6
	
Patrón 7	Patrón 8
	

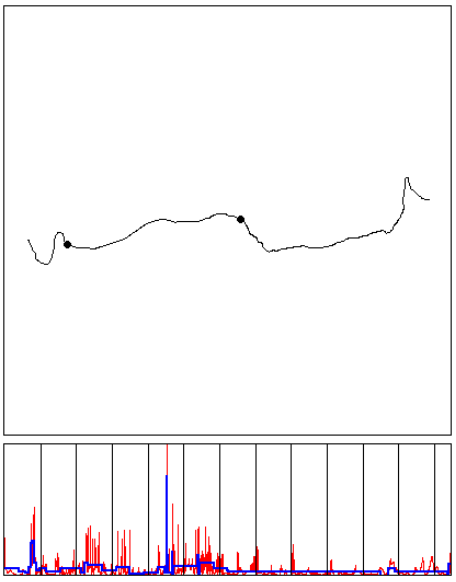
A-311



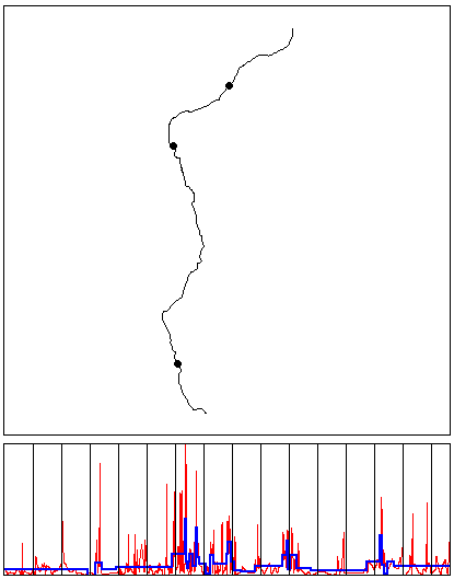
A-320



A-324

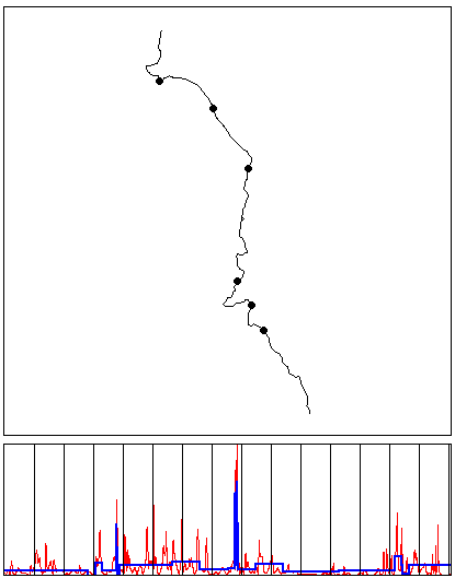


A-1102

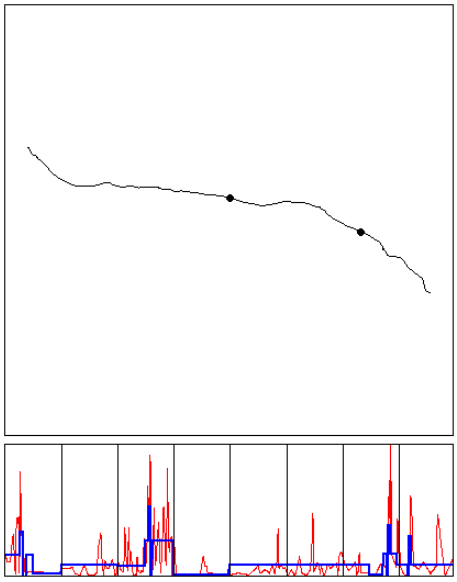


$K = 40\%$; $L = 1000$ m

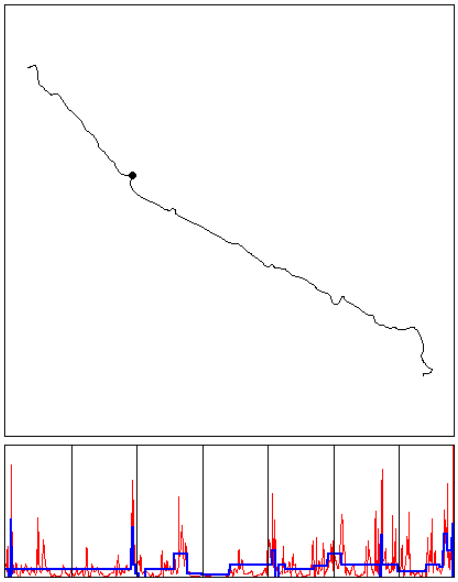
JV-2222



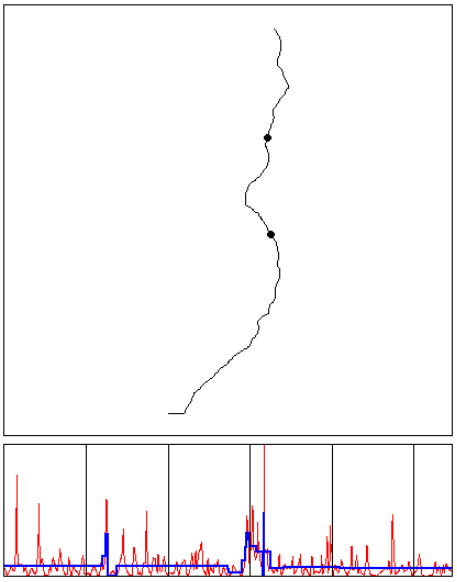
JV-2223



JV-2224

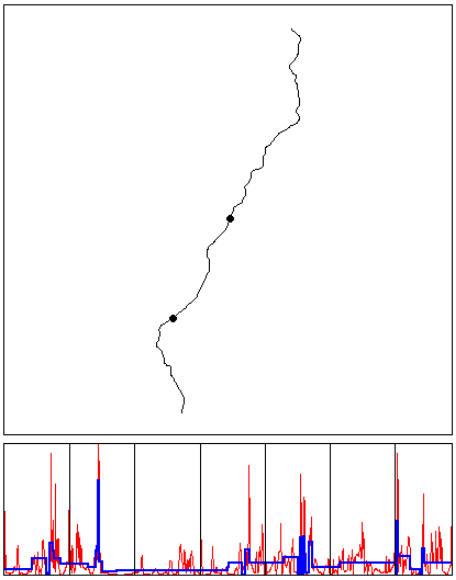


JV-2225

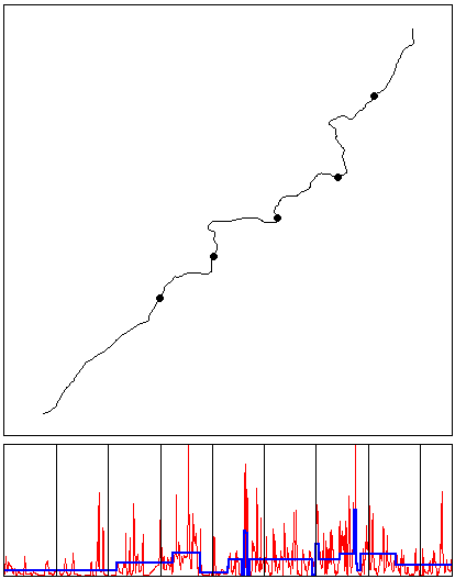


$K = 40\%$; $L = 1000$ m

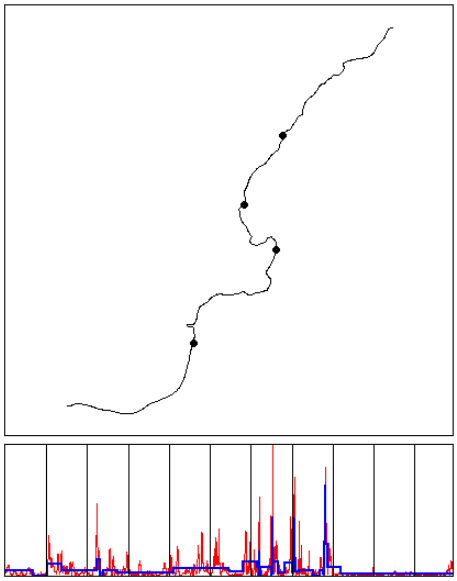
JV-2226



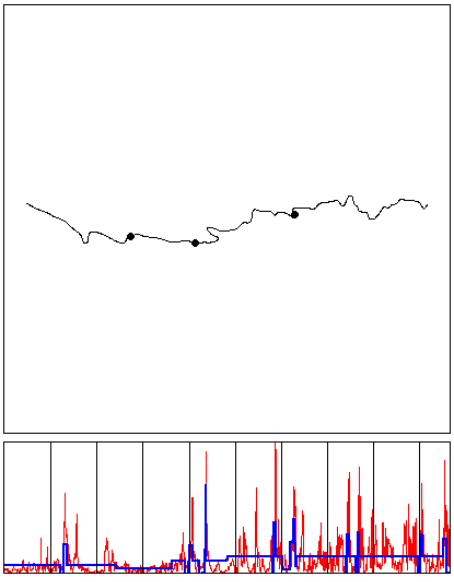
JV-3012



JV-3241

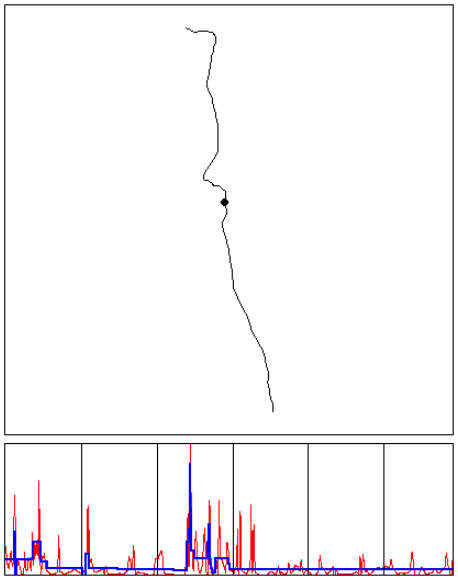


JV-3242

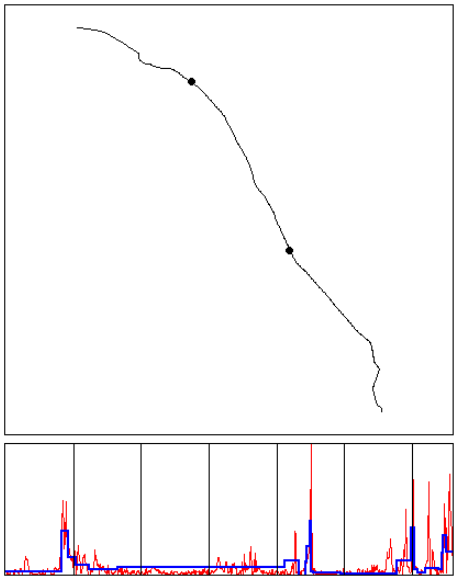


$K = 40\%$; $L = 1000$ m

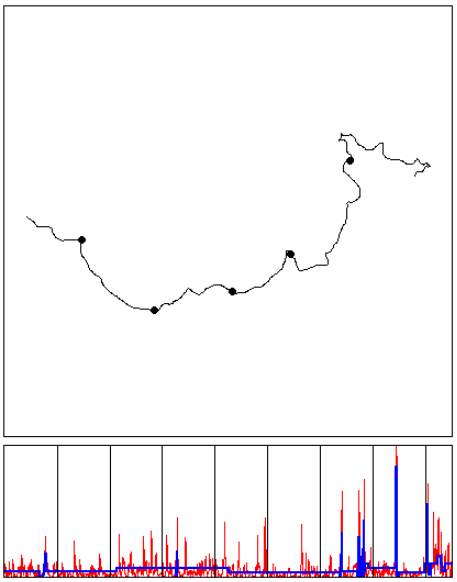
JP-2332



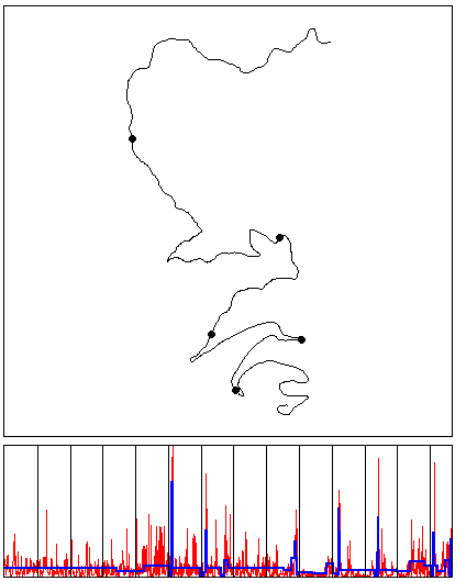
P-CaminoAncho



P-CaminoAzadillas

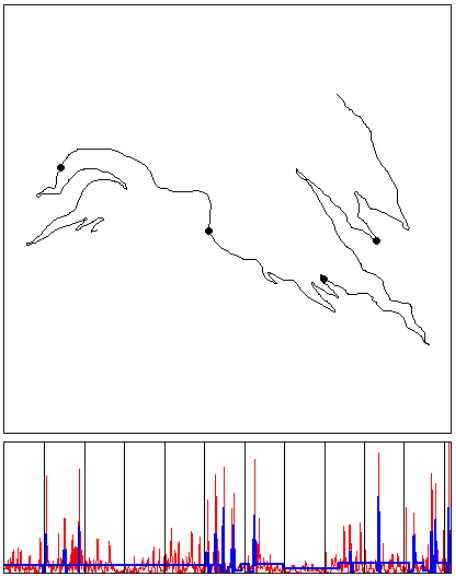


P-CerroAlmaden

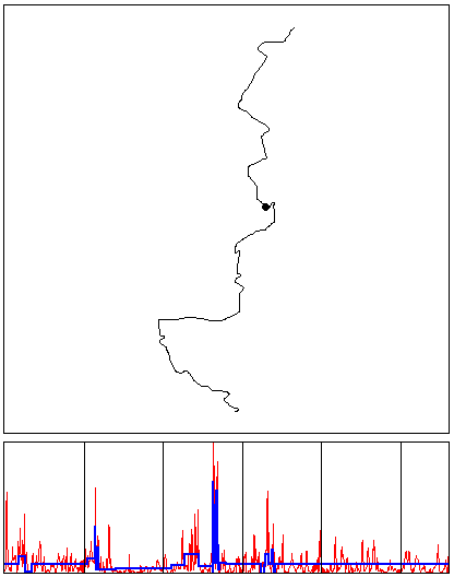


$K = 40\%$; $L = 1000$ m

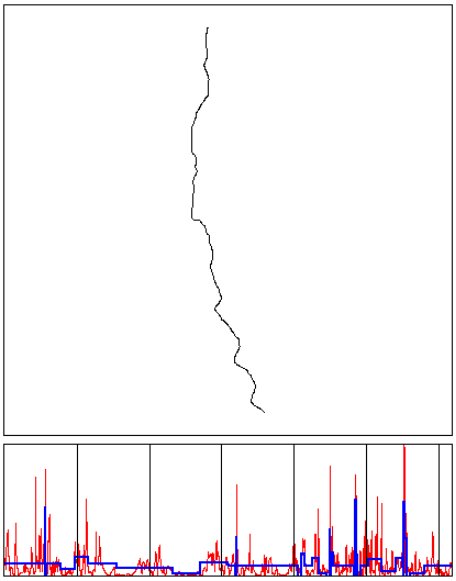
P-CerroJabalcuz



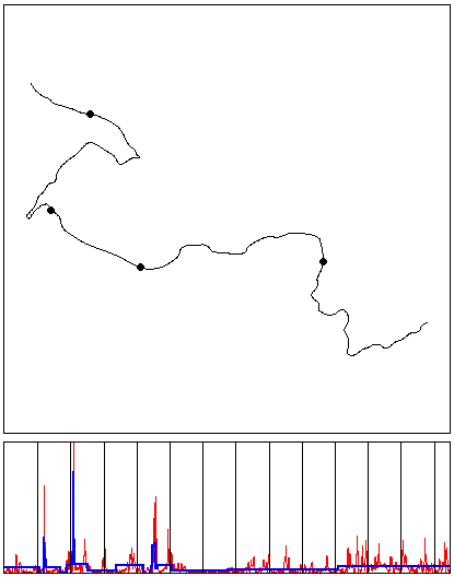
P-CerroSantin



P-Pegalajar-Central



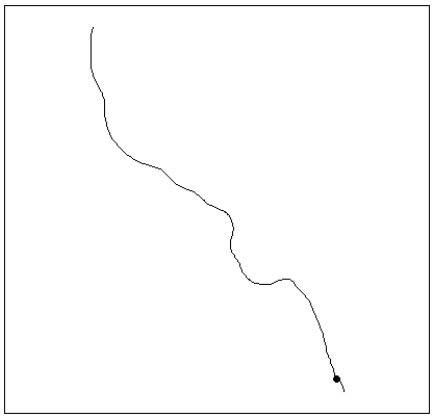
P-SierraPeñaAguila



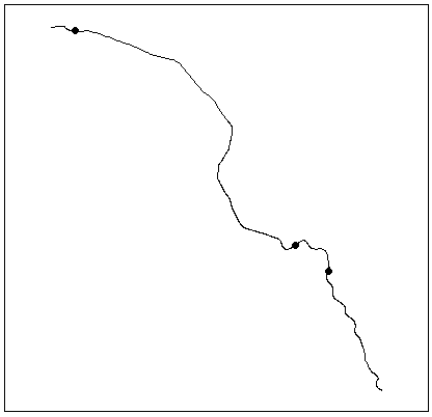
Anexo D. Trazados de la segmentación mediante la red neuronal

$L = 3000\ m; l = 250\ m$

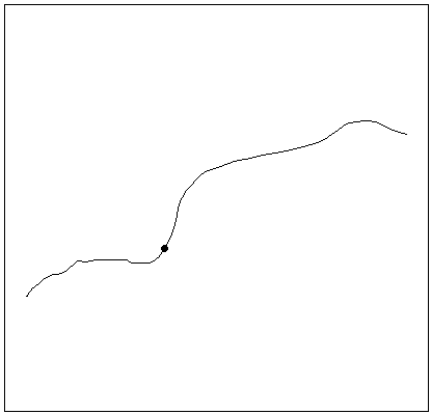
A-44



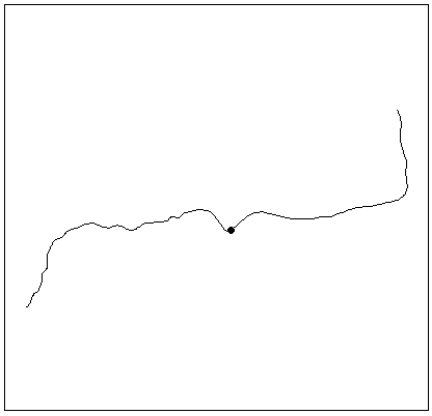
N-323



A-316A

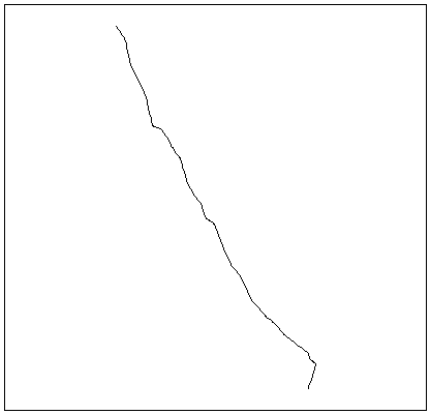


A-316

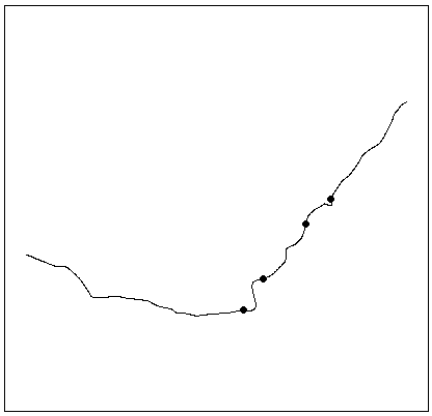


$L = 1500\ m; l = 250\ m$

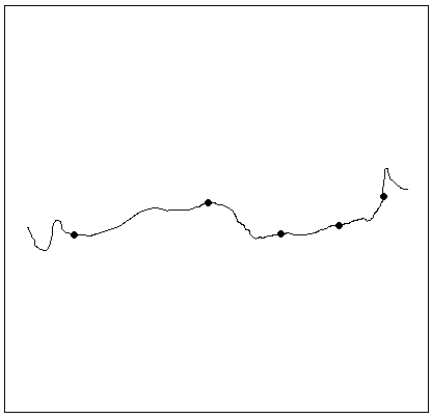
A-311



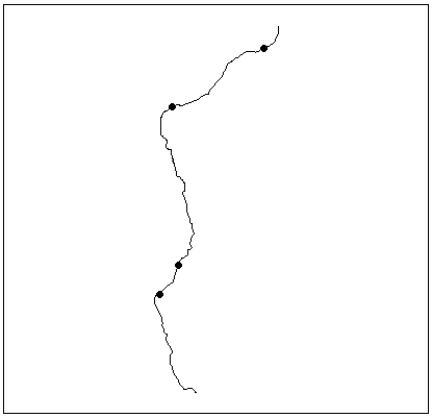
A-320



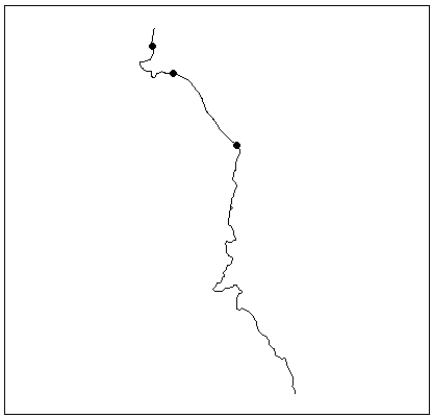
A-324



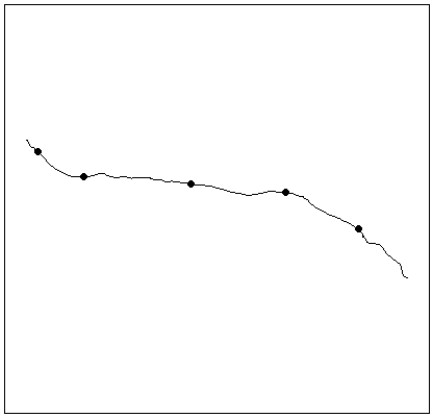
A-1102



JV-2222

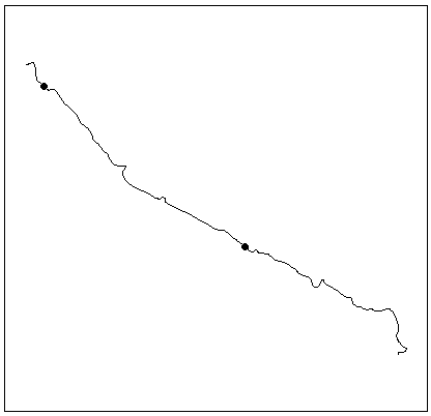


JV-2223

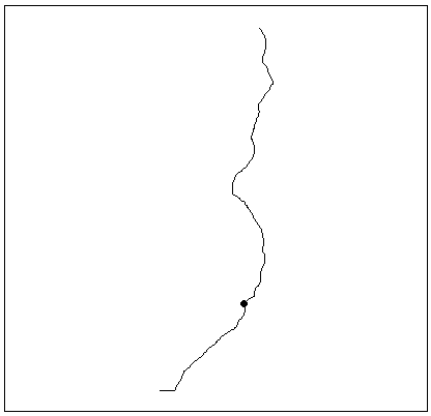


$L = 1500\ m; l = 250\ m$

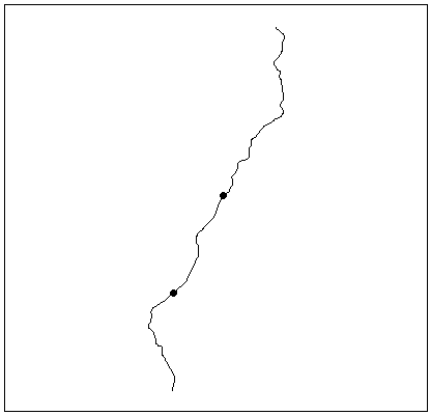
JV-2224



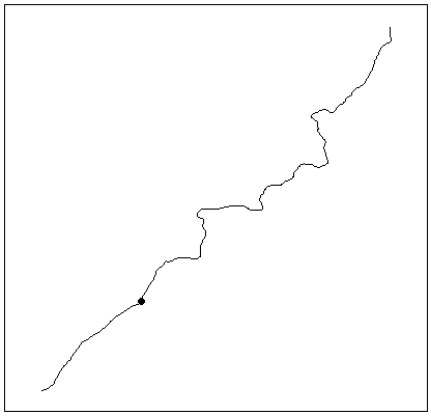
JV-2225



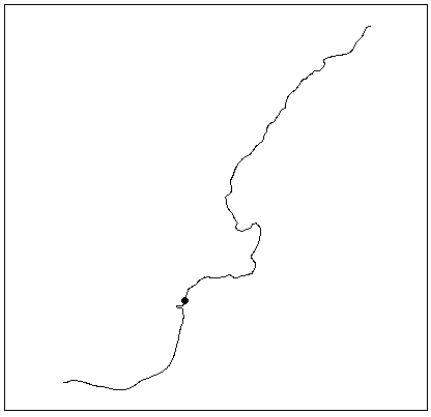
JV-2226



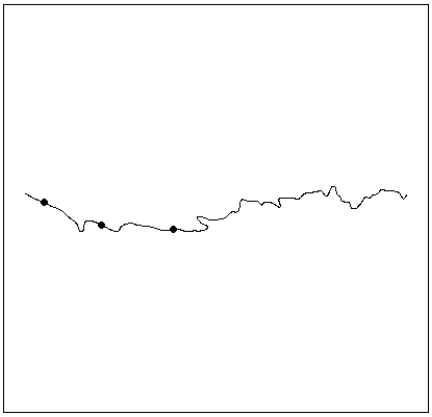
JV-3012



JV-3241

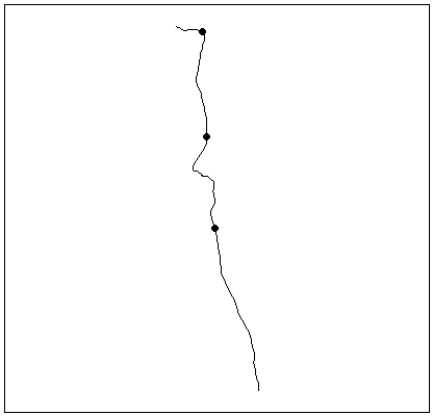


JV-3242

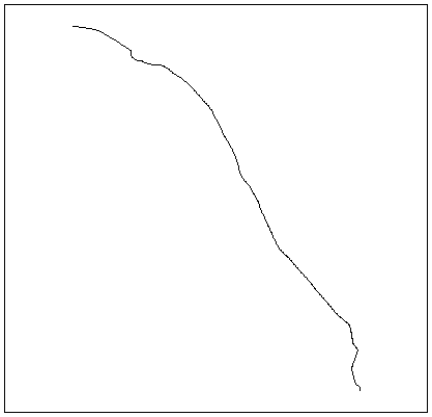


$$L = 1500\ m;\ l = 250\ m$$

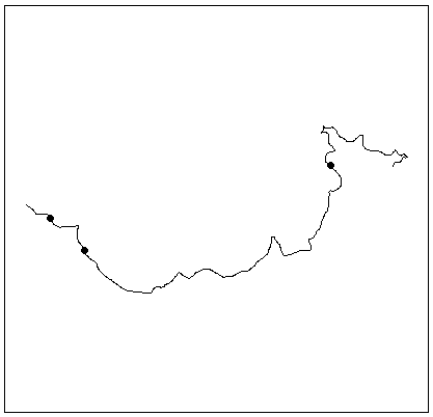
JP-2332



P-CaminoAncho



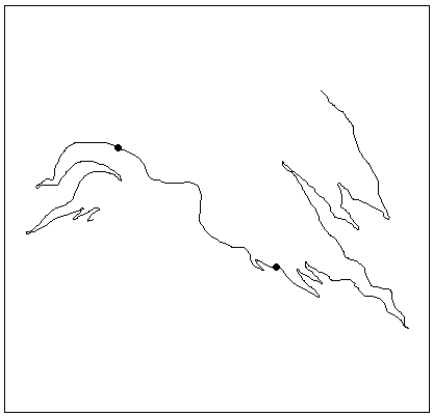
P-CaminoAzadillas



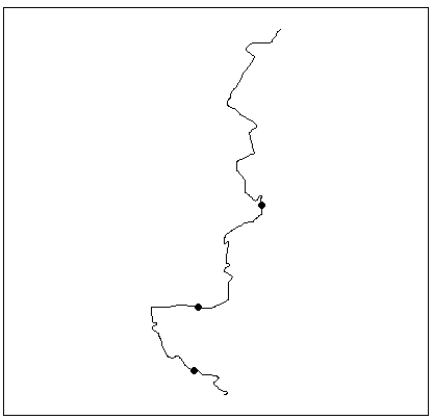
P-CerroAlmaden



P-CerroJabalcuz

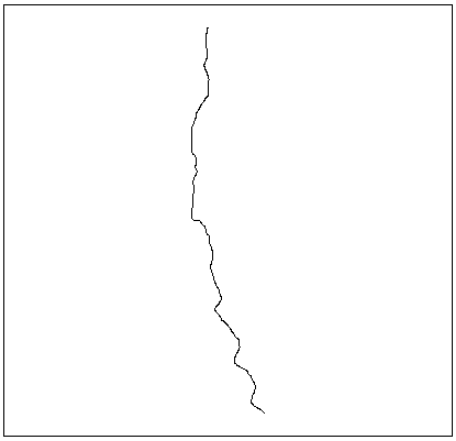


P-CerroSantin

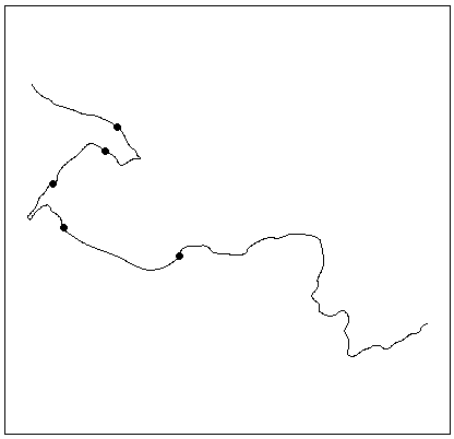


$$L = 1500\ m;\ l = 250\ m$$

P-Pegalajar-Central



P-SierraPeñaAguila



Anexo E. Resumen de respuestas en la evaluación por el panel de expertos

Como se comenta en el apartado III.6.2.2, el panel de expertos dispuso de una tabla de respuestas como la que se presenta en la Figura E.1 para evaluar cada una de las líneas que se le presentaron. En las siguientes páginas se resume el contenido de estas tablas de respuestas. Las respuestas se presentan ordenadas según la línea bajo análisis. Los problemas 1 a 5 que a los que se hace referencia se corresponden con los problemas de la columna 2 de la Figura E.1.

TABLA 1

CASO	COLUMNA 1					COLUMNA 2	COLUMNA 3				
	Puntuación (hoja 3)					Problemas detectados / observaciones (hoja 3)	Puntuación (hoja 4)				
a)	1 - Nada satisfactorio	2 - Poco satisfactorio	3 - Satisfactorio	4 - Bastante satisfactorio	5 - Muy satisfactorio	Nº de secciones excesivo Nº de secciones insuficiente Existen cambios de sección en lugares incorrectos Existen secciones excesivamente largas Existen secciones excesivamente cortas Observación 1: _____ Observación 2: _____	1 - Nada satisfactorio	2 - Poco satisfactorio	3 - Satisfactorio	4 - Bastante satisfactorio	5 - Muy satisfactorio
b)	1 - Nada satisfactorio	2 - Poco satisfactorio	3 - Satisfactorio	4 - Bastante satisfactorio	5 - Muy satisfactorio	Nº de secciones excesivo Nº de secciones insuficiente Existen cambios de sección en lugares incorrectos Existen secciones excesivamente largas Existen secciones excesivamente cortas Observación 1: _____ Observación 2: _____	1 - Nada satisfactorio	2 - Poco satisfactorio	3 - Satisfactorio	4 - Bastante satisfactorio	5 - Muy satisfactorio
c)	1 - Nada satisfactorio	2 - Poco satisfactorio	3 - Satisfactorio	4 - Bastante satisfactorio	5 - Muy satisfactorio	Nº de secciones excesivo Nº de secciones insuficiente Existen cambios de sección en lugares incorrectos Existen secciones excesivamente largas Existen secciones excesivamente cortas Observación 1: _____ Observación 2: _____	1 - Nada satisfactorio	2 - Poco satisfactorio	3 - Satisfactorio	4 - Bastante satisfactorio	5 - Muy satisfactorio
d)	1 - Nada satisfactorio	2 - Poco satisfactorio	3 - Satisfactorio	4 - Bastante satisfactorio	5 - Muy satisfactorio	Nº de secciones excesivo Nº de secciones insuficiente Existen cambios de sección en lugares incorrectos Existen secciones excesivamente largas Existen secciones excesivamente cortas Observación 1: _____ Observación 2: _____	1 - Nada satisfactorio	2 - Poco satisfactorio	3 - Satisfactorio	4 - Bastante satisfactorio	5 - Muy satisfactorio

Figura E.1 - Tabla de respuestas de la prueba.

Línea 1 - A-44									
Experto	**Solución**	**Segmentación**							**Clasificación**
		Punt.	**Problemas**					**Observaciones**	**Puntuación**
			1	**2**	**3**	**4**	**5**		
1	a	4			x			-	4
	b	2		x		x		-	2
	c	4	x					-	3
	d	3	x				x	-	4
4	a	3			x			-	2
	b	1				x	x	-	1
	c	3					x	-	3
	d	4					x	-	3
10	a	3			x			-	4
	b	5						-	5
	c	4			x			-	3
	d	5						-	5
13	a	2		x				-	5
	b	1		x				-	1
	c	4			x			-	5
	d	4			x			-	5

Línea 2 - N-323									
Experto	**Solución**	**Segmentación**							**Clasificación**
		Punt.	**Problemas**					**Observaciones**	**Puntuación**
			1	**2**	**3**	**4**	**5**		
2	a	3		x				-	3
	b	3	x					-	3
	c	4				x		-	3
	d	3	x					-	4
6	a	4	x					-	4
	b	3	x					-	2
	c	5						-	4
	d	3	x					-	3
11	a	5						-	4
	b	2	x		x		x	-	2
	c	4						Section 1 is quite ok, but might have been segmented even further, as in porposal a.	2
	d	2,5	x		x			This proposal is better than proposal b, but segmentation is sometimes in wrong places.	1
18	a	2		x		x		-	3
	b	4		x				-	4
	c	1		x		x		-	2
	d	3			x			1ª sección, el cambio lo considero incorrecto.	1

Línea 3 - A-316A									
Experto	**Solución**	**Segmentación**							**Clasificación**
		Punt.	**Problemas**					**Observaciones**	**Puntuación**
			1	**2**	**3**	**4**	**5**		
3	a	1		x				Tengo un problema con la escala o grado de generalización posterior.	5
	b	1		x				-	5
	c	1		x				-	5
	d	2			x			-	3
5	a	2		x				-	2
	b	2		x				-	2
	c	2		x				-	2
	d	4						-	4
8	a	4						-	5
	b	5						-	5
	c	4						-	5
	d	3	x					-	2
12	a	5						-	5
	b	3			x			Wrong position of section.	5
	c	5						-	5
	d	4	x					-	4

Línea 4 - A-316									
Experto	**Solución**	**Segmentación**							**Clasificación**
		Punt.	**Problemas**					**Observaciones**	**Puntuación**
			1	**2**	**3**	**4**	**5**		
4	a	3		x				-	3
	b	3		x				-	3
	c	2			x			-	2
	d	2			x			-	2
7	a	5	x					-	3
	b	3						-	3
	c	5	x					-	4
	d	3	x		x			-	3
14	a	3						-	4
	b	2		x	x			-	5
	c	4						-	2
	d	2	x		x			-	3

Línea 5 - A-311									
Experto	**Solución**	**Segmentación**							**Clasificación**
		Punt.	**Problemas**					**Observaciones**	**Puntuación**
			1	**2**	**3**	**4**	**5**		
1	a=b=c=d	4						Yo he hecho división, no me parece bien no hacerlas. Estoy de acuerdo.	4
5	a=b=c=d	4						-	4
8	a=b=c=d	3						Correcto.	3
15	a=b=c=d	5						-	5

Línea 6 - A-320									
Experto	**Solución**	**Segmentación**							**Clasificación**
		Punt.	**Problemas**					**Observaciones**	**Puntuación**
			1	**2**	**3**	**4**	**5**		
3	a	5						Buen criterio.	5
	b	3	x			x		-	3
	c	4						Iguel que el a.	4
	d	3			x			-	3
6	a	5						-	5
	b	3	x					-	3
	c	4						-	3
	d	2			x			-	2
9	a	4			x			-	3
	b	3	x					-	3
	c	5						-	4
	d	4	x					-	4
17	a	5						-	5
	b	3	x				x	-	3
	c	5						-	4
	d	2	x		x			Falta un recuadro.	2

Línea 7 - A-324									
Experto	**Solución**	**Segmentación**							**Clasificación**
		Punt.	**Problemas**					**Observaciones**	**Puntuación**
			1	**2**	**3**	**4**	**5**		
7	a	4	x				x	-	4
	b	3	x				x	-	5
	c	4						-	4
	d	4						-	3
11	a	4,5						Depending on the segmentation criteria used, I would consider this solution equally good as my solution.	4,5
	b	3	x					Still quite a good solution.	4
	c	2		x	x	x		-	3
	d	1		x	x	x		-	3
13	a	4			x			-	4
	b	5						-	4
	c	2		x				-	1
	d	1		x				-	1
19	a	5						-	4
	b	4					x	La 4ª sección es corta.	4
	c	2		x				La última sección puede desdoblarse.	3
	d	2			x			La 2ª marca está en lugar incorrecto.	3

Línea 8 - A-1102									
Experto	**Solución**	**Segmentación**							**Clasificación**
		Punt.	**Problemas**					**Observaciones**	**Puntuación**
			1	**2**	**3**	**4**	**5**		
1	a	3		x				-	2
	b	4	x					Muy bien, solo falta la primera división.	4
	c	2		x	x			-	2
	d	1			x	x		Cambios en lugares incorrectos.	3
4	a	4						-	3
	b	2						No entiendo por qué sale como tipo 4 el segmento superior.	4
	c	3						-	4
	d	2						-	2
16	a	3			x			-	4
	b	2			x		x	-	4
	c	2			x	x		-	4
	d	2			x	x		-	4

Línea 9 - JV-2222									
Experto	**Solución**	**Segmentación**							**Clasificación**
		Punt.	**Problemas**					**Observaciones**	**Puntuación**
			1	**2**	**3**	**4**	**5**		
2	a	4		x				-	3
	b	2		x		x		-	4
	c	3		x				-	2
	d	4		x				-	1
6	a	4			x			-	4
	b	4		x		x		-	3
	c	2		x	x			-	3
	d	2			x			-	2
10	a	5						-	5
	b	2		x	x			-	3
	c	3		x	x			-	3
	d	4						-	4

Línea 10 - JV-2223									
Experto	**Solución**	**Segmentación**							**Clasificación**
		Punt.	**Problemas**					**Observaciones**	**Puntuación**
			1	**2**	**3**	**4**	**5**		
3	a	1		x				-	5
	b	3	x		x			-	3
	c	3			x			-	2
	d	2			x			-	2
8	a	3				x		-	5
	b	2	x				x	-	4
	c	2					x	-	3
	d	4						-	3
7	a	5						-	5
	b	3	x					-	4
	c	2	x					-	2
	d	3	x					-	4
16	a	3			x	x		-	5
	b	2			x		x	-	3
	c	2			x		x	-	2
	d	4			x			-	2

Línea 11 - JV-2224									
Experto	**Solución**	**Segmentación**							**Clasificación**
		Punt.	**Problemas**					**Observaciones**	**Puntuación**
			1	**2**	**3**	**4**	**5**		
4	a	3		x				-	2
	b	2			x		x	-	2
	c	3		x				Me parece igual que la a.	3
	d	5						-	3
8	a	3						-	3
	b	2	x					-	2
	c	3						-	3
	d	5						-	4
14	a	3						-	4
	b	2	x		x			-	3
	c	4						-	4
	d	2			x			-	2
16	a	3			x			-	4
	b	2				x		-	4
	c	2				x		-	5
	d	2				x		-	5

Línea 12 - JV-2225									
Experto	**Solución**	**Segmentación**							**Clasificación**
		Punt.	**Problemas**					**Observaciones**	**Puntuación**
			1	**2**	**3**	**4**	**5**		
1	a	4		x				Se parece bastante a la mía.	5
	b	4		x				Parecida a la anterior, quizá algo mejor.	5
	c	3		x				Puede valer, pero creo que se puede segmentar.	4
	d	2			x		x	División en lugares incorrectos e innecesarios.	2
5	a	5						-	5
	b	4						-	5
	c	1						-	1
	d	2					x	-	2
8	a	3					x	-	5
	b	3					x	-	5
	c	3				x		-	5
	d	3	x					-	4
9	a	4						-	4
	b	3			x			-	4
	c	5						-	4
	d	3			x			-	4

Línea 13 - JV-2226									
Experto	**Solución**	**Segmentación**							**Clasificación**
		Punt.	**Problemas**					**Observaciones**	**Puntuación**
			1	**2**	**3**	**4**	**5**		
6	a	3		x				-	3
	b	3			x			-	4
	c	3		x				-	2
	d	4						-	4
15	a	5						-	5
	b	3			x			-	4
	c	5						-	5
	d	3			x			-	4
19	a	3		x				Satisfactorio si consideramos ambos tramos como clase 4.	3
	b	5						-	5
	c	3						Igual que a.	3
	d	4						Igual que b.	5
17	a	2	x	x				Admite 1 ó 3 tramos, no 2.	4
	b	4			x			-	4
	c	2	x	x				Admite 1 ó 3 tramos, no 2.	4
	d	4						-	5

Línea 14 - JV-3012									
Experto	**Solución**	**Segmentación**							**Clasificación**
		Punt.	**Problemas**					**Observaciones**	**Puntuación**
			1	**2**	**3**	**4**	**5**		
4	a	4						Resultado similar a d.	2
	b	2		x				-	2
	c	2			x			-	5
	d	5						-	3
7	a	5						-	4
	b	5						-	4
	c	3					x	-	4
	d	4					x	-	4
13	a	5						-	5
	b	3						-	1
	c	1	x					-	1
	d	5						-	2
15	a	4						-	4
	b	3						-	3
	c	3						-	3
	d	4						-	4

Línea 15 - JV-3241									
Experto	**Solución**	**Segmentación**							**Clasificación**
		Punt.	**Problemas**					**Observaciones**	**Puntuación**
			1	**2**	**3**	**4**	**5**		
1	a	5						Coincide con mi división milimétricamente.	5
	b	3		x	x			También queda bastante bien, la útlima división algo más abajo debe quedar.	4
	c	4				x		Bastante bien.	4
	d	3	x				x	No me desagrada, pero creo que hay demasiadas divisiones, algunas no necesarias.	5
3	a	4						Es la segmentación que más me gusta.	5
	b	2			x	x		Poco segmentada.	3
	c	2		x				Poco segmentada.	3
	d	2	x		x			-	4
12	a	4						-	5
	b	3		x				-	4
	c	3		x	x			-	4
	d	2	x		x			-	1
18	a	4						-	5
	b	1		x		x		-	3
	c	2		x	x	x		-	1
	d	3	x				x	-	2

Línea 16 - JV-3242									
Experto	**Solución**	**Segmentación**							**Clasificación**
		Punt.	**Problemas**					**Observaciones**	**Puntuación**
			1	**2**	**3**	**4**	**5**		
2	a	5						-	3
	b	4		x		x		-	5
	c	3	x					-	4
	d	2			x			-	2
6	a	3			x			-	5
	b	3	x					-	3
	c	4	x					-	5
	d	3			x			-	3
7	a	4						-	5
	b	2					x	-	3
	c	3	x					-	5
	d	3						-	2
16	a	4			x			-	4
	b	2			x	x	x	-	3
	c	2	x		x			-	3
	d	3			x			-	2

Línea 17 - JP-2332										
Experto	**Solución**	**Segmentación**								**Clasificación**
		Punt.	**Problemas**					**Observaciones**		**Puntuación**
			1	**2**	**3**	**4**	**5**			
3	a	3			x			-		3
	b	5						Está bien.		3
	c	2			x	x		-		2
	d	3				x		Podría ser válida dependiendo, creo, del grado de generalización.		4
14	a	1			x			-		2
	b	5						-		1
	c	1		x	x			-		2
	d	1		x	x			-		3
16	a	5						-		3
	b	4			x		x	-		5
	c	2						-		2
	d	1		x				-		4
17	a	3	x				x	-		4
	b	3	x				x	-		3
	c	2			x		x	-		2
	d	4			x			-		4

Línea 18 - CaminoAncho										
Experto	**Solución**	**Segmentación**								**Clasificación**
		Punt.	**Problemas**					**Observaciones**		**Puntuación**
			1	**2**	**3**	**4**	**5**			
1	a=b=c	3		x		x		Podría ser, pero yo creo que se puede y se debe segmentar.		3
	d	4			x			Bastante de acuerdo, sólo alguna descrepancia en la posición de los cortes.		3
4	a=b=c	5						-		5
	d	2	x					-		2
12	a=b=c	4						-		4
	d	1			x			Midden section should be of type 1.		3,5
18	a=b=c	2		x		x		Existe una zona suave claramente diferenciable.		2
	d	3			x			Considero que la sección 1 debería ser mas larga.		3

Línea 19 - CaminoAzadillas									
Experto	**Solución**	**Segmentación**							**Clasificación**
		Punt.	**Problemas**					**Observaciones**	**Puntuación**
			1	**2**	**3**	**4**	**5**		
5	a	5						-	4
	b	2		x				-	2
	c	3		x				-	3
	d	2		x				-	3
7	a	3	x				x	-	2
	b	2	x		x		x	-	3
	c	5						-	5
	d	4			x			-	4
13	a	5						-	4
	b	1			x		x	-	3
	c	2				x		-	5
	d	2				x		-	5
14	a	2	x		x			-	5
	b	2	x		x			-	4
	c	3						-	4
	d	2	x					-	4

Línea 20 - P-CerroAlmaden									
Experto	**Solución**	**Segmentación**							**Clasificación**
		Punt.	**Problemas**					**Observaciones**	**Puntuación**
			1	**2**	**3**	**4**	**5**		
6	a	2			x			-	4
	b	2	x		x			-	4
	c	2			x			-	4
	d	2			x			-	4
11	a	1			x			The segmentation happens at places which do not seem very logical.	3
	b	2							3
	c	4			x				4
	d	1			x			Similar arguments as for proposal a.	5
19	a	1			x			Todos los cambios en sitios incorrectos.	2
	b	2			x			Algún cambio incorrecto. Todos los cambios incorrectos.	1
	c	4						Un cambio dudoso. Dudas en 1 cambio.	4
	d	2						El último cambio inadecuado. Duda en 1 cambio.	4
17	a	2			x			Separa secciones similares.	4
	b	3			x			-	5
	c	3			x			Separa secciones similares	3
	d	3			x			-	4

Línea 21 - P-CerroJabalcuz									
Experto	**Solución**	**Segmentación**							**Clasificación**
		Punt.	**Problemas**					**Observaciones**	**Puntuación**
			1	**2**	**3**	**4**	**5**		
3	a	1			x			-	5
	b	3		x				-	5
	c	2			x			-	4
	d	2			x			-	5
7	a	5					x	-	5
	b	5						-	5
	c	5					x	-	5
	d	5						-	5
10	a	2	x		x			-	4
	b	5		x				-	5
	c	5						-	4
	d	4			x			-	2
18	a	3						-	3
	b	2		x	x			-	3
	c	2			x	x		-	3
	d	2			x	x		-	3

Línea 22 - P-CerroSantin									
Experto	**Solución**	**Segmentación**							**Clasificación**
		Punt.	**Problemas**					**Observaciones**	**Puntuación**
			1	**2**	**3**	**4**	**5**		
1	a	4		x				Podría ser así.	4
	b	2	x		x		x	Demasiados cambios que no vienen a cuento.	2
	c	4			x			Muy parecido a mi propuesta.	5
	d	3			x			Bastante de acuerdo.	3
16	a	2				x		-	3
	b	2			x		x	-	2
	c	4			x			-	3
	d	3			x			-	2
3	a	3		x				-	3
	b	1			x			-	4
	c	3			x			-	4
	d	1			x			-	4

Línea 23 - P-Pegalajar-Central									
Experto	**Solución**	**Segmentación**							**Clasificación**
		Punt.	**Problemas**					**Observaciones**	**Puntuación**
			1	**2**	**3**	**4**	**5**		
2	a	2			x			-	3
	b	1		x		x		-	3
	c	4						-	2
	d	2			x			-	3
4	a	4						-	3
	b	5						-	5
	c	2	x				x	-	1
	d	2	x				x	-	2
8	a	5						Correcto.	5
	b	3				x		-	4
	c	2			x			-	3
	d	3					x	-	3
15	a	4						-	4
	b	2		x				-	2
	c	3						-	3
	d	2			x			-	1

Línea 24 - P-SierraPeñaAguila									
Experto	**Solución**	**Segmentación**							**Clasificación**
		Punt.	**Problemas**					**Observaciones**	**Puntuación**
			1	**2**	**3**	**4**	**5**		
3	a	2			x	x		-	3
	b	2	x			x		-	3
	c	2		x		x		-	5
	d	4						Más parecido a mi criterio	4
8	a	3				x		-	4
	b	2	x			x		-	2
	c	3		x				-	3
	d	4			x			-	2
6	a	3			x			-	4
	b	3	x		x		x	-	4
	c	3		x				-	2
	d	4			x			-	2
9	a	4	x					-	4
	b	4			x			-	5
	c	2	x		x			-	4
	d	3	x		x			-	4

Anexo F. Normativa sobre carreteras

Este anexo complementa al apartado III.2.2.1 en el que se analizaron los criterios de diseño de algunas de las vías de comunicación de la muestra. Se resumen las sucesivas normativas aprobadas en cuanto al diseño de vías de comunicación, estructurándose en dos apartados: normativa estatal y normativa autonómica andaluza.

F.1. Normativa estatal

Las distintas normativas aprobadas en el último siglo en nuestro país referentes al trazado de vías para vehículos automóviles son las siguientes:

- Orden de 11 de agosto de 1939 aprobando la Instrucción de Carreteras (BOE 331/1939).
- Orden de 27 de junio de 1961 del Ministerio de Obras Públicas por la que se deroga la Instrucción de Carreteras, aprobada por Orden ministerial de 11 de agosto de 1939 (BOE 187/1961 de 7 de agosto de 1961).
- Orden de 23 de abril de 1964 por la que se aprueba la Instrucción de la Dirección General de Carreteras 3.1-IC "Características geométricas. Trazado" (BOE 150/1964, de 23 de junio de 1964).
- Orden de 12 de marzo de 1976 por la que se aprueba el documento "Instrucción de Carreteras. Norma complementaria de la 3.1-IC. Trazado de autopistas" (BOE. 86/1976, de 9 de abril de 1976).
- Orden de 27 de diciembre de 1999 por la que se aprueba la Norma 3.1-IC. Trazado, de la Instrucción de Carreteras (BOE 28/2000, de 2 de febrero de 2000).
- Orden de 13 septiembre 2001 de modificación parcial de la Orden de 16 de diciembre de 1997 por la que se regulan los accesos a las carreteras del Estado, las vías de servicio y la construcción de instalaciones de servicios y de la Orden de 27 de diciembre de 1999 por la que se aprueba la norma 3.1-IC.

Trazado, de la Instrucción de Carreteras (BOE 231/2001, de 26 de septiembre de 2001).

En las tablas F.1, F.2 y F.3 se presentan, respectivamente, algunos de los parámetros que regulan el diseño de los trazados en planta. Se aprecia una clara evolución de las normas de trazado, cuya rigurosidad va en aumento, al incrementarse las velocidades de los vehículos (por ejemplo, en 1939 se les suponía una velocidad de 60 km/h) y los requisitos de seguridad y comodidad, que imponen fuertes restricciones.

Tabla F.1 - Instrucción de Carreteras (BOE 331/1939). Algunos parámetros del trazado en planta.

Curvas circulares
En todas las nuevas construcciones o variantes que mejoren las carreteras nacionales, comarcales y locales, las curvas mínimas admitidas tendrán como radio 100, 60 y 40 metros.
Podrán tolerarse en los trazados existentes zigzags cuyos radios mínimos sean de 40, 30 y 16 metros.

Tabla F.2 - Norma 3.1-IC. Trazado, de la Instrucción de Carreteras (BOE 150/1964, de 23 de junio de 1964). Algunos parámetros del trazado en planta.

Rectas			
Son aceptables longitudes máximas comprendidas entre 500 y 2000 m según la velocidad específica.			
Las longitudes mínimas deberán estar comprendidas entre 50 y 200 m.			
Curvas circulares			
No se aconseja utilizar radios superiores a 10.000 m.			
Velocidad específica [km/h]	**Radio mínimo [m]**	**Velocidad específica [km/h]**	**Radio mínimo [m]**
30	25	80	250
40	45	90	350
50	75	100	450
60	120	120	800
70	175		

Tabla F.3 - Norma 3.1-IC. Trazado, de la Instrucción de Carreteras (BOE 28/2000, de 2 de febrero de 2000). Algunos parámetros del trazado en planta.

Rectas

Longitud mínima de una alineación recta entre alineaciones curvas con radios de curvatura de sentido contrario:	$L_{min.s} = 1{,}39\ V_p$ (V_p = velocidad de proyecto)
Longitud mínima de una alineación recta entre alineaciones curvas con radios de curvatura del mismo sentido:	$L_{min.o} = 2{,}78\ V_p$
Longitud máxima recomendable:	$L_{max} = 16{,}70\ V_p$

V_p [km/h]	$L_{min.s}$ [m]	$L_{min.o}$ [m]	L_{max} [m]
40	56	111	668
50	69	139	835
60	83	167	1002
70	97	194	1169
80	111	222	1336
90	125	250	1503
100	139	278	1670
110	153	306	1837
120	167	333	2004

Curvas circulares

Desarrollo mínimo de 20^g. Se aceptan hasta 9^g y excepcionalmente valores inferiores.

Autopistas, autovías, vías rápidas y carreteras C-100		Carreteras C-80, C-60 y C-40	
Velocidad específica [km/h]	Radio mínimo [m]	Velocidad específica [km/h]	Radio mínimo [m]
80	250	40	50
85	300	45	65
90	350	50	85
95	400	55	105
100	450	60	130
105	500	65	155
110	550	70	190
115	600	75	225
120	700	80	265
125	800	85	305
130	900	90	350
135	1050	95	410
140	1250	100	485
145	1475	105	570
150	1725	110	670

Clotoide

Autopistas, autovías, vías rápidas y carreteras C-100: se emplean clotoides para circulares de radio inferior a 5000 m.

Carreteras C-80, C-60 y C-40: se emplean clotoides para circulares de radios inferior a 2500 m.

La variación del acimut entre los extremos ha de ser como mínimo de 1/18 radianes.

F.2. Normativa autonómica andaluza

Tras la aprobación de la Ley Orgánica 6/1981, de 30 de diciembre, Estatuto de Autonomía para Andalucía (BOE 9/1982, de 11 de enero de 1982), la Comunidad Autónoma de Andalucía adquirió, entre otras, la competencia exclusiva (artículo

13.10) sobre "Los ferrocarriles, carreteras y caminos cuyo itinerario se desarrolla íntegramente en territorio andaluz y en los mismos términos, el transporte desarrollado por estos medios por vía fluvial o por cable". Esta competencia fue transferida por el Estado mediante el Real Decreto 951/1984, de 28 de marzo, sobre traspaso de funciones y servicios del Estado a la Comunidad Autónoma de Andalucía en materia de carreteras (BOE de 22 de mayo de 1984).

Para desarrollar esta competencia adquirida en cuanto a las carreteras, se aprobó la Resolución de 10 de enero de 1985, por la que se crea la Oficina del Plan General de Carreteras (BOJA 6/1985, de 22 de enero de 1985), formulándose a partir de ese momento un conjunto de documentos de planificación que, con un horizonte de veinte años (1987-2006), establecieron una programación de actuaciones para los dos primeros cuatrienios.

Las directrices del Plan General de Carreteras[1] (PGCA) fueron especificadas posteriormente en el Decreto 296/1995, de 19 de diciembre, por el que se acuerda la formulación del Plan General de Carreteras de Andalucía (BOJA 166/1995, de 28 de diciembre de 1995). Los objetivos del PGCA, programado inicialmente para los años 1996 a 2007, fueron los de revisar los documentos de planificación, valorar su nivel de ejecución, analizar el escenario actual y sus tendencias, definir la política sectorial de carreteras y programar las actuaciones necesarias en la red para adaptarla a los niveles de servicios propuestos. En el artículo 2 del citado Decreto, se especifica como objetivo el del "Establecimiento de las directrices de diseño del Plan en cuanto a: parámetros geométricos de las redes en función de las características topográficas, niveles de tráfico, jerarquía de la carretera e incidencia en el medio ambiente; intersecciones, enlaces, variantes de poblaciones, vías lentas, y vías de incorporación; características de vías rápidas, de desdoblamientos y de autovías." Así, el PGCA es el que define las características del trazado geométrico de las distintas categorías establecidas para la red viaria andaluza, que se presentan en las tablas F.4 y F.5. Todas las actuaciones a realizar

[1] En el año 2001 se aprobó la Ley 8/2001, de 12 de julio, de Carreteras de Andalucía (BOJA 85/2001, de 26 de julio de 2001), que estableció, en el apartado 1 del artículo 22[1], que el Plan General de Carreteras de Andalucía "es el superior instrumento técnico y jurídico de la planificación viaria de toda la red de carreteras de Andalucía".

en el ámbito de la Comunidad Autónoma de Andalucía, tanto para vías de nuevo trazado como para las reformas de las existentes, se han de ajustar a este PGCA.

Tabla F.4 - Plan General de Carreteras de Andalucía. Características del trazado geométrico de las categorías definidas para las redes Básica e Intercomarcal

		RED BÁSICA				RED INTERCOMARCAL											
Intensidad Media Diaria (IMD) (v/d)		-				5000 - 3000				3000 - 1000				< 1000			
Terreno (*)		**LL**	**O**	**A**	**MA**	**LL**	**O**	**A**	**MA**	**LL**	**O**	**A**	**MA**	**LL**	**O**	**A**	**MA**
Denominación (**)		**B-11**	**B-12**	**B-13**	**B-14**	**I-11**	**I-12**	**I-13**	**I-14**	**I-21**	**I-22**	**I-23**	**I-24**	**I-31**	**I-32**	**I-33**	**I-34**
Velocidad de proyecto (km/h)		120	100	80	70	100	80	70	60	80	70	60	50	70	60	50	40
Radio mínimo en planta (m)		800	450	250	180	450	250	180	120	250	180	120	75	180	120	75	40
Curva de transción mínima en planta (m)		260	150	80	60	150	80	60	40	80	60	40	25	60	40	25	15
Peralte máximo (%)		3	5	6,5	7	5	6,5	7	8	6,5	7	8	9	7	8	9	10
Pendiente máxima (%)		3	4	5	6	4	5	5	6	5	5	6	7	5	6	7	7
Calzada mínima (m)		7,0	7,0	7,0	7,0	7,0	7,0	7,0	7,0	7,0	7,0	7,0	7,0	6,0	6,0	6,0	6,0
Arcenes mínimos (m)		1,5	1,5	1,5	1,5	1,5	1,5	1,5	1,5	0,5	0,5	0,5	0,5	1,0	1,0	1,0	1,0
Curva vertical convexa	**Parámetro (Kv)**	15000	8000	3500	2500	8000	3500	2500	1400	3500	2500	1400	1400	2500	1400	1400	1400
	Longitud mínima (m)	120	100	80	70	100	80	70	60	80	70	60	60	70	60	60	60
Curva vertical cóncava	**Parámetro (Kv)**	6000	4500	2500	2000	4500	2500	2000	1400	2500	2000	1400	1400	2000	1400	1400	1400
	Longitud mínima (m)	120	100	80	70	100	80	70	60	80	70	60	60	70	60	60	60
Plataforma en estructuras (m)		11,0	11,0	11,0	11,0	11,0	11,0	11,0	11,0	9,0	9,0	9,0	9,0	9,0	9,0	9,0	9,0

(*) Las categorías de terreno son: Llano (LL), Ondulado (O), Accidentado (A), Muy Accidentado (MA)

(**) La denominación sigue la siguiente codificación:

- Primer carácter: codificación de la jerarquía. Es el carácter alfabético inicial del tipo de Red: B para la Básica, I para la Intercomarcal, C para la Comarcal y L para la local.
- Segundo carácter: codificación de la sección transversal de la calzada (que es función de la categoría de la carretera y de la IMD). Es un carácter numérico del 1 al 5: el 1 para la sección 7 -10 (calzada mínima de 7 m, más 3 m de arcenes) el 2 para la sección 7-8, el 3 para la sección 6-8, el 4 para la sección 6-7 y el 5 para la sección 6-6.
- Tercer carácter: codificación del tipo de terreno. Es un carácter numérico comprendido entre el 1 y el 4. El 1 para el terreno llano, el 2 para el terreno ondulado, el 3 para el terreno accidentado, el 4 para el terreno muy accidentado.

Tabla F.5 - Plan General de Carreteras de Andalucía. Características del trazado geométrico de las categorías definidas para las redes Comarcal y Local

		RED COMARCAL								RED LOCAL							
Intensidad Media Diaria (IMD) (v/d)		**3000 - 1000**				**< 1000**				**1000 - 250**				**< 250**			
Terreno (*)		**LL**	**O**	**A**	**MA**	**LL**	**O**	**A**	**MA**	**LL**	**O**	**A**	**MA**	**LL**	**O**	**A**	**MA**
Denominación (**)		**C-31**	**C-32**	**C-33**	**C-34**	**C-41**	**C-42**	**C-43**	**C-44**	**L-41**	**L-42**	**L-43**	**L-44**	**L-51**	**L-52**	**L-53**	**L-54**
Velocidad de proyecto (km/h)		70	60	50	40	60	50	40	30	60	50	40	30	50	40	30	30
Radio mínimo en planta (m)		180	120	75	40	120	75	40	25	120	75	40	25	75	40	25	25
Curva de transción mínima en planta (m)		60	40	25	15	40	25	15	10	40	25	15	10	25	15	10	10
Peralte máximo (%)		7	8	9	10	8	9	10	10	8	9	10	10	9	10	10	10
Pendiente máxima (%)		5	6	7	8	6	7	8	8	6	7	8	9	7	8	9	9
Calzada mínima (m)		6,0	6,0	6,0	6,0	6,0	6,0	6,0	6,0	6,0	6,0	6,0	6,0	6,0	6,0	6,0	6,0
Arcenes mínimos (m)		1,0	1,0	1,0	1,0	0,5	0,5	0,5	0,5	0,5	0,5	0,5	0,5	0,0	0,0	0,0	0,0
Curva vertical convexa	**Parámetro (Kv)**	2500	1400	1400	1400	1400	1400	1400	1400	1400	1400	1400	1400	1400	1400	1400	1400
	Longitud mínima (m)	70	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60
Curva vertical cóncava	**Parámetro (Kv)**	2000	1400	1400	1400	1400	1400	1400	1400	1400	1400	1400	1400	1400	1400	1400	1400
	Longitud mínima (m)	120	60	60	60	60	60	60	60	60	60	60	60	60	60	60	60
Plataforma en estructuras (m)		9,0	9,0	9,0	9,0	8,0	8,0	8,0	8,0	8,0	8,0	8,0	8,0	7,0	7,0	7,0	7,0

(*) Las categorías de terreno son: Llano (LL), Ondulado (O), Accidentado (A), Muy Accidentado (MA)

(**) La denominación sigue la siguiente codificación:

- Primer carácter: codificación de la jerarquía. Es el carácter alfabético inicial del tipo de Red: B para la Básica, I para la Intercomarcal, C para la Comarcal y L para la local.
- Segundo carácter: codificación de la sección transversal de la calzada (que es función de la categoría de la carretera y de la IMD). Es un carácter numérico del 1 al 5: el 1 para la sección 7 -10 (calzada mínima de 7 m, más 3 m de arcenes) el 2 para la sección 7-8, el 3 para la sección 6-8, el 4 para la sección 6-7 y el 5 para la sección 6-6.
- Tercer carácter: codificación del tipo de terreno. Es un carácter numérico comprendido entre el 1 y el 4. El 1 para el terreno llano, el 2 para el terreno ondulado, el 3 para el terreno accidentado, el 4 para el terreno muy accidentado.

Anexo G. Empleo del programa JavaNNS

En el presente Anexo se concretan algunas de las particularidades del manejo del programa JavaNNS[1] (Java Neural Network Simulator) que, como se ha indicado en el apartado III.4.3.6, se ha empleado para crear y entrenar la red neuronal que efectúa la tarea de clasificación automática de las secciones procedentes de las tareas de segmentación.

De esta forma, el presente anexo se estructura en varios apartados que siguen el orden lógico de utilización del programa en este trabajo: creación de un archivo patrón para alimentar a una red, creación de una red neuronal, proceso de aprendizaje de la red, y a la aplicación de la red entrenada.

G.1. Formato del archivo de patrón

Este formato, que se almacena en un fichero de texto con extensión '.pat', tiene una sencilla estructura formada por una cabecera y un cuerpo (véase la Tabla G.1). En la cabecera se indica el tipo de archivo, la fecha y hora de generación, así como el número de patrones que contiene, indicando también el número de neuronas de entrada y de salida. En el cuerpo se incluyen los valores de entrada y salida de la red para cada patrón, separados por un salto de línea. Entre patrón y patrón se introduce una línea en blanco.

La preparación de los ficheros patrón en formato JavaNNS se puede realizar de forma sencilla con una hoja de cálculo, con una fila de valores de entrada y una de valores de salida por cada una de las secciones del patrón. Así, para los valores de entrada se han empleado 9 columnas para las medidas caracterizadoras, normalizadas en el intervalo [-1, 1] y 5 columnas para las categorías de las vías de comunicación (1 si pertenece a la categoría y -1 en caso

[1] JavaNNS puede conseguirse en:
http://www-ra.informatik.uni-tuebingen.de/software/JavaNNS/welcome_e.html

contrario). Los valores de salida se han introducido mediante 5 columnas, insertando "1" en la clase a la que pertenece y "0" en el resto.

Tabla G.1 - Ejemplo de archivo de patrón de JavaNNS con 9 patrones, cada uno de ellos con los valores de 14 neuronas de entrada y 5 de salida.

Cabecera	SNNS pattern definition file V3.2 generated at Fri Apr 22 16:56:45 2004 No. of patterns : 9 No. of input units : 14 No. of output units : 5
Cuerpo	0,75 0,58 -0,69 0,68 -0,76 -0,87 -0,5436 -0,64 -0,81 1 -1 -1 -1 -1 1 0 0 0 0 0,93 -0,94 0,42 0,99 -0,96 -0,42 -0,95 0,01 -0,33 -1 -1 1 -1 -1 0 1 0 0 0 0,96 -0,83 -1 0,96 -0,90 -0,60 -0,65 -0,25 -0,60 -1 -1 -1 1 -1 0 1 0 0 0 0,79 -0,79 -0,51 0,20 0,22 -0,47 0,28 -0,57 -0,48 -1 -1 -1 1 -1 0 0 1 0 0 0,73 -0,91 -0,56 0,68 -0,78 -0,83 -0,17 -0,51 -0,62 -1 -1 -1 1 -1 0 0 1 0 0 0,46 -0,67 -0,50 -1 0,78 -0,60 -0,56 -0,26 -0,68 -1 -1 -1 1 -1 0 0 1 0 0 0,26 -0,56 0,33 -0,06 0,62 -0,53 -0,27 -0,38 -0,71 -1 -1 -1 1 -1 0 0 0 1 0 0,07 -0,98 -0,47 0,76 0,11 -0,38 -0,13 -0,30 -0,65 -1 -1 -1 -1 1 0 0 0 1 0 -0,71 -0,92 -0,14 0,89 0,80 0,40 -0,53 -0,05 -0,53 -1 -1 -1 -1 1 0 0 0 0 1

G.2. Creación de una red neuronal

La creación de una red en JavaNNS se realiza capa a capa, mediante la opción de *create layers*. La ventana que aparece solicita en primer lugar el tamaño de la capa mediante la anchura y altura de la capa (siendo la unidad de estas dos magnitudes una neurona). Seguidamente se especifican de forma simultánea varias características comunes a todas las neuronas de la capa: el tipo de neurona (*input*-entrada, *output*-salida, *hidden*-oculta), función de activación, función de salida, número de capa y número de subred. A modo de ejemplo, en la Figura G.1 se muestra la ventana con los datos introducidos para la creación de la capa de entrada.

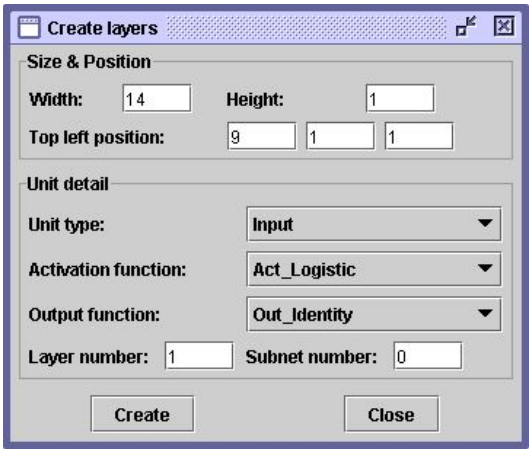


Figura G.1 - Ventana de JavaNNS para la creación de una nueva capa.

Las conexiones, hacia delante en el caso de una red Backpropagation, también pueden ser creadas automáticamente, pulsando sobre la opción pertinente. JavaNNS muestra de forma gráfica la creación de la red, tal y como puede verse en la Figura G.2, que se interpreta de forma sencilla:

- Cada cuadrado representa una neurona.
- Cada neurona va acompañada de dos campos de texto. El que se sitúa sobre la neurona es un nombre libre que puede asignarle el usuario. El que se encuentra debajo es de tipo numérico e indica el valor de activación de la neurona, nulo en el momento de crear la red.
- Las conexiones entre las neuronas se indican mediante flechas. Hacia la mitad de cada flecha se localiza un nuevo campo de texto de tipo numérico que indica el peso de cada conexión, que también es nulo antes de cualquier tipo de entrenamiento.

Cada arquitectura, y sus valores de las conexiones, es almacenada en un archivo de texto, con extensión '.net', en un formato propio que JavaNNS genera automáticamente.

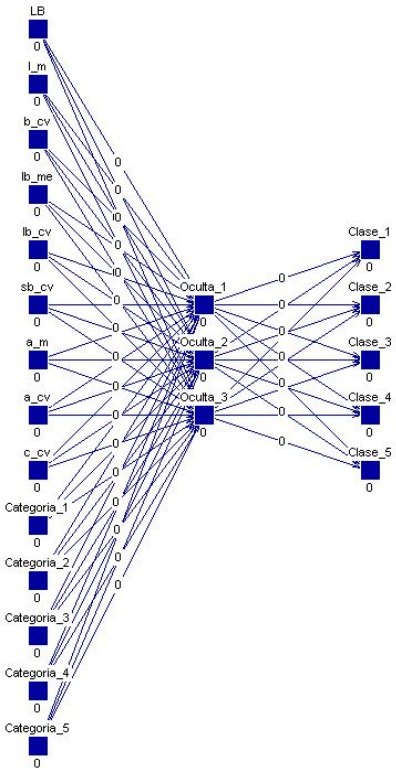


Figura G.2 - Representación gráfica de JavaNNS al crear la red neuronal con 3 neuronas ocultas.

G.3. Aprendizaje de la red

JavaNNS centraliza sus posibilidades de entrenamiento de una red a través de su Panel de Control (Figura G.3) en la pestaña *Learning*. En primer lugar se ha de seleccionar el tipo de función de aprendizaje de entre las múltiples disponibles en el programa, que en este trabajo es la de la regla delta generalizada más la adición de un momento, que en JavaNNS se indica como *Backprop-Momentum*.

Los parámetros que muestra JavaNNS para este tipo de aprendizaje son cuatro:

- η, tasa de aprendizaje, que normalmente se indica con α.
- μ, influencia del momento, que normalmente se indica con β.
- *dmax*, máxima diferencia tolerada en la salida. Un error en la salida que sea inferior a *dmax*, retropopagará un error nulo durante el aprendizaje.

- *c*, parámetro de *flat spot elimination*; se trata de un valor constante añadido a la derivada de la función de activación, que permite mejorar el proceso de aprendizaje en regiones donde las derivadas sean próximas a cero.

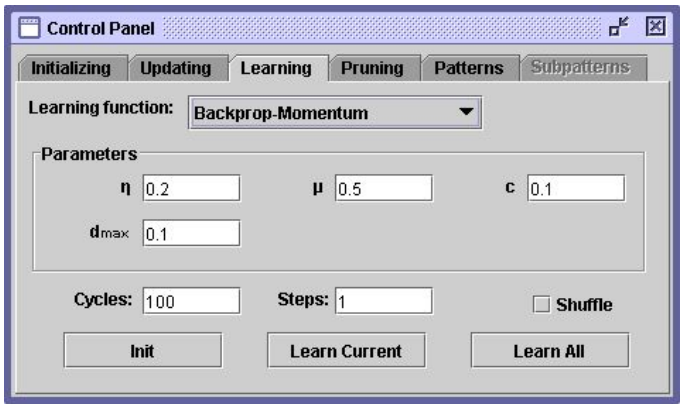


Figura G.3 - Panel de Control de JavaNNS. Pestaña de aprendizaje. Parámetros de la función de aprendizaje *Backprop-Momentum*.

Un ciclo de aprendizaje completo con JavaNNS necesita de la consecución de los siguientes pasos:

- Apertura del archivo '.net' correspondiente a la red que se quiere entrenar.
- Apertura del archivo de patrón '.pat' que se va a utilizar para el aprendizaje.
- Apertura del archivo de patrón '.pat' que se va a emplear para la prueba.
- Especificación del patrón de aprendizaje y del patrón de validación, a través de la pestaña *Patterns* del panel de control. Selección del patrón de prueba como patrón de validación.
- Apertura del gráfico de la gráfica de error de JavaNNS, para verificar cómo evoluciona los errores durante el aprendizaje, tanto el del patrón de prueba como el del patrón de validación.
- Inicialización de los pesos de las conexiones, pulsando sobre el botón *Init* del panel de control. Esto hace que aleatoriamente todos los pesos de la red tomen aleatoriamente un valor en un intervalo especificado, por ejemplo el [-1, 1].
- Introducción del número de iteraciones (*cycles*) e inicialización del entrenamiento (botón *Learn All*).

Una vez se haya dado por finalizado el entrenamiento, la red entrenada se guardaría en el archivo '.net' correspondiente, en el que quedarían almacenados los pesos entre las neuronas y los umbrales de cada una de ellas, en el formato propio de JavaNNS.

G.4. Aplicación de una red entrenada

Una vez se dispone de una red entrenada se ha de pretender su empleo para el objetivo para el cual se diseñó. En este caso será la clasificación de una sección en una de las cinco clases definidas, a partir de los valores introducidos en las catorce neuronas de la capa de entrenada.

En JavaNNS el proceso para realizar esta operación sería el siguiente:

- Apertura del archivo '.net' correspondiente a la red que se quiere utilizar.
- Apertura del archivo de patrón '.pat' que se va a utilizar para alimentar la red.
- Pulsar sobre la opción *Save data*, en el menú *File*.

De esta forma se generará un archivo de resultados de la red neuronal con extensión '.res'. En el caso de este trabajo, se podrá comprobar para cada sección del patrón cuáles son los valores de las cinco neuronas de salida, que oscilarán entre 0 y 1.

Índices

Índice de figuras

Figura I.1 Fotografía aérea de parte de la ciudad de Sevilla (arriba) y cartografía derivada de la misma (abajo). 13
Figura II.1 Cartografía de la zona de la Universidad de Jaén a distintas escalas 21
Figura II.2 Fragmento de la hoja 947-I (Jaén) del MTN25 (Instituto Geográfico Nacional, 1997). 24
Figura II.3 Fragmento de la hoja 947 (Jaén) del MTN50 (Instituto Geográfico Nacional, 1999) 25
Figura II.4 Ejemplo de servidor de cartografía en internet. 25
Figura II.5 Equipos portátiles en los que se representa información cartográfica. 26
Figura II.6 Representación del modelo de generalización de Ratajski. 34
Figura II.7 Esquema del Modelo Conceptual Comprensivo de McMaster y Shea (1988)..... 36
Figura II.8 Ejemplos de operadores de generalización. 39
Figura II.9 Ejemplo de autogeneralización de un micro-agente (edificación)..... 43
Figura II.10 Ejemplo de generalización con el software Clarity (Laser-Scan). ... 44
Figura II.11 Clasificación de medidas en generalización en el proyecto AGENT (1999)..... 49
Figura II.12 Matriz distancia-dirección de McMaster (1995). 57
Figura II.13 Aplicación del método del "walking divider" a la línea de costa gallega. 58
Figura II.14 Clasificación de una muestra de líneas según su entropía (Plazanet, 1996, p.89). 63
Figura II.15 Medidas sobre una curva aislada (Plazanet, 1995, 1996, 1997). ... 65
Figura II.16 Ángulos de inflexión en cada vértice y curvas detectadas (B1, B2 y B3) (Wang y Müller, 1998). 70
Figura II.17 Ejemplo del funcionamiento del algoritmo de Douglas-Peucker..... 80
Figura II.18 Ejemplo del funcionamiento del algoritmo de Visvalingam. 82
Figura II.19 Ejemplos de filtrado con Visvalingam (izquierda) y Douglas-Peucker (derecha), ambos con el mismo número de puntos (Reinoso et.al, 2001). 83

Figura II.20 Línea original con cambio de dirección de 90º y líneas filtradas con Thapa en ambos sentidos con th = 0,75. 86
Figura II.21 Ejemplo de filtrado con el algoritmo de Thapa. 86
Figura II.22 ínea original con cambio de dirección de 90º y líneas filtradas con TBR en ambos sentidos con th = 0,75. 87
Figura II.23 Ejemplo de filtrado de la costa de la Península Ibérica con el algoritmo TBR. 88
Figura II.24 Ejemplo de suavizado gausiano con sigma 1,5 (12 vecinos más central) para la línea de costa de la península ibérica..... 92
Figura II.25 Mapa de África suavizado mediante filtro gausiano con $\sigma = 4$, mediante el método estándar (a) y aplicando la corrección (b) (Lowe, 1988). 93
Figura II.26 Función $y = ax^3$ en el sistema local. 97
Figura II.27 La línea generalizada (línea continua) extrae la tendencia general de la línea original (línea punteada). 99
Figura II.28 Ejemplos de picos que surgen en la línea generalizada (línea continua)..... 99
Figura II.29 Generalización (línea continua) de parte una pista de montaña..... 99
Figura II.30 Filtrado (línea continua) mediante truncado de la serie Fourier (Plazanet et.al, 1995)..... 102
Figura II.31 Obtención de los valores originales a partir de la base..... 103
Figura II.32 Componentes de la base de Haar en W^1. 104
Figura II.33 Ejemplo de descomposición de coeficientes wavelet. 105
Figura II.34 Ejemplo de reconstrucción a partir de coeficientes wavelet..... 106
Figura II.35 Pseudocódigo del algoritmo de descomposición wavelet (Stollnitz et.al, 1996)..... 106
Figura II.36 Pseudocódigo del algoritmo de reconstrucción wavelet (Stollnitz et.al, 1996)..... 107
Figura II.37 Funciones original y generalizada (García y Ariza, 2000b)..... 108
Figura II.38 Radio de curvatura de un punto n..... 109
Figura II.39 Espectro de frecuencia (longitud, curvatura) de una autovía (García y Ariza, 2000b). 109
Figura II.40 Espectro de frecuencia de la autovía tras la generalización wavelet (García y Ariza, 2000b). 110
Figura II.41 Generalización de una pista de montaña mediante filtrado wavelet (García y Ariza, 2000b). 112

Figura II.42 Generalización de una pista de montaña mediante filtrado wavelet (García y Ariza, 2000b). 112
Figura II.43 Promedio y ajuste exponencial de la evolución del porcentaje de pérdida de información en función del número de vértices eliminados (García y Ariza, 2000b). 113
Figura II.44 Diagrama del algoritmo del acordeón (Plazanet, 1996). 114
Figura II.45 Diagrama del algoritmo del globo (Plazanet, 1996). 115
Figura II.46 Diagrama del algoritmo de esquematización (Plazanet, 1996). ... 115
Figura II.47 Ejemplo de detección de coalescencia en cuna curva (Lecordix et.al, 1997). 116
Figura II.48 Ejemplo de línea no homogénea (Plazanet, 1996, p. 69)..... 122
Figura II.49 Medidas de Buttenfield (1991). 124
Figura II.50 Evolución de un filtrado mediante el algoritmo de Visvalingam (Visvalingam y Herbert, 1999). 125
Figura II.51 Filtrado con Visvalingam de la línea de costa de Andalucía (Reinoso et.al, 2001) 126
Figura II.52 Filtrado de la Península Ibérica mediante TBR (García et.al, 2001) 126
Figura II.53 Ejemplo de segmentación manual (Plazanet et.al, 1995). 127
Figura II.54 Árbol jerárquico de segmentación de líneas (Plazanet, 1996). 128
Figura II.55 Evolución de la costa de África con un suavizado gausiano (Mokhtarian y Mackworth, 1992). 129
Figura II.56 Ejemplo de segmentación mediante puntos de inflexión..... 130
Figura II.57 Ejemplo de segmentación realizada por Plazanet (1996)..... 131
Figura II.58 Clasificación de las secciones (Plazanet et.al, 1995; Plazanet, 1995, 1997)..... 131
Figura II.59 Ejemplo de resultado de la segmentación de una línea mediante cruces con la línea de tendencia (Burghardt, 2002).. 133
Figura II.60 Clasificación de secciones de carreteras mediante la dimensión fractal (Plazanet, 1996)..... 134
Figura II.61 Clasificación efectuada por Skopeliti y Tsoulos (1999) sobre 18 líneas de costa escogidas de una base de datos 1:500 000. 137
Figura II.62 Detección de secciones mediante la función f. 138
Figura II.63 Descompensación de la generalización tras aplicar el filtrado wavelet: polilíneas y función de curvatura (García y Ariza, 2000b; García, 1998). 138

Figura II.64 Situación de las redes neuronales en el campo de la inteligencia artificial (Hilera y Martínez, 1995). 140
Figura II.65 Esquema de la comunicación entre neuronas biológicas. 143
Figura II.66 Funciones de salida (tipos de neuronas). 145
Figura II.67 Entrada y salida de una neurona Uj, con función de activación identidad y con umbral de activación θj. 146
Figura II.68 Estructura de una red multicapa de dos capas ocultas, con todas las conexiones hacia delante. 148

Figura III.1 Pista de montaña en la hoja 947-III del MTN25 (Instituto Geográfico Nacional, 1996b). 157
Figura III.2 Ejemplo de segmentación manual de la línea de la Figura III.1. en cinco secciones. 158
Figura III.3 Esquema general del método de trabajo seguido. 161
Figura III.4 Situación de la hoja 947 en la serie MTN50. 164
Figura III.5 Representación de un modelo digital de elevaciones de la hoja 947. 164
Figura III.6 Leyenda sobre carreteras en las hojas 947 del MTN25. 167
Figura III.7 Representación de la muestra de líneas seleccionada en las hojas 947 del MTN25 (no está a escala). 170
Figura III.8 Distribución de áreas efectivas en la línea A-316. 178
Figura III.9 Distribución de áreas efectivas en la línea A-316 (escala logarítmica). 179
Figura III.10 Suma del Log10 de las áreas efectivas en la línea A-316 con L = 1500 m. 180
Figura III.11 Arriba: ejemplo de detección de puntos críticos con Douglas-Peucker. Abajo: segmentación de la línea A-316 a partir de los puntos críticos. 182
Figura III.12 Ejemplo de interferencia de la longitud L en la detección de puntos críticos con Douglas-Peucker. 183
Figura III.13 Filtrado de la línea N-323b mediante TBR con parámetro 0,94... 184
Figura III.14 Segmentación de N-323b mediante TBR con parámetro 0,94. ... 185
Figura III.15 Gráficas de (longitud,curvatura) original y filtrada de la línea Jabalcuz. K = 45. 186
Figura III.16 Segmentación automática mediante wavelet de la línea Jabalcuz. K = 45. L = 500. 187

Figura III.17 Detalle de la segmentación de Jabalcuz con K = 10%, L = 250. 188
Figura III.18 Variables a medir sobre una curva aislada, definida entre dos puntos de inflexión (P_i y P_{i+1})..... 197
Figura III.19 Créditos del programa JavaNNS. 209
Figura III.20 Resumen del proceso de creación de una red neuronal artificial para la clasificación automática de secciones. 211
Figura III.21 Extracción de fragmentos de la línea para su clasificación por la red neuronal. 212
Figura III.22 Ejemplos de líneas no homogéneas, con variación en su sinuosidad y/o direccionalidad. 217
Figura III.23 Clases de sección propuestas en la prueba. 223
Figura III.24 Tabla de respuestas de la prueba. 224
Figura III.25 Ejemplo de Hoja 2: línea P-CaminoAzadillas..... 225
Figura III.26 Ejemplo de Hoja 3: línea P-CaminoAzadillas..... 226
Figura III.27 Ejemplo de Hoja 4: línea P-CaminoAzadillas..... 227

Figura IV.1 Gráfica con la distancia media entre puntos en cada línea. 232
Figura IV.2 Evolución del número de secciones n detectadas sobre F(d, LogA) al modificar DP entre 50 y 450..... 237
Figura IV.3 Gráficas (longitud, curvatura) de la línea A-44. Original en rojo y filtradas wavelet en azul. 240
Figura IV.4 Segmentación mediante wavelet de la línea A-44, con K = 30% y L = 500 m (a) ó 1000 m (b)..... 241
Figura IV.5 Segmentación mediante wavelet de la línea A-44, con K = 30% (a), 35% (b), 40% (c), y L = 2000 m. 241
Figura IV.6 Muestra de líneas original (no está a escala). 247
Figura IV.7 Clasificación manual de las secciones. Ubicación relativa original (no está a escala). 247
Figura IV.8 Clasificación manual de las secciones. Secciones agrupadas (no está a escala)..... 248
Figura IV.9 Panel de control de JavaNNS. Pestaña de aprendizaje. 258
Figura IV.10 Gráfica de error generada por JavaNNS durante el aprendizaje de una red neuronal. 259

Figura IV.11 Ejemplos de gráficas de error del aprendizaje realizado sobre las diferentes arquitecturas neuronales planteadas mediante 5000 iteraciones (se han empleado el patrón de entrenamiento 1 y el patrón de prueba 1)..... 261
Figura IV.12 Gráficas de error del re-entrenamiento de la arquitectura de 3 neuronas ocultas. 286

Índice de tablas

Tabla II.1 Objetivos filosóficos del Modelo Conceptual Comprensivo. 36
Tabla II.2 Evaluación cartométrica del Modelo Conceptual Comprensivo. 37
Tabla II.3 Transformaciones espaciales y de atributos del Modelo Conceptual Comprensivo. 37
Tabla II.4 Operadores de generalización identificados por diferentes autores.... 40
Tabla II.5 Constreñimientos y objetivos de un edificio y un distrito a la escala 1:50 000 (Lamy et.al, 1999). 43
Tabla II.6 Clasificación de medidas internas (AGENT, 1999). 50
Tabla II.7 Clasificación de medidas entre objetos (AGENT, 1999). 51
Tabla II.8 Clasificación de medidas sobre estructuras (AGENT, 1999). 51
Tabla II.9 Proceso efectuado por el algoritmo de Thapa..... 84
Tabla II.10 Proceso efectuado por el algoritmo de Thapa Bidireccional Recursivo. 86
Tabla II.11 Tipos de continuidad en una curva paramétrica..... 95
Tabla II.12 Las treinta medidas evaluadoras del trabajo de McMaster (1986). 119
Tabla II.13 Medidas empleadas en un ACP por Skopeliti y Tsoulos (1999)..... 136
Tabla II.14 Características de la red Backpropagation 152

Tabla III.1 Resumen de criterios de selección de la muestra. 166
Tabla III.2 Tamaños de muestra empleados en investigación sobre generalización de elementos lineales (orden cronológico). 168
Tabla III.3 Muestra de los 24 elementos lineales empleados en el presente trabajo..... 169
Tabla III.4 Proyectos de construcción o reforma del trazado de las vías de la muestra. 172
Tabla III.5 Resumen de características del trazado de las vías de la muestra.. 174
Tabla III.6 Clasificación de secciones en trabajos de otros autores..... 193
Tabla III.7 Medidas consideradas sobre cada curva aislada. 198
Tabla III.8 Medidas caracterizadoras a someter a un ACP. 198
Tabla III.9 Redes de carreteras a las que pertenecen las secciones disponibles 203

Tabla III.10 Categorías de vías de comunicación para alimentar la red neuronal. 204
Tabla III.11 Panel de expertos previsto para la evaluación de los resultados .. 221

Tabla IV.1 Distancia (densidad) media entre puntos de las líneas de la muestra (ordenada de mayor a menor) 232
Tabla IV.2 Estimación del parámetro del filtrado de cada línea..... 234
Tabla IV.3 Tanteo de valores de L para las líneas de la muestra 235
Tabla IV.4 Número de secciones en cada elemento lineal tras el filtrado wavelet... 242
Tabla IV.5 Clases establecidas a la vista de las líneas de la muestra. 246
Tabla IV.6 Parámetros para la segmentación semiautomática. 246
Tabla IV.7 Varianza explicada por las 6 primeras componentes. 249
Tabla IV.8 Matriz factorial, para 6 componentes. 249
Tabla IV.9 Matriz factorial rotada (método varimax), para 6 componentes. 250
Tabla IV.10 Varianza explicada por las 6 primeras componentes (nuevo ACP). 252
Tabla IV.11 Matriz factorial, para 5 componentes (nuevo ACP) 252
Tabla IV.12 Matriz factorial rotada (método varimax), para 5 componentes (nuevo ACP)..... 253
Tabla IV.13 Matriz de correlación de las 16 variables seleccionadas tras el ACP 254
Tabla IV.14 Medidas caracterizadoras seleccionadas..... 255
Tabla IV.15 Número de secciones por estrato (clase) en cada conjunto..... 256
Tabla IV.16 Secciones por estrato (clase) y conjunto (asignación aleatoria).... 256
Tabla IV.17 Conjuntos presentes en cada patrón de entrenamiento y de prueba 257
Tabla IV.18 Clasificación efectuada mediante la arquitectura de 2 neuronas ... 264
Tabla IV.19 Resumen de tipos de clasificación en la arquitectura de 2 neuronas. 264
Tabla IV.20 Resumen de tipos de interferencia en la arquitectura de 2 neuronas. 264
Tabla IV.21 Matriz de confusión de la arquitectura de 2 neuronas. 264
Tabla IV.22 Índices por clase de la matriz de confusión de la arquitectura de 2 neuronas. 264
Tabla IV.23 Clasificación efectuada mediante la arquitectura de 3 neuronas ... 265

Tabla IV.24 Resumen de tipos de clasificación en la arquitectura de 3 neuronas. 267
Tabla IV.25 Resumen de tipos de interferencia en la arquitectura de 3 neuronas. 267
Tabla IV.26 Matriz de confusión de la arquitectura de 3 neuronas. 267
Tabla IV.27 Índices por clase de la matriz de confusión de la arquitectura de 3 neuronas. 267
Tabla IV.28 Clasificación efectuada mediante la arquitectura de 4 neuronas ... 268
Tabla IV.29 Resumen de tipos de clasificación en la arquitectura de 4 neuronas. 269
Tabla IV.30 Resumen de tipos de interferencia en la arquitectura de 4 neuronas. 269
Tabla IV.31 Matriz de confusión de la arquitectura de 4 neuronas. 269
Tabla IV.32 Índices por clase de la matriz de confusión de la arquitectura de 4 neuronas. 269
Tabla IV.33 Clasificación efectuada mediante la arquitectura de 5 neuronas ... 270
Tabla IV.34 Resumen de tipos de clasificación en la arquitectura de 5 neuronas. 271
Tabla IV.35 Resumen de tipos de interferencia en la arquitectura de 5 neuronas. 271
Tabla IV.36 Matriz de confusión de la arquitectura de 5 neuronas. 271
Tabla IV.37 Índices por clase de la matriz de confusión de la arquitectura de 5 neuronas. 271
Tabla IV.38 Comparación de medidas de la clasificación realizada por las distintas arquitecturas. 272
Tabla IV.39 Errores del productor y del usuario de las clasificaciones efectuadas. 275
Tabla IV.40 Clasificación realizada por las arquitecturas de 3 a 5 neuronas para cada sección de la muestra. 277
Tabla IV.41 Secciones sobre las que se ha detectado un posible cambio de clase. 278
Tabla IV.42 Nueva estratificación del número de secciones de cada clase en cada conjunto. 280
Tabla IV.43 Nueva distribución de secciones para cada conjunto. 280
Tabla IV.44 Clasificación efectuada tras el nuevo entrenamiento de la arquitectura de 3 neuronas. 282

Tabla IV.45 Resumen de tipos de clasificación tras el nuevo entrenamiento de la arquitectura de 3 neuronas. 283
Tabla IV.46 Resumen de tipos de interferencia tras el nuevo entrenamiento de la arquitectura de 3 neuronas. 283
Tabla IV.47 Matriz de confusión tras el nuevo entrenamiento de la arquitectura de 3 neuronas..... 283
Tabla IV.48 Índices por clase de la matriz de confusión tras al nuevo entrenamiento de la arquitectura de 3 neuronas..... 283
Tabla IV.49 Comparación de medidas de la clasificación realizada por las arquitecturas de 3 neuronas previa y nueva..... 284
Tabla IV.50 Secciones de la clase 1 que han sido mal clasificadas. 285
Tabla IV.51 Umbrales de las neuronas de la red 287
Tabla IV.52 Peso de las conexiones entre la capa de entrada y la capa oculta. 287
Tabla IV.53 Peso de las conexiones entre la capa oculta y la capa de salida.... 287
Tabla IV.54 Parámetros para la segmentación semiautomática (caso a)..... 290
Tabla IV.55 Parámetros para la segmentación mediante la RNA (caso b)..... 291
Tabla IV.56 Parámetros para la segmentación mediante la suma acumulada de áreas efectivas (caso c) 291
Tabla IV.57 Parámetros para la segmentación mediante wavelets (caso d)..... 292
Tabla IV.58 Estadística de la puntuación de la segmentación de cada miembro del panel de expertos. 294
Tabla IV.59 Número de problemas indicados por cada miembro del panel de expertos..... 294
Tabla IV.60 Estadística de la puntuación de la clasificación por cada miembro del panel de expertos. 296
Tabla IV.61 Resumen de expertos que han sido significativamente críticos o satisfechos con los procesos evaluados. 296
Tabla IV.62 Puntuación media de cada caso de segmentación y clasificación .. 297
Tabla IV.63 Número de problemas de cada tipo indicados por el panel de expertos..... 298
Tabla IV.64 Evaluación de los expertos. Resultados por cada línea 300
Tabla IV.65 Categorías de vías de comunicación para alimentar la red neuronal. 302
Tabla IV.66 Evaluación de los expertos. Resultados por cada línea (categoría 1). 302

Tabla IV.67 Evaluación de los expertos. Resultados por cada línea (categoría 2). 302
Tabla IV.68 Evaluación de los expertos. Resultados por cada línea (categoría 3). 303
Tabla IV.69 Evaluación de los expertos. Resultados por cada línea (categoría 4). 303
Tabla IV.70 Evaluación de los expertos. Resultados por cada línea (categoría 5). 303
Tabla IV.71 Resumen de resultados por categorías. 305
Tabla IV.72 Análisis cluster de la segmentación y clasificación según la mejor puntuación y la media. 306
Tabla IV.73 Detección de líneas fáciles y difíciles de segmentar y clasificar según el análisis cluster de valores medios. 306