

Taxonomía de funciones comunicativas negativas para su identificación automática en el contexto de las ciudades inteligentes

Nicolás José Fernández-Martínez
Departamento de Filología Inglesa, Universidad de Jaén
njfernan@ujaen.es

1. Introducción

Los usuarios vierten con frecuencia en las redes sociales sus pensamientos, opiniones y emociones sobre diversos asuntos de interés tanto de carácter público o privado. Comprender en su totalidad y complejidad el lenguaje natural humano es una de las principales áreas de interés para la Inteligencia Artificial (IA) (McStay, 2020). especialmente en tareas de Procesamiento de Lenguaje Natural (PLN) como la detección de emociones (Cambria, 2016; Jurafsky & Martin, 2021b; Mohammad, 2021), en la que se identifican las emociones contenidas en los textos o expresadas por su autores, o la clasificación de actos de habla (Jurafsky & Martin, 2021a), donde se infieren los actos de habla a partir de los mensajes de los usuarios.

Sin embargo, hasta ahora en el PLN se ha ignorado la identificación automática de la función comunicativa de un determinado microtexto de las redes sociales. La única referencia que encontramos con respecto al concepto de función comunicativas en el PLN es de Caselli et al. (2021), que citan la identificación de funciones comunicativas pero en otro sentido, esto es, como una tarea de identificación automática de tipología textual, es decir, catalogar un texto como narrativo, argumentativo, expositivo, instructivo, otros o ninguno. Por función comunicativa entendemos, de acuerdo con el enfoque nocional-funcional en el campo de aprendizaje y enseñanza de lengua extranjera (Wilkins, 1976; Williams, 2018), por ejemplo, las siguientes: desagrado, desacuerdo, desaprobación, preocupación, enfado, amenaza, indiferencia, queja, etc. De especial interés puede ser la identificación de dichas funciones comunicativas de carácter negativo en el contexto de las denominadas ciudades inteligentes (*smart cities*), donde dicha información puede ser de suma importancia para identificar la parte ilocutiva de un mensaje, esto es, la intención del ciudadano con respecto a problemas de carácter social, cultural, económico o político. La identificación de esta información puede servir para hacer un estudio pormenorizado de la dimensión sociológica de las preocupaciones y problemas manifestados por los ciudadanos con el objetivo de implementar políticas adecuadas destinadas a paliar tales problemas.

En este sentido, nuestro objetivo con este capítulo es, por un lado, definir el concepto de función comunicativa, haciendo hincapié en su origen y evolución como parte integral del denominado enfoque nocional-funcional y, por otro, presentar una taxonomía de funciones comunicativas negativas que sirva para desarrollar modelos de PLN cuyo fin sea la identificación automática de las mismas en contextos de ciudades inteligentes. Para ello, relacionaremos la identificación automática de funciones comunicativas con las tareas de detección automática de emociones y clasificación automática de actos de habla para vislumbrar las similitudes y diferencias con la tarea que vamos a introducir. La taxonomía presentada podrá ser reutilizada y aprovechada por

los profesionales de PLN en el contexto de las ciudades inteligentes, así como para otras tareas como la detección de lenguaje tóxico o la detección del lenguaje abusivo de tipo misógino, racista, etc. (Plaza-del-Arco, Collado-Montañez, et al., 2022).

Esta investigación se enmarca dentro del proyecto de ALLEGRO (Adaptive muLti-domain social-media sEnsinG fRamework), en el que se está desarrollando un sistema multimodal que identifica y clasifica problemáticas sociales que afectan a los ciudadanos en el contexto de las ciudades inteligentes y, en particular, el módulo de DIAPASON (unified hybrid Approach to microtext Analysis in Social-media crowdsensing), que se encarga de procesar y analizar mediante técnicas de minería textual y PLN el contenido textual de los mensajes que vierten los ciudadanos en las redes sociales para generar esquemas de conocimiento sobre las problemáticas mencionadas por dichos usuarios.¹

2. Antecedentes en el PLN: detección automática de emociones y clasificación automática de actos de habla

En esta sección, ofrecemos un breve recorrido a lo largo de dos tareas de PLN cuya naturaleza es similar a la tarea de la identificación automática de funciones que introducimos más adelante. Lo que tienen en común todas ellas es que se tratan de tareas de clasificación textual, en las que, dado un texto cualquiera, un modelo ha de poder identificar la clase correcta de entre un conjunto de clases, ya sea una emoción, en el caso de detección de emociones, un acto de habla en el caso de la clasificación de actos de habla, o una función comunicativa en el caso de la identificación de funciones comunicativas.

2.1. Detección automática de emociones

La primera de estas tareas, conocida como detección o clasificación de emociones, tiene como objetivo la extracción de emociones expresadas por los usuarios en sus mensajes, ya sea de manera explícita mediante palabras o expresiones cargadas de emoción (e.g. *estar triste/enfadado, exasperarse*, etc.) o de manera implícita a través del conocimiento enciclopédico evocado por ciertos términos (e.g. *muerte*, asociada con tristeza; *fiesta*, asociada con alegría) (Jurafsky & Martin, 2021b). Esta tarea fue originariamente definida por Picard (1997) dentro del campo que se conoce como análisis del afecto (*affective computing*), que se refiere a la tarea general de ayudar a las máquinas a reconocer y comprender las emociones que se encuentran en textos o contenidos audiovisuales, y que engloba otras tareas computacionales como el análisis del sentimiento (i.e. detección de la polaridad de un mensaje, esto es, si es positivo, negativo o neutro), la detección de rasgos de la personalidad, la detección del estado de ánimo o la construcción de lexicones afectivos. La emoción a identificar en un mensaje puede corresponderse a la del autor del mensaje, la del receptor o la de alguno de los caracteres mencionados en el mensaje (Maia & Santos, 2018), aunque normalmente en esta tarea se tiene en cuenta la emoción del autor, que es la fuente y perspectiva más fiable y

¹ Para más información sobre la modelización de las quejas de los ciudadanos en DIAPASON, léase el capítulo escrito por Carlos Perrián-Pascual en este monográfico.

además la más relevante para la anotación de un mensaje (Buechel & Hahn, 2017). Para abordar las principales contribuciones de esta tarea, trataremos de responder brevemente a las siguientes cuestiones: ¿qué son las emociones y de dónde parte su estudio? ¿qué modelos de emociones enraizados en la psicología informan un sistema de PLN de detección de emociones? ¿qué corpus disponibles hay y cuáles son los principales géneros o dominios textuales en los que se han basado? ¿cuáles son los enfoques principales en la literatura? ¿qué limitaciones o desafíos caracterizan a esta tarea? ¿cuáles son las aplicaciones prácticas que se derivan del uso de esta tarea?

En cuanto a la base teórica de los modelos computacionales, las emociones han sido abordadas desde diversos campos, como la filosofía o la psicología. Estas se definen como la manera que tienen los humanos para percibir el mundo e interactuar en él en nuestro día a día, como respuestas ante situaciones particulares dada la interpretación del individuo, que a su vez suele estar social y culturalmente condicionada (Scherer, 2005). Las emociones se expresan mediante el lenguaje humano, de manera explícita o implícita, mediante la interacción e integración de distintos niveles lingüísticos como la sintaxis o la semántica (Baider & Cislaru, 2014). Entre los marcadores lingüísticos de emoción, encontramos unidades léxicas como verbos (e.g. *alegrarse*) o adjetivos de emoción (e.g. *alegre*), adverbios intensificadores (e.g. *muy*, *mucho*...), afijos (e.g. *-ito/-ico*), signos de puntuación (e.g. exclamaciones), términos que expresan afinidad (e.g. *querido*, *hermano*, *amor mío*), fonología suprasegmental (e.g. intensidad, entonación, prosodia), etc. (Mohammad & Alm, 2015).

El estudio de las emociones data de la Antigua Grecia o el Imperio Romano de la mano, entre otros, de los estoicos, quienes definían las emociones (o pasiones, como así las denominaban, del griego *pathê*), como juicios o evaluaciones que se derivan de la impresión recibida ante un acontecimiento particular, las cuales estaban divididas en miedo (*fobos*), lujuria (*epithumia*), dolor o angustia (*lupê*) y placer o deleite (*hêdonê*) (Sorabji, 2000). Fue en el siglo XX de la mano de la psicología cuando surgieron multitud de categorizaciones de emociones, así como diversos enfoques que explican el origen y expresión de estas. Entre los modelos psicológicos más usados en el PLN y en específico para esta tarea, nos encontramos con aquellos denominados categóricos como el de Ekman (1992), que se basa en un conjunto de seis emociones básicas de carácter universal (enfado, asco, miedo, alegría, tristeza y sorpresa), o el de Plutchik (1980), que se sirve de las anteriores y añade, además, confianza y anticipación, ambas de carácter darwinista. Estas categorizaciones han sido especialmente útiles en el PLN, ya que ofrecen un conjunto limitado, finito y preciso de clases predefinidas para la tarea en cuestión, si bien como desventaja principal se podría citar que estas no captan matices afectivos más finos (Mohammad, 2022). Por esta razón, ha habido modelos de detección de emociones que han extendido el conjunto hasta obtener más de veinte clases de emociones (Demszky et al., 2021; Liew et al., 2016), con el inconveniente de introducir más ruido en el rendimiento del modelo.

Entre los corpus de emociones, mayoritariamente en inglés, cabe mencionar los que contienen entrevistas (Scherer & Wallbott, 1994) títulos de noticias (Strapparava & Mihalcea, 2007), blogs (Aman & Szpakowicz, 2007), cuentos (Alm et al., 2005) y, más recientemente, tuits (S. M. Mohammad, 2012;

S. M. Mohammad et al., 2015; Liew et al., 2016; S. M. Mohammad & Kiritchenko, 2018; S. Mohammad et al., 2018; Plaza-del-Arco et al., 2020; entre otros) y comentarios de Reddit (Demszky et al., 2021). El corpus de EmoEvent (Plaza-del-Arco et al., 2020) es el único corpus de tuis disponible en español para la tarea de detección de emociones. Cada género textual impone su idiosincrasia lingüística y esto, a su vez, influencia cómo aparecen las emociones codificadas en las realizaciones lingüísticas (Bostan & Klinger, 2018). Recientes intentos han tratado de unificar todos estos corpus en uno solo para facilitar y estandarizar la tarea de detección de emociones (Bostan & Klinger, 2018). En cuanto a la forma de etiquetación, muchos de estos corpus confían en la supervisión lejana, esto es, el uso de medios automáticos como la presencia de palabras, hashtags o emoticonos que indican emoción para la etiquetación automática de microtextos (Purver & Battersby, 2012; Wang et al., 2012); otros confían en conocimiento experto (Aman & Szpakowicz, 2007; Strapparava & Mihalcea, 2007) o semiexperto, normalmente mediante *crowdsourcing* (Demszky et al., 2021; Liew et al., 2016; Mohammad et al., 2015; Plaza-del-Arco et al., 2020; Schuff et al., 2017); por último, algunos confían en conocimiento autoinformado de los autores de los mensajes (Scherer & Wallbott, 1994).

En cuanto a la naturaleza de los modelos, hacemos una distinción entre aquellos basados en enfoques simbólicos, esto es, basados en reglas y recursos lingüísticos de aquellos basados en enfoques probabilísticos, desde el aprendizaje automático tradicional (*machine learning*) hasta el aprendizaje profundo (*deep learning*). Destacamos, brevemente, las principales contribuciones de cada tipo de modelo. Los primeros suelen utilizar diccionarios, listas, lexicones u ontologías de palabras cargadas de emoción, como WordNet-Affect (Strapparava & Valitutti, 2004), SentiWordNet (Esuli & Sebastiani, 2008), LIWC (Pennebaker et al., 2001), NRC WordEmotion Association Lexicon (Mohammad, 2012), SenticNet (Cambria et al., 2020), entre otros, con la intención de hacer un conteo de palabras cargadas de emoción dentro de un mensaje, acompañado de características léxico-sintácticas que tienen en cuenta n -gramas o combinaciones de palabras, signos de puntuación, emoticonos, etc. Por ejemplo, Strapparava & Mihalcea (2007) construyeron un modelo para identificar emociones siguiendo el esquema de Ekman (1992) en su corpus de títulos de noticias llamado AffectiveText que utilizaba el lexicon de WordNet-Affect para identificar emociones, cuya puntuación F1 oscilaba entre el 16% y el 42% según la emoción detectada. Dini & Bittar (2016) desarrollaron un modelo basado en las emociones de Ekman (1992) entrenado con un corpus de tuits etiquetados mediante supervisión lejana que hace uso de WordNet-Affect y reglas lexicosintácticas basadas en relaciones sintácticas de dependencia, obteniendo una puntuación F1 de 41%. En cuanto a los enfoques probabilísticos basados en aprendizaje automático tradicional, estos utilizan diversos algoritmos y características lingüísticas para enriquecer al modelo, como n -gramas, vectores semánticos, emoticonos, signos de puntuación, etc. Destacamos, en este sentido, Aman & Szpakowicz (2007), quienes implementaron un modelo para identificar las emociones en un corpus de entradas de blogs utilizando el esquema de emociones de Ekman (1992) más la categoría sin emoción, utilizando un algoritmo clasificador bayesiano ingenuo y otro de máquinas de vectores de soporte enriquecidos con características lingüísticas, y obteniendo

en ambos casos una puntuación de F1 superior al 70%. Mohammad (2012) utilizó máquinas de vectores de soporte y un clasificador bayesiano ingenuo con características lingüísticas, con su propio corpus de 21.051 tuits, el Twitter Emotion Corpus (TEC), etiquetado con el esquema de Ekman (1992) y mediante supervisión lejana, alcanzando una puntuación F1 de 49,9%. Liew et al. (2016) utilizaron máquinas de vectores de soporte enriquecidas con características lingüísticas para entrenar y evaluar su modelo con el corpus de 15.553 tuits que crearon mediante anotación semiexperta, llamado EmoTweet-28, etiquetado con hasta 28 categorías de emoción más la clase sin emoción, para hacer una clasificación multietiqueta (esto es, más de una etiqueta de emoción por tuit), obteniendo una puntuación F1 de 45%. En los enfoques probabilísticos basados en aprendizaje profundo, se utilizan redes neuronales como redes de memoria a largo y corto plazo (LSTM) y, más recientemente, transformadores como BERT (Devlin et al., 2019). Por ejemplo, para la tarea de SemEval 2018 *Affect in Tweets* (Mohammad et al., 2018), los competidores utilizaron mayormente redes neuronales, como LSTM bidireccionales, para el corpus de tuits etiquetado mediante anotación semiexperta con 11 emociones basadas en Plutchik (1980). El mejor modelo, el de Baziotis et al. (2018) consistía en LSTM bidireccionales y técnicas de atención profunda junto con vectores semánticos de Word2Vec (Mikolov et al., 2013), alcanzando una precisión de 46,9%. Demszky et al. (2021) afinaron BERT con el corpus que crearon de 58.000 comentarios de Reddit llamado GoEmotions, que fue etiquetado con 27 emociones, obteniendo una puntuación F1 de 45%. En la tarea de EmoEvalEs (Plaza-del-Arco et al., 2021), se presentaron varios modelos para identificar emociones en tuits en español usando el esquema de Ekman (1992) utilizando para ello el corpus de tuits de EmoEvent (Plaza-del-Arco et al., 2020), cuyo mejor modelo fue el de Vera et al. (2021), quienes utilizaron el transformador multilingüe adaptado a tuits XLM-RoBERTa (Barbieri et al., 2021), obteniendo una puntuación F1 de 71,7%. Más recientemente, se ha explorado el uso de los transformadores como *zero-shot classifiers*, es decir, como clasificadores no supervisados que reaprovechan su conocimiento probabilístico-lingüístico adquirido en procesos de pre-entrenamiento para ser aplicados a diversas tareas, utilizando *prompts* o instrucciones que enseñan pistas al modelo para averiguar la categoría correspondiente. Por ejemplo, en este sentido citamos el trabajo de Basile et al. (2021) y Plaza-del-Arco, Martín-Valdivia, et al. (2022) quienes reutilizaron diversos transformadores pre-entrenados para tareas de inferencia para detectar emociones utilizando instrucciones como *This person feels {emotion_label}* sin realizar una fase de entrenamiento, y evaluando dichos modelos con varios corpus de emociones, obteniendo puntuaciones F1 variables según el corpus, modelo de transformador y *prompt* utilizado de entre un 15 y 61%.

De entre los trabajos en la literatura de detección de emociones que citan la intención del hablante en relación a la expresión de emociones, encontramos Neviarouskaya et al. (2007), quienes destacan la importancia de detectar funciones comunicativas junto con emociones, si bien se centraron en pocos actos de habla como saludo, agradecimiento, preguntar, felicitar y despedida. Por otra parte, Mohammad et al. (2015), en su corpus de tuits en relación con las elecciones presidenciales de los EEUU en 2012, etiquetaron estos en base a su emoción, intensidad, estilo, tema e intención. Sin una base teórica de apoyo para la categorización de intenciones, los autores

establecieron categorías como estar de acuerdo, estar en desacuerdo, criticar, alabar, admirar, apreciar, apoyar, motivar o incitar a la acción, entretener, proporcionar información, ridiculizar, etc., funciones comunicativas relacionadas con el discurso político.

A pesar de lo mucho que se ha avanzado en este campo, sigue habiendo bastantes desafíos a los que enfrentarse. Por ejemplo, la carga emocional de una proposición va más allá de la suma de la carga emocional de cada una de sus palabras; existe una gran dificultad en detectar las expresiones implícitas de emoción que requieren conocimiento enciclopédico (e.g. trabajar hasta la extenuación podría despertar emociones negativas como repulsa o desagrado, o emociones positivas como admiración, dependiendo de la cultura); los marcadores paralingüísticos de emoción (i.e. información prosódica) están ausentes en una proposición escrita; la dificultad que supone identificar el uso del lenguaje figurado o metafórico (ironía, sarcasmo, humor, metáforas, metonimia), o la presencia del uso no estándar del lenguaje en el género microtextual de los tuits; la presencia de múltiples emociones y contrastes en un único mensaje; la fuente de la emoción (autor, receptor, o texto) y la intención comunicativa (e.g. informar de un suceso negativo no equivale a expresar una opinión con emoción asociada) (Mohammad & Alm, 2015). Todos estos desafíos afectan primeramente a la anotación de los corpus, que suele resultar en porcentajes de acuerdos de anotación bajos, y luego en resultados normalmente por debajo del 50% en cuanto a la puntuación F1 (Mohammad, 2021).

En cuanto a las aplicaciones prácticas de la detección de emociones, existe un amplio abanico de estas, como la salud y seguridad públicas, la respuesta ante emergencias y crisis, la publicidad, el entretenimiento, comercio, etc. (Cambria, 2016; Mohammad, 2021; Plaza-del-Arco, Collado-Montañez, et al., 2022; Valle-Cruz et al., 2021). Por ejemplo, en el ámbito sanitario la detección de emociones puede servir para vigilar la salud mental mediante la detección de emociones negativas y su evolución en pacientes clínicamente diagnosticados clínicamente o potencialmente propensos a desarrollar problemas de salud mental. En la respuesta ante emergencias y situaciones de crisis, la detección de emociones sirve para evaluar el impacto de los eventos de crisis en la percepción subjetiva de los ciudadanos. En la política, se utiliza para la toma de decisiones mediante la extracción de las emociones de los votantes en relación con acontecimientos políticos y cuestiones sociales determinadas para así aplicar políticas adecuadas y/o desarrollar campañas de marketing personalizadas. En la inteligencia empresarial y comercio electrónico, se utiliza para el diseño de campañas publicitarias personalizadas que se adapten a los intereses de los clientes en función de su respuesta emocional a los productos o servicios, extraída de sus opiniones y comentarios en la web.

2.2. Clasificación automática de actos de habla

La clasificación de actos de habla o diálogo (*dialog act classification*) extrae los actos de habla de los mensajes que vierten los usuarios, una tarea muy apreciada en el campo del desarrollo de agentes conversacionales para el servicio de atención al cliente (Jurafsky & Martin, 2021a). Por lo general, en la literatura no se presta atención a la expresión de emociones o juicios, y se

basa vagamente en los actos de habla de (Searle, 1976), poniendo el foco mayormente en la aplicación práctica. A continuación, se ofrecen algunos de los trabajos más relevantes en este campo en orden cronológico.

Jurafsky et al. (1997) fue uno de los primeros trabajos en ofrecer un corpus etiquetado con actos de habla, denominado Switchboard-DAMSL, basado en conversaciones telefónicas en la variedad americana del inglés que versa sobre setenta temas y que contiene hasta 205.000 proposiciones etiquetadas con 42 etiquetas, entre las que se incluyen declaración, aceptación, pregunta retórica, agradecimiento, arrepentimiento, etc. Stolcke et al. (2000) reutilizaron dicho corpus para entrenar y evaluar un modelo oculto de Markov enriquecido con características lingüísticas, llegando a obtener una precisión de entre un 65 y 70%. Zhang et al. (2011) fue uno de los trabajos pioneros de este campo en el que los autores emplearon un modelo basado en máquinas de vectores de soporte para clasificar los actos de habla de un corpus de 8.164 tuits anotados con las etiquetas declaración, pregunta, sugerencia, comentario y miscelánea, siguiendo la taxonomía de actos de habla de (Searle, 1976), y sirviéndose de características lingüísticas como la presencia de palabras y sintagmas clave (por ejemplo, verbos performativos), abreviaturas, acrónimos, palabras que expresan opinión, palabras vulgares, emoticonos, signos de puntuación, etc., obteniendo un muy buen resultado, esto es, una puntuación F1 de 70%. Novielli & Strapparava (2013) investigaron la relación entre la información afectiva de un mensaje y su acto de habla, utilizando un enfoque no supervisado basado en vectores y similitud semántica y otro supervisado basado en máquinas de vectores de soporte utilizando el corpus de Switchboard-DAMSL. En lugar de utilizar las 42 etiquetas originales, las convirtieron en 9, que incluyen: petición de información, declaración, opinión, mostrar acuerdo o aceptación, rechazo, apertura, cierre, actitud amable y respuestas genéricas. Los resultados del modelo no supervisado arrojaron una puntuación de F1 de 68%, mientras que el modelo supervisado obtuvo un F1 de 77%. De acuerdo con los autores, las proposiciones del corpus tenían una carga afectiva baja, la cual se midió utilizando SentiWordNet (Esuli & Sebastiani, 2008) o WordNet-Affect (Strapparava & Valitutti, 2004) así como LIWC (Pennebaker et al., 2001). Saha et al. (2020) afinaron el transformador de BERT (Devlin et al., 2019) para entrenarlo con un corpus de 7.735 tuits etiquetados con los siguientes actos de habla: declaraciones, expresiones, sugerencias, peticiones, preguntas, amenazas y otros. Además, aprovecharon ciertas características lingüísticas como símbolos de tuits (i.e. RT, # y @), abreviaturas, signos de puntuación, emoticones, palabras vulgares y de opinión, etc. Obtuvieron una precisión de 77,52% y una puntuación F1 de 77%. Como señalan los autores, existe un creciente interés en comprender las intenciones comunicativas de los usuarios de Twitter, además de incidir en las dificultades que entrañan los tuits dada su naturaleza informal y su brevedad.

En definitiva, como se puede observar, la literatura en este campo aborda los actos de habla pero utilizando grupos de etiquetas heterogéneos, basados parcialmente en los actos de habla definidos por (Searle, 1976), e ignorando las posibilidades de su uso para el campo de las ciudades inteligentes, entre otros. Además, se ignora el concepto de función comunicativa y lo que el campo del enfoque nocional-funcional ofrece en este sentido para obtener taxonomías de clases más finas y sobre todo en relación a la expresión de emociones y juicios de valor.

3. Actos de habla: un breve recorrido por la pragmática

Como hemos visto anteriormente, una parte importante en la descripción de un problema es la parte ilocutiva, esto es, la intención comunicativa del hablante, para comprender el propósito o fin de un mensaje. En la literatura lingüística teórica y aplicada, la intención comunicativa del hablante ha sido ampliamente estudiada en el campo de la pragmática con diferentes caracterizaciones, definiciones, etiquetas y taxonomías en lo referente a la naturaleza de tales intenciones (Austin, 1962; Searle, 1969; Levinson, 1983; Yule, 1996; Cruse, 2000; Huang, 2007). Uno de los términos más relevantes con los que la literatura lingüística mencionada anteriormente ha abordado la intención comunicativa de los hablantes es conocido como *speech act* o acto de habla, esto es, lo que hacemos con las palabras cuando hablamos, por ejemplo, prometer, pedir, ordenar, quejarse, expresar X emoción, etc. El término 'acto de habla' fue acuñado por primera vez por el propio Austin (1962).

En una proposición, encontramos tres partes bien diferenciadas: la parte o fuerza locutiva, la parte o fuerza ilocutiva y la parte o fuerza perlocutiva. Por ejemplo:

(1) *Me preocupa la inflación.*

En esta proposición, la fuerza locutiva es el contenido del mensaje en sí, esto es, las realizaciones lingüísticas que aparecen en la proposición. La fuerza ilocutiva, también llamada acto de habla, denota la intención comunicativa del hablante, que en este caso es expresar preocupación (i.e. acto de habla expresivo y función WORRY), mientras que la fuerza perlocutiva tiene que ver con el efecto que provoca en el oyente, esto es, o que simpatice con la preocupación del hablante e intente de alguna manera calmar su preocupación. El acto de habla es directo porque hay una correspondencia inequívoca entre la realización lingüística y su función.

La parte que nos interesa identificar de manera automática sería el acto de habla, prestando atención a la parte locutiva, esto es, las expresiones lingüísticas en el contenido de la proposición que ayudan a la identificación del acto de habla. En el contexto de las ciudades inteligentes donde los usuarios expresan sus actitudes con respecto a problemáticas que les atañen, la fuerza perlocutiva esencial será la de respuesta de las autoridades competentes, es decir, se espera que se resuelva la problemática expresada mediante la destinación de recursos y/o implementación de medidas socioeconómicas.

De entre todos los esfuerzos por presentar una taxonomía de actos de habla (véase, por ejemplo, Hancher, 1979, para un revisión de otras clasificaciones similares de la época), es la de Searle (1976) la que ha resistido el paso del tiempo en el campo de la pragmática. Searle (1976) realizó la siguiente clasificación general de los actos de habla en cinco grandes tipos de fuerzas ilocutivas: declaraciones, representativas, expresivas, directivas y comisivas. Con declaraciones, el autor se refiere a aquellos actos de habla que cambian el mundo mediante la proposición, como cuando el cura declara el casamiento (e.g. *Yo os declaro marido y mujer*). Los actos de habla representativos expresan afirmaciones que el hablante cree o no cree,

pudiéndose expresar en términos de verdadero o falso (e.g. *La Tierra es redonda*). Los actos de habla expresivos son aquellos que expresan el estado afectivo o psicológico del hablante, es decir, sus emociones o sentimientos, como placer, dolor, enfado, agrado, desagrado, alegría, pena, tristeza, sorpresa, queja, desconfianza, etc. (e.g. *¡Qué alegría me da verte!*). Los actos de habla directivos expresan lo que el hablante quiere que alguien haga mediante órdenes, peticiones, sugerencias, consejos, etc. (e.g. *No toques eso*). Los actos de habla comisivos comprometen al hablante que los usa a una acción futura, es decir, expresan la intención del hablante en, por ejemplo, las promesas, las amenazas, rechazo, compromisos, etc. (e.g. *Ni se te ocurra hacerlo*).

De todos estos actos de habla, destacamos, en relación con el contexto de la ciudad inteligente y las redes sociales, los actos de habla expresivos, en tanto que los ciudadanos en las redes sociales expresan con asiduidad sus emociones y juicios negativos con respecto a una problemática dada, así como los actos de habla comisivos cuando los ciudadanos se comprometen a (no) hacer algo si no se ofrece una solución a un problema dado.

4. Taxonomía de funciones comunicativas negativas para las ciudades inteligentes y su identificación automática

4.1. Definición de función comunicativa

Si bien la clasificación de Searle (1976) es útil como aproximación a las funciones comunicativas, resulta evidente que no es especialmente granular y que en el contexto de las ciudades inteligentes necesitamos una taxonomía semánticamente más fina capaz de diferenciar distintos subtipos dentro de actos de habla. Por esta razón, convendría ahora introducir el concepto de función comunicativa, concepto que hemos extraído de los estudios del campo del aprendizaje de lengua extranjera (inglés), dentro de lo que se conoce como enfoque nocional-funcional o comunicativo (Wilkins, 1976; Finnochiaro & Brumfit, 1983; Williams, 2018), y sobre la base del cual hemos elaborado la taxonomía de funciones comunicativas. Una función comunicativa se define como un acto comunicativo o el uso de la lengua mediante expresiones lingüísticas para un propósito o intención determinados, típicamente para expresar el sentimiento o actitud del hablante (Milanovic & Saville, 2012), es decir, para referirnos mayormente a actos de habla expresivos y comisivos.

Una de las listas más completas y definidas de funciones comunicativas con sus correspondientes expresiones lingüísticas se encuentra en Blundell et al. (1982), que es un manual práctico de funciones con fines pedagógicos para la enseñanza y aprendizaje del inglés. De acuerdo con los autores, las funciones comunicativas son los fines por los cuales la gente escribe o lee, y hacen una distinción entre tres tipos de funciones: informacionales, actitudinales y activas. Estas funciones aparecen ordenadas en distintos niveles, junto con las realizaciones lingüísticas que las conforman, ejemplos de uso, información sobre el contexto de uso y grado de formalidad, además de ejercicios prácticos. Esta lista se basa mayormente en categorizaciones previas de Wilkins (1976), el padre fundador del enfoque nocional-funcional,

las categorizaciones de Finnochiaro & Brumfit (1983) y el plan comunicativo de van Ek & Trim (1991).

4.2. Taxonomía de funciones comunicativas negativas: preparación y procesamiento

De la lista exhaustiva presentada por Blundell et al. (1982), obtuvimos las funciones comunicativas y sus realizaciones lingüísticas en inglés más representativas de la categoría actitudinal, esto es, las que denotan un sentimiento, emoción, pensamiento o argumento negativo, ya que son las más relevantes en el contexto de las ciudades inteligentes y las redes sociales, donde los usuarios vierten mensajes en los que expresan su estado psicológico negativo con respecto a problemáticas que perciben como dañinas para su calidad de vida. Para cada función comunicativa hemos escogido las construcciones lingüísticas más informales o neutrales en su grado de formalidad, algunas de las cuales adaptamos para adecuarse al género del microtexto de redes sociales. Hay una función que añadimos a la taxonomía *a posteriori* que no estaba formalizada en el manual de Blundell et al. (1982) pero que consideramos de suma importancia en el contexto de las ciudades inteligentes: DISTRUST o desconfianza. Para ello, de manera manual supervisamos y seleccionamos las construcciones lingüísticas correspondientes que aparecen en los diccionarios de Collins² y MacMillan³ en relación con la expresión de la desconfianza. Además, hemos añadido la etiqueta OTHER, que aglutina construcciones lingüísticas de diversas funciones comunicativas que aparecían en el manual distintas de las que hemos añadido. En este sentido, la construcción de nuestra taxonomía ha seguido criterios exclusivamente lingüísticos y sociológicos: lingüísticos en tanto que se basa en el conocimiento experto proporcionado por la literatura en el campo de las funciones, y sociológicos en tanto que estas funciones están estrechamente ligadas a la manifestación de los problemas de los ciudadanos en el contexto de las ciudades inteligentes.

En la Tabla 1 mostramos la lista de las funciones comunicativas que hemos obtenido en la taxonomía y que procesamos como una base de datos.

Tabla 1. Taxonomía de funciones comunicativas.

ID	Función comunicativa	Descripción	Nº	Ejemplos
0	OTHER	Other communicative functions.	79	My pleasure. Don't worry (about _). I hope it will happen. Did you know (about _)?
11	NOT_CORRECT	Saying something is not correct.	8	That's/It's not the case. You're/He's/She's/That's/We're/The y're (all) wrong. (That's/It's) nonsense/rubbish/bullshit/bs/crap.

² https://www.collinsdictionary.com/dictionary/english-thesaurus/distrust#distrust_1

³ https://www.macmillandictionary.com/dictionary/british/distrust_1 ,

<https://www.macmillanthesaurus.com/topics/ways-of-saying-that-you-do-not-believe-something>

<https://www.macmillanthesaurus.com/topics/to-not-trust-or-believe-someone-or-something>

25	PESSIMISTIC	Saying you are pessimistic.	18	(I'm) not (too) happy (about _). There's no way. _ can't be done.
26	WORRIED	Saying you are worried or afraid.	16	I fear _. (I'm) (very) worried/uneasy (about _). _ gives me the creeps/jitters.
30	ANGRY	Saying you are displeased or angry.	23	_ is most/very/extremely annoying/exasperating. What an idiot/fool. _ (really) makes me mad.
32	DISAPPOINTED	Saying you are disappointed.	8	That's/It's a real shame/pity/let-down. What a pity/disappointment. That's too bad.
34	BORED	Saying you are bored.	18	_ is a (total) bore/drag. _ leaves me cold. (I) don't think _ is (very) exciting/interesting.
38	DISLIKE	Expressing dislike.	22	(I) don't like _. How awful. _ is not one of my favourite.
43	NOT_APPROVE	Saying you do not approve.	19	(I) don't think that's/it's (very) good. (I'm) dead against _. Is _ (really) necessary?
45	NOT_IMPORTANT	Saying something is not important.	20	(I) don't think that's (so) important. Does _ matter? So what?
53	NOT_INTERESTED	Saying you are not interested.	17	(I'm) not (very) interested (in _). _ isn't for me. (I) couldn't care less (about _).
57	DISAGREEING	Disagreeing.	23	(I) don't agree (with _). That's not the way I see _. (I) can't go along (with _).
83	WARN	Warning someone.	10	Watch out (for _). Make sure you don't do _. I would be extremely careful of _ if I were you.
88	COMPLAIN	Complaining.	21	_ just isn't good enough. _ really is the limit! (I'm) not at all satisfied (with _).
89	THREATEN	Threatening.	13	If I were you, I wouldn't do _. Don't do that or I'll do _. Just you try!
92	UNWILLING	Saying you are unwilling to do something.	13	(I) don't (really) fancy doing _. I'm not (totally/entirely) convinced we should do _. I'd rather not (do _).
93	REFUSE	Refusing to do something,	19	(I'm) sorry, I can't/couldn't (do _) Out of the question. I (certainly) won't.

141	DISTRUST	Saying you don't have confidence in someone or something.	15	(I) don't have any reason to trust _. Are you kidding? You must be joking.
-----	----------	---	----	--

La taxonomía incluye un identificador numérico correspondiente a la función obtenida del manual, la etiqueta, una breve descripción en inglés, el número de construcciones lingüísticas que contienen y una lista con algunos ejemplos de estas construcciones lingüísticas típicas asociadas a cada función. Como se puede observar en las construcciones, hemos incluido una serie de convenciones metodológicas que señalan ciertas operaciones o modificaciones que se pueden realizar en las construcciones:

- (i) Paréntesis (): los paréntesis marcan opcionalidad de elementos (i.e. sintagmas preposicionales o adverbios intensificadores, generalmente) que podrían omitirse ya sea por falta de especificidad del mensaje (e.g. *interested (in something)* o *(very) interested*) o porque haya elementos con potencial de omisión en el contexto informal de un tuit (i.e. pronombres en función de sujeto).
- (ii) Barra baja (_): la barra baja indica la temática o entidad cualquiera sobre la cual se expresa una opinión, emoción, sentimiento o actitud.
- (iii) Barras (/): las barras indican todas las posibles alternativas, normalmente de adjetivos o verbos sinónimos, o también de adverbios intensificadores de distinto grado de intensidad (e.g. *_ is most/very/extremely annoying/exasperating*).

El uso de estos operadores es importante, ya que un sistema de PLN debería tener en cuenta todas las construcciones alternativas que se deriven de las mismas para obtener una gran cantidad de ejemplos representativos por cada función comunicativa. Además, el hecho de que las construcciones estén en un solo idioma no supone un problema para sistemas de PLN multilingües que sean capaces de reutilizar dichas construcciones para otros idiomas.

4.3. Identificación automática de funciones comunicativas

Tras definir la taxonomía de funciones comunicativas negativas, formulamos la tarea de identificación automática de funciones comunicativas como una tarea de clasificación textual multi-etiqueta que se encarga de asignar una o más etiquetas de funciones comunicativas de un conjunto de estas a un texto dado. Las expresiones o construcciones lingüísticas de la taxonomía proporcionarían la pista principal para identificar tales funciones, esto es, en el caso de que haya una correspondencia directa entre proposición e ilocución (Cruse, 2000, p. 333). Por ejemplo, si yo digo que me muestro en desacuerdo con algo, la expresión *mostrarse en desacuerdo* nos está indicando claramente que la función comunicativa es DISAGREEMENT, sin ambages. Otra cosa sería si *mostrarse en desacuerdo* fuera acompañado de otras señales contextuales que indicaran la presencia de otras funciones como, por ejemplo, COMPLAINT o ANGRY. En este sentido, no es raro encontrar tuits (como el Ejemplo 1, abajo, obtenido de un tuit real) en los que vemos en acción cómo

una proposición contiene más de una función comunicativa en tanto que hay elementos dentro del microtexto, como emojis o expresiones adyacentes, que indican la presencia implícita de más de una función comunicativa en juego:

(2) *La subida del precio la marca Matutano... Lo peor es que todavía hay gente que sigue comprándola. Vaya robo 🙄*

No está tan claro si el usuario muestra únicamente su queja, acompañada de desagrado y enfado con respecto a la problemática de la inflación. Por tanto, entrarían en juego funciones comunicativas como COMPLAINT, DISLIKE y ANGRY. Esta polisemia de funciones viene dada por expresiones como *vaya robo*, acompañado del emoji que expresa enfado, o expresiones como *lo peor es que X*, junto con la detección del problema de la inflación latente en la expresión *subida del precio*. Por tanto, la taxonomía no es sino un punto de partida a partir del cual un modelo de PLN ha de ser capaz de reconocer las sutilezas de las expresiones implícitas de funciones comunicativas.

También puede darse el caso de que una misma proposición o expresión lingüística descontextualizada pueda referir a varias funciones comunicativas a la vez (Wilkins, 1976, p. 44). Ya de por sí es muy complicado, como indica la literatura, obtener categorías que estén claramente delimitadas fuera de contexto por la ambigüedad subyacente en algunas expresiones lingüísticas (Thomas, 1995, p. 103). Véase, por ejemplo, una de las expresiones lingüísticas que hemos incluido en la taxonomía, que pertenece a las funciones comunicativas DISLIKE y ANGER, simultáneamente:

(3) *I really hate _*

En otras ocasiones, se complica más aún si cabe la identificación de la o las funciones comunicativas, sobre todo cuando esta depende casi exclusivamente del significado contextual situacional. Por ejemplo, si un ciudadano comentara *¿Es este el gobierno que nos merecemos?*, si bien podemos entender inequívocamente el significado de la proposición, esto es, la fuerza locutiva, desconocemos si esta pregunta esconde alguna intención comunicativa más allá de lo que en apariencia se muestra como una pregunta retórica: ¿expresa el hablante desprecio, desagrado y/o una queja? ¿qué expresión lingüística en el contexto lingüístico, si acaso hay alguna, ayuda a tal interpretación? ¿cómo podrían los sistemas de PLN ser capaces de ir más allá del texto y comprender esta variedad de significados pragmáticos? Esta ambigüedad interpretativa sucede cuando la proposición o parte locutiva podría tener más de una fuerza ilocutiva en diferentes contextos o cuando no tiene una fuerza ilocutiva clara asociada, fenómeno que se conoce como acto de habla indirecto.

En consecuencia, en un contexto particular como un tuit la complejidad de determinar la o las funciones comunicativas presentes en el texto se convierte en una tarea todavía más complicada si cabe dado que el hablante podría incurrir, consciente o inconscientemente, en la ambigüedad del mensaje. En este sentido, los anotadores del tuit tendrían que tener en cuenta todos estos factores e intentar evitar en la medida de lo posible proyectar en el tuit lo que ellos perciben como receptores y ponerse en la piel del hablante para adivinar su intención. Del mismo modo, quedaría por ver si los sistemas de PLN más innovadores como los transformadores podrían inferir las funciones

comunicativas de un mensaje aun cuando el mensaje carezca de marcadores lingüísticos explícitos que ayuden a tal fin, como el caso del ejemplo (2), ya que la taxonomía que hemos desarrollado contiene únicamente aquellas expresiones lingüísticas que están típicamente asociadas a cada función comunicativa, es decir, sólo contiene funciones comunicativas de actos de habla directos.

5. Conclusiones

Las redes sociales son una mina de datos de información de sus usuarios, quienes vierten con frecuencia sus opiniones, pensamientos, emociones, etc. con respecto a temáticas de todo tipo, ya sean de carácter público o privado. Tal cantidad y riqueza de información se puede aprovechar para el contexto de las ciudades inteligentes, en el que la calidad de vida de los ciudadanos depende, directa o indirectamente, de la posibilidad de identificar y describir los problemas que estos manifiestan en las redes sociales, para así poder intervenir y subsanar tales problemas. Para este fin, se ha desarrollado el proyecto ALLEGRO y, específicamente, DIAPASON, el módulo lingüístico encargado de proporcionar la caracterización conceptual de los problemas de los ciudadanos contenidos en los mensajes de redes sociales.

Una parte importante del mensaje es la parte ilocutiva o función comunicativa que, en el contexto de las ciudades inteligentes, tiene que ver con la expresión de emociones, pensamientos y juicios de carácter negativo. Hasta ahora en el PLN se ha abordado la detección de emociones y actos de habla, pero se ha dejado a un lado la identificación y clasificación de tales funciones comunicativas, como se entienden estas en el enfoque nocional-funcional o comunicativo perteneciente al campo del aprendizaje y enseñanza de lengua extranjera. Ya autores previos como Levinson (1980, p. 241) apuntaban que era quizá posible obtener una taxonomía finita de funciones comunicativas, si bien tal interés lo consideraba fuera de lugar. Hoy día, sin embargo, debido a la explosión de la IA y la necesidad de desarrollar sistemas de PLN que puedan entender la semántica profunda, se convierte en una tarea casi indispensable el estudiar y delimitar el rango de funciones comunicativas existentes en las lenguas para su aplicación en tales sistemas.

Este capítulo ha pretendido demostrar cómo de útil y necesario es el desarrollo de una taxonomía de funciones comunicativas negativas en el contexto de las ciudades inteligentes. Identificar dichas funciones comunicativas de un mensaje es necesario para predecir la insatisfacción y las preocupaciones de los ciudadanos y así mejorar su bienestar, mediante la mejora de los servicios e infraestructuras de la ciudad. Los ciudadanos manifiestan sus quejas acerca del estado de las calles, los parques y otras infraestructuras; también pueden manifestar su preocupación por diferentes cuestiones sociológicas como el racismo, el sexismo, el desempleo, la política local, la brecha económica o la inflación, utilizando para ello la expresión de distintas emociones, juicios y actitudes, que va más allá de las emociones predefinidas en la literatura de la detección de emociones o la lista de actos de habla normalmente utilizados en la tarea de clasificación de actos de habla.

Por ello, hemos presentado una taxonomía semántica y sintácticamente granular de funciones comunicativas negativas en el contexto de las ciudades

inteligentes que facilitará el entrenamiento y evaluación de modelos de PLN basados en esta taxonomía para la tarea de identificación automática de funciones comunicativas. A este respecto, como parte de investigaciones futuras, planteamos el uso de esta taxonomía como corpus sintético de entrenamiento con los denominados transformadores, esto es, modelos de PLN de redes neuronales que sean multilingües y adaptados al género microtextual de los tuits como, por ejemplo, XLM-RoBERTa-T (Barbieri et al., 2021). Asimismo, valoraremos la reutilización de corpus de tuits pertenecientes a la tarea de detección de emociones mediante técnicas automáticas de procesamiento y mapeo para la fase de evaluación del modelo de transformador entrenado con nuestra taxonomía de funciones comunicativas negativas.

Agradecimientos

Esta publicación es parte del proyecto de I+D+i PID2020-112827GB-I00 financiado por MCIN/AEI/10.13039/501100011033 y del proyecto SMARTLAGOON [referencia 101017861] financiado por el Programa Horizonte 2020 de la Unión Europea.

Referencias

- Alm, C. O., Roth, D., & Sproat, R. (2005). Emotions from text: Machine learning for text-based emotion prediction. *HLT/EMNLP 2005 - Human Language Technology Conference and Conference on Empirical Methods in Natural Language Processing, Proceedings of the Conference, October*, 579–586.
- Aman, S., & Szpakowicz, S. (2007). Identifying expressions of emotion in text. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 4629 LNAI, 196–205. https://doi.org/10.1007/978-3-540-74628-7_27
- Austin, J. L. (1962). *How to Do Things with Words*. Oxford University Press.
- Baider, F., & Cislaru, G. (2014). *Linguistic approaches to emotion in context*. John Benjamins Publishing Company. <https://doi.org/10.1075/pbns.241.01bai>
- Barbieri, F., Anke, L. E., & Camacho-Collados, J. (2021). *XLM-T: A Multilingual Language Model Toolkit for Twitter*. 2015. <http://arxiv.org/abs/2104.12250>
- Basile, A., Pérez-Torró, G., & Franco-Salvador, M. (2021). Probabilistic Ensembles of Zero- and Few-Shot Learning Models for Emotion Classification. *International Conference Recent Advances in Natural Language Processing, RANLP*, 128–137. https://doi.org/10.26615/978-954-452-072-4_016
- Baziotis, C., Athanasiou, N., Chronopoulou, A., Kolovou, A., Paraskevopoulos, G., Ellinas, N., Narayanan, S., & Potamianos, A. (2018). *NTUA-SLP at SemEval-2018 Task 1: Predicting Affective Content in Tweets with Deep Attentive RNNs and Transfer Learning*.
- Blundell, J., Higgins, J., & Middlemiss, N. (1982). *Function in English*. Oxford University Press.

- Bostan, L.-A.-M., & Klinger, R. (2018). An Analysis of Annotated Corpora for Emotion Classification in Text. *Proceedings of the 27th International Conference on Computational Linguistics*, 2104–2119. <https://www.aclweb.org/anthology/C18-1179%0Ahttp://www.ims.uni-stuttgart.de/data/unifyemotion>
- Buechel, S., & Hahn, U. (2017). Readers vs. writers vs. texts: Coping with different perspectives of text understanding in emotion annotation. *LAW 2017 - 11th Linguistic Annotation Workshop, Proceedings of the Workshop*, 1–12. <https://doi.org/10.18653/v1/w17-0801>
- Cambria, E. (2016). Affective Computing and Sentiment Analysis. *IEEE Intelligent Systems*, 31(2), 102–107. <https://doi.org/10.1109/MIS.2016.31>
- Cambria, E., Li, Y., Xing, F. Z., Poria, S., & Kwok, K. (2020). SenticNet 6: Ensemble Application of Symbolic and Subsymbolic AI for Sentiment Analysis. *International Conference on Information and Knowledge Management, Proceedings*, 105–114. <https://doi.org/10.1145/3340531.3412003>
- Caselli, T., Sprugnoli, R., & Moretti, G. (2021). Identifying communicative functions in discourse with content types. *Language Resources and Evaluation*. <https://doi.org/10.1007/s10579-021-09554-4>
- Cruse, A. (2000). *Meaning in Language: An Introduction to Semantics and Pragmatics*. Oxford University Press.
- Demszky, D., Movshovitz-Attias, D., Ko, J., Cowen, A., Nemade, G., & Ravi, S. (2021). *GoEmotions: A Dataset of Fine-Grained Emotions*. 4040–4054. <https://doi.org/10.18653/v1/2020.acl-main.372>
- Devlin, J., Chang, M. W., Lee, K., & Toutanova, K. (2019). BERT: Pre-training of deep bidirectional transformers for language understanding. *NAACL HLT 2019 - 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies - Proceedings of the Conference*, 1, 4171–4186.
- Dini, L., & Bittar, A. (2016). Emotion analysis on twitter: The hidden challenge. *Proceedings of the 10th International Conference on Language Resources and Evaluation, LREC 2016*, 3953–3958.
- Ekman, P. (1992). An argument for basic emotions. *Cognition and Emotion*, 6(3), 169–200.
- Esuli, A., & Sebastiani, F. (2008). SENTIWORDNET: A Publicly Available Lexical Resource for Opinion Mining. *Proceedings of the 7th Conference on Language Resources and Evaluation LREC10*, 417–422. http://www.lrec-conf.org/proceedings/lrec2010/pdf/769_Paper.pdf
- Finocchiaro, M., & Brumfit, C. (1983). *The functional-notional approach: from theory to practice*. Oxford University Press.
- Hancher, M. (1979). The classification of cooperative illocutionary acts. *Language in Society*, 8(1), 1–14. <https://doi.org/10.1017/S0047404500005911>
- Jurafsky, D., & Martin, J. H. (2021a). Chatbots & Dialogue Systems. In *Speech and Language Processing*. Book in preparation.
- Jurafsky, D., & Martin, J. H. (2021b). Lexicons for sentiment, affect, and connotation. In *Speech and Language Processing*. Book in preparation. <https://web.stanford.edu/~jurafsky/slp3/ed3book.pdf>
- Jurafsky, D., Shriberg, E., & Biasca, D. (1997). *Switchboard SWBD DAMSL Shallow-Discourse-Function Annotation*.

- Levinson, S. C. (1983). *Pragmatics*. Cambridge University Press.
- Liew, J., Yan, S., Turtle, H. R., & Liddy, E. D. (2016). EmoTweet-28 : A Fine-Grained Emotion Corpus for Sentiment Analysis. *Proceedings of the Tenth International Conference on Language Resources and Evaluation (LREC'16)*, 1149–1156.
- Maia, B., & Santos, D. (2018). Language, emotion, and the emotions: The multidisciplinary and linguistic background. *Language and Linguistics Compass*, 12(6), 1–17. <https://doi.org/10.1111/lnc3.12280>
- McStay, A. (2020). Emotional AI, soft biometrics and the surveillance of emotional life: An unusual consensus on privacy. *Big Data and Society*, 7(1). <https://doi.org/10.1177/2053951720904386>
- Mikolov, T., Chen, K., Corrado, G., & Dean, J. (2013). Efficient Estimation of Word Representations in Vector Space. *Proceedings of the International Conference on Learning Representations (ICLR 2013)*, 1–12. <http://arxiv.org/abs/1301.3781>
- Milanovic, M., & Saville, N. (2012). The Theoretical Foundations for functions in the Council of Europe modern languages projects and the Common European Framework of Reference for languages. In *Language Functions Revisited*. Cambridge University Press. www.cambridge.org
- Mohammad, S. M. (2012). Emotional tweets. **SEM 2012 - 1st Joint Conference on Lexical and Computational Semantics*, 1, 246–255.
- Mohammad, S. M. (2021). Sentiment Analysis: Detecting Valence, Emotions, and Other Affectual States from Text. In *Emotion Measurement* (pp. 201–237). Elsevier. <https://doi.org/10.1016/B978-0-08-100508-8.00009-6>
- Mohammad, S. M. (2022). Ethics Sheet for Automatic Emotion Recognition and Sentiment Analysis. *Computational Linguistics*, September, 1–38. https://doi.org/10.1162/coli_a_00433
- Mohammad, S. M., & Alm, C. O. (2015). Computational Analysis of Affect and Emotion in Language. *Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing: Tutorial Abstracts*.
- Mohammad, S. M., Bravo-Marquez, F., Salameh, M., & Kiritchenko, S. (2018). SemEval-2018 Task 1: Affect in Tweets. *Proceedings Of the 12th International Workshop on Semantic Evaluation (SemEval-2018)*, 1–17. <https://doi.org/10.18653/v1/s18-1001>
- Mohammad, S. M., & Kiritchenko, S. (2018). Understanding emotions: A dataset of tweets to study interactions between affect categories. *LREC 2018 - 11th International Conference on Language Resources and Evaluation*, 198–209.
- Mohammad, S. M., Zhu, X., Kiritchenko, S., & Martin, J. (2015). Sentiment, emotion, purpose, and style in electoral tweets. *Information Processing and Management*, 51(4), 480–499. <https://doi.org/10.1016/j.ipm.2014.09.003>
- Neviarouskaya, A., Prendinger, H., & Ishizuka, M. (2007). Textual affect sensing for sociable and expressive online communication. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 4738 LNCS, 218–229. https://doi.org/10.1007/978-3-540-74889-2_20
- Novielli, N., & Strapparava, C. (2013). The role of affect analysis in dialogue act identification. *IEEE Transactions on Affective Computing*, 4(4), 439–451. <https://doi.org/10.1109/T-AFFC.2013.20>

- Pennebaker, J. W., Francis, M. E., & Booth, R. J. (2001). Linguistic inquiry and word count: LIWC 2001. *Mahway: Lawrence Erlbaum Associates*, 71(2001), 2001. <https://doi.org/10.4018/978-1-60960-741-8.ch012>
- Picard, R. (1997). *Affective computing*. MIT Press.
- Plaza-del-Arco, F. M., Collado-Montañez, J., Ureña, L. A., & Martín-Valdivia, M.-T. (2022). *Empathy and Distress Prediction using Transformer Multi-output Regression and Emotion Analysis with an Ensemble of Supervised and Zero-Shot Learning Models*. 239–244. <https://doi.org/10.18653/v1/2022.wassa-1.23>
- Plaza-del-arco, F. M., Mar, S., Montejo-r, A., Molina-gonz, M. D., Ure, L. A., & Mart, M. T. (2021). Overview of the EmoEvalEs task on emotion detection for Spanish at IberLEF 2021. *Procesamiento Del Lenguaje Natural*, 2021(67), 155–161. <https://doi.org/10.26342/2021-67-13>
- Plaza-del-Arco, F. M., Martín-Valdivia, M.-T., & Klinger, R. (2022). *Natural Language Inference Prompts for Zero-shot Emotion Classification in Text across Corpora*. <http://arxiv.org/abs/2209.06701>
- Plaza-del-Arco, F. M., Strapparava, C., Alfonso Ureña-López, L., & Teresa Martín-Valdivia, M. (2020). EmoEvent: A multilingual emotion corpus based on different events. *LREC 2020 - 12th International Conference on Language Resources and Evaluation, Conference Proceedings, May*, 1492–1498.
- Plutchik, R. (1980). A general psychoevolutionary theory of emotion. In R. Plutchik & H.Kellerman (Eds.), *Emotion: Theory, research, and experience: Vol. 1. Theories of emotion*, (pp. 3-33). Academic.
- Purver, M., & Battersby, S. (2012). Experimenting with distant supervision for emotion classification. *EACL 2012 - 13th Conference of the European Chapter of the Association for Computational Linguistics, Proceedings*, 482–491.
- Saha, T., Ramesh Jayashree, S., Saha, S., & Bhattacharyya, P. (2020). BERT-Caps: A Transformer-Based Capsule Network for Tweet Act Classification. *IEEE Transactions on Computational Social Systems*, 7(5), 1168–1179. <https://doi.org/10.1109/TCSS.2020.3014128>
- Scherer, K. R., & Wallbott, H. G. (1994). Evidence for universality and cultural variation. *Journal of Personality and Social Psychology*, 66(2), 310–328.
- Scherer, K. R. (2005). What are emotions? And how can they be measured? *Social Science Information*, 44(4), 695–729.
- Schuff, H., Barnes, J., Mohme, J., Padó, S., & Klinger, R. (2017). Annotation, Modelling and Analysis of Fine-Grained Emotions on a Stance and Sentiment Detection Corpus. *Proceedings of the 8th Workshop on Computational Approaches to Subjectivity, Sentiment and Social Media Analysis*, 13–23. <https://doi.org/10.18653/v1/w17-5203>
- Searle, J. R. (1969). *Speech Acts: An Essay in the Philosophy of Language*. Cambridge University Press.
- Searle, J. R. (1976). A classification of illocutionary Acts. *Language in Society*, 5(1), 1–23.
- Sorabji, R. (2000). *Emotion and Peace of Mind: From Stoic Agitation to Christian Temptation*. Oxford University Press
- Stolcke, A., Ries, K., Coccaro, N., Shriberg, E., Bates, R., Jurafsky, D., Taylor, P., Martin, R., Van Ess-Dykema, C., & Meteer, M. (2000). Dialogue Act Modeling for Automatic Tagging and Recognition of Conversational

- Speech. *Computational Linguistics*, 26(3), 35.
<http://dx.doi.org/10.1162/089120100561737>
- Strapparava, C., & Mihalcea, R. (2007). Learning to identify emotions in text. *Proceedings of the ACM Symposium on Applied Computing*, 1556–1560.
<https://doi.org/10.1145/1363686.1364052>
- Strapparava, C., & Valitutti, A. (2004). WordNet-Affect: An affective extension of WordNet. *Proceedings of the 4th International Conference on Language Resources and Evaluation, LREC 2004*, 1083–1086.
- Thomas, J. (1995). *Meaning in interaction: An introduction to Pragmatics*. Routledge.
- Valle-Cruz, D., Lopez-Chau, A., & Sandoval-Almazan, R. (2021). How much do Twitter posts affect voters? Analysis of the multi-emotional charge with affective computing in political campaigns. *ACM International Conference Proceeding Series*, 1–14. <https://doi.org/10.1145/3463677.3463698>
- van Ek, J. A., & Trim, J. L. M. (1991). *Threshold*. Cambridge University Press.
- Vera, D., Araque, O., & Iglesias, C. A. (2021). GSI-UPM at IberLEF2021: Emotion analysis of Spanish tweets by fine-tuning the XLM-RoBERTa language model. *CEUR Workshop Proceedings*, 2943(September), 16–26.
- Wang, W., Chen, L., Thirunarayan, K., & Sheth, A. P. (2012). Harnessing twitter “big data” for automatic emotion identification. *Proceedings - 2012 ASE/IEEE International Conference on Privacy, Security, Risk and Trust and 2012 ASE/IEEE International Conference on Social Computing, SocialCom/PASSAT 2012*, 587–592. <https://doi.org/10.1109/SocialCom-PASSAT.2012.119>
- Wilkins, D. A. (1976). *Notional Syllabuses*. Oxford University Press.
- Williams, H. (2018). Functional-Notional Approach. In J. I. Lontas (Ed.), *The TESOL Encyclopedia of English Language Teaching* (pp. 1–7). John Wiley & Sons. <https://doi.org/10.1002/9781118784235.eelt0165>
- Yule, G. (1996). *Pragmatics*. Oxford University Press.
- Zhang, R., Gao, D., & Li, W. (2011). What are tweeters doing: Recognizing speech acts in twitter. *AAAI Workshop - Technical Report, WS-11-05*, 86–91.