

TRABAJO FINAL INTEGRADOR

ESPECIALIZACIÓN EN INGENIERÍA EN  
SISTEMAS DE INFORMACIÓN

Título:

“ANÁLISIS DE SENTIMIENTOS EN ESPAÑOL A  
TRAVÉS DE EMOTICONES EN TWITTER PARA  
DETECCIÓN DE SARCASMO”

Autor: Ing. Caleb Josue FAILLACE VILLANUEVA

Tutores:

Dra. Paola Britos (UNRN)

Dra. María Florencia Pollo Cattaneo (UTNFRBA)

Buenos Aires – 12/2020



*Universidad Tecnológica Nacional  
Facultad Regional Buenos Aires*



**UTN.BA**  
**ESCUELA DE**  
**POSGRADO**

# **ANÁLISIS DE SENTIMIENTOS EN ESPAÑOL A TRAVÉS DE EMOTICONES EN TWITTER PARA DETECCIÓN DE SARCASMO**

Alumno:

**Ing. Caleb Josue FAILLACE VILLANUEVA**

Directores

**Dra. Paola Britos (UNRN)**

**Dra. María Florencia Pollo Cattaneo (UTNFRBA)**

TRABAJO FINAL PRESENTADO PARA OBTENER EL GRADO DE  
ESPECIALISTA EN INGENIERÍA EN SISTEMAS DE INFORMACIÓN

**ESCUELA DE POSGRADO FACULTAD REGIONAL DE  
BUENOS AIRES UNIVERSIDAD TECNÓLOGICA NACIONAL**

**DICIEMBRE, 2020**



## Resumen

Los últimos años han sido testigos de un rápido crecimiento de las plataformas de medios sociales, como Twitter, donde millones de personas comparten sus pensamientos y opiniones sobre varios temas. La creciente popularidad de las redes sociales ha transformado la web en un vasto depósito de opiniones sobre diversos temas. Por lo tanto, comprender las opiniones de los usuarios es muy importante en el proceso de toma de decisiones.

La opinión pública cambia con el tiempo, por lo tanto, el seguimiento de la evolución de opiniones y sentimientos es muy crítico para las partes interesadas. El análisis de la evolución de los sentimientos brinda la oportunidad de identificar cambios repentinos de sentimientos y, lo que es más importante, de obtener información sobre lo que ha causado estos picos de sentimientos.

En este trabajo se presenta un estudio sobre cómo los emoticones pueden afectar el análisis de la polaridad de un conjunto de datos extraídos de Twitter, detallando el impacto de estos en el lenguaje figurado cómo pueden ser la ironía y el sarcasmo.

En el caso del lenguaje literal, las técnicas existentes logran resultados aceptables con textos. Sin embargo, esta tarea es especialmente compleja cuando en el texto se encuentra lenguaje figurado, puesto que nos enfrentamos con distintos significados debido al uso de la ironía o el sarcasmo, por lo tanto, la polaridad del significado literal puede contrastar fuertemente con el sentimiento que pretende transmitir el sentido figurado.

**Palabras clave:** *Análisis de sentimientos, Emoticones, Ironía, Sarcasmo, Lenguaje figurativo*

## **Abstract**

The past few years have witnessed the rapid growth of social media platforms, such as Twitter, where millions of people share their thoughts and opinions on various topics. The increasing popularity of social networks has transformed the web into a vast repository of opinions on various topics. Therefore, understanding user opinions is very important in the decision-making process.

Public opinion changes over time, therefore monitoring the evolution of opinions and feelings is very critical for stakeholders. Analysis of the evolution of feelings provides an opportunity to identify sudden changes in feelings and, more importantly, to obtain information about what has caused these spikes in feelings.

This paper presents a study on how emoticons can affect the polarity analysis of a set of data extracted from Twitter, detailing the impact of these on figurative language such as irony and sarcasm.

In the case of literal language, existing techniques achieve acceptable results with texts. However, this task is especially complex when we find figurative language in the text, since we are faced with different meanings due to the use of irony or sarcasm, therefore, the polarity of the literal meaning can contrast sharply with the sentiment it seeks to transmit the figurative meaning.

**Keywords:** *Sentiment Analysis, Emoticons, Irony, Sarcasm, Figurative language*

# ÍNDICE

ÍNDICE DE FIGURAS.....	I
ÍNDICE DE TABLAS.....	II
1. INTRODUCCIÓN.....	1
1.1. IMPORTANCIA DEL TRABAJO DE ESPECIALIDAD.....	1
1.2. OBJETIVOS.....	3
1.2.1. <i>Objetivo general</i> .....	3
1.2.2. <i>Objetivos específicos</i> .....	3
1.3. ALCANCE.....	3
2. METODOLOGÍA.....	4
3. ESTADO DE LA CUESTIÓN.....	5
3.1. TWITTER.....	5
3.1.1. EMOTICONES EN TWITTER.....	7
3.2. ANÁLISIS DE SENTIMIENTOS.....	9
3.3. ANÁLISIS DE SENTIMIENTOS EN TWITTER.....	11
3.4. ENFOQUES DEL ANALISIS DE SENTIMIENTOS.....	12
3.4.1. <i>Enfoque Basado En Léxico</i> .....	13
3.4.2. <i>Enfoque Basado en Aprendizaje Automático</i> .....	14
3.4.2.1. Aprendizaje supervisado.....	15
3.4.2.2. Aprendizaje no supervisado.....	16
3.4.3. Enfoque Híbrido.....	17
3.5. RECURSOS.....	17
4. CONCLUSIONES.....	23
4.1. RESUMEN DE LOS RESULTADOS DEL TRABAJO.....	23
4.2. FUTURAS LÍNEAS DE INVESTIGACIÓN.....	24
4.3. PUBLICACIONES PRESENTADAS.....	25
5. REFERENCIAS.....	25

## ÍNDICE DE FIGURAS

Figura 1 Ejemplo de un tweet.....	7
Figura 2 Emoticones en twitter.....	7
Figura 3 Enfoques del Análisis de Sentimientos .....	12
Figura 4 Análisis de sentimientos con enfoque basado en léxico.....	14
Figura 5 Analisis de sentimientos con enfoque de aprendizaje automático.....	15

## ÍNDICE DE TABLAS

Tabla 1 Ejemplo de emoticones y el sentimiento que representa. ....	9
Tabla 2 Ejemplos extraídos del corpus de la tarea 11 de SemEval 2015.....	11
Tabla 3 Participantes del SemEval 2015 por orden alfabético .....	18
Tabla 4 Participantes del SemEval 2018 por orden alfabético .....	18
Tabla 5 Participantes, Soluciones y recursos en SemEval 2015 por orden alfabético .....	20
Tabla 6 Participantes, Soluciones y recursos en SemEval 2018 por orden alfabético .....	23

## 1. INTRODUCCIÓN

En las secciones posteriores se examina la importancia del trabajo de especialidad (sección 1.1), se plantean los objetivos, tanto el general como los específicos, de la obra (sección 1.2) y se delimita el alcance de la misma (sección 1.3).

### 1.1. IMPORTANCIA DEL TRABAJO DE ESPECIALIDAD

La información producida por personas, el tipo de contenido expresado en textos, se pueden categorizar en dos grandes grupos: hechos y opiniones. Los hechos son definidos como expresiones objetivas sobre entidades, eventos y sus propiedades, mientras que las opiniones tratan sobre la subjetividad en forma de sentimientos, sensaciones y juicios de valor (B. Liu, 2010).

Los últimos años han sido testigos de un rápido crecimiento de las plataformas de medios sociales, como Twitter, donde millones de personas comparten sus pensamientos y opiniones sobre varios temas, con el crecimiento explosivo del contenido generado por los usuarios en la Web en los últimos años, el mundo se ha transformado (B. Liu, 2010). La creciente popularidad de las redes sociales ha transformado la web en un vasto depósito de opiniones sobre diversos temas. Por lo tanto, comprender las opiniones de los usuarios es muy importante en el proceso de toma de decisiones (Rosenthal et al., 2019).

La opinión pública cambia con el tiempo, por lo tanto, el seguimiento de la evolución de opiniones y sentimientos es muy crítico para las partes interesadas. El análisis de la evolución de los sentimientos brinda la oportunidad de identificar cambios repentinos de sentimientos y, lo que es más importante, de obtener información sobre lo que ha causado estos picos de sentimientos.

El auge de las redes sociales continúa demostrando que la gente busca activamente dar a conocer sus opiniones, compartiendo lo que le gusta, no le gusta y lo que piensa sobre distintos temas, aún con extraños (Ghiassi et al., 2013). Con este crecimiento se generan nuevas posibilidades de explotar la información producida por los consumidores de estos servicios. Twitter cuenta con bases de usuarios que rondan los cientos de millones de personas y cuya actividad produce a diario una inmensa cantidad de contenido en forma de textos, imágenes, videos y otros formatos. Con la intención de aprovechar la información disponible, disciplinas relacionadas a las ciencias políticas, económicas, sociales y de investigación de mercado estudian las redes con un interés especial en las estadísticas sobre datos agregados que resultan de algunos de estos canales (Rosenthal et al., 2019). El conjunto de los datos extraídos durante la ejecución de las técnicas resulta de gran valor para empresas, gobiernos y demás organizaciones por sus posibles aplicaciones, entre las cuales se encuentran el delinear perfiles, conocer sentimientos e

ideas de futuros consumidores o votantes, relevar expectativas y realizar predicciones. A menudo, el fin de estos procesos es auxiliar en la toma de decisiones estratégicas que se alineen con los objetivos de la organización.

Dentro de las opiniones se encuentra el uso extensivo de emojis que ha atraído una atención creciente de los investigadores porque los emojis transmiten información semántica y sentimental fructífera para complementar visualmente la información textual que es significativamente útil para comprender las señales emocionales incrustadas en los textos (Chen et al., 2018).

Se demostró que los usuarios de Twitter utilizan ampliamente los emoticones. En particular, los emoticones que expresan sentimientos positivos, como :) y ;), fueron la mayoría dominante en Twitter (Wang & Castanon, 2015). Los emojis pueden resumir y enfatizar la idea original de sus contextos, o expresar semánticas más complejas como la ironía y el sarcasmo al combinarse con contextos de semánticas o sentimientos contradictorios (Chen et al., 2018).

El objetivo principal del análisis de sentimientos es identificar la orientación general (positiva, negativa o neutral) en un texto dado. El sarcasmo es un tipo especial de sentimiento que desempeña un papel como factor de interferencia que puede cambiar la polaridad del texto dado (Bharti et al., 2015). La presencia de sentimientos sarcásticos es uno de los desafíos para el análisis de sentimientos. Debido a esto, la mayoría de los sistemas existentes para el análisis de sentimientos falla al detectar el valor real de los sentimientos. El sarcasmo es un tipo particular de sentimiento que generalmente cambia la orientación de la opinión en un texto dado (Bharti et al., 2017).

A diferencia de una simple negación, un texto sarcástico suele transmitir una opinión negativa utilizando solo palabras positivas o incluso palabras positivas intensificadas. El reconocimiento del sarcasmo es una de las tareas más difíciles en el procesamiento del lenguaje natural. El lector humano promedio tendrá dificultades para reconocer el sarcasmo en los datos de Twitter (Bharti et al., 2015).

En la comunicación cara a cara, el sentimiento a menudo se puede deducir de señales visuales como sonreír. Sin embargo, en la comunicación de texto plano mediada por computadora, tales señales visuales se pierden (Hogenboom et al., 2013). A lo largo de los años, las personas han adoptado el uso de los llamados emoticones como una alternativa a las señales visuales cara a cara en la comunicación mediada por computadora, como las expresiones virtuales de opiniones. A medida que las personas utilizan cada vez más emoticones en el texto para expresar, enfatizar o desambiguar sus sentimientos, es crucial que las herramientas de análisis de sentimientos automatizadas tengan en cuenta correctamente tales señales gráficas para el sentimiento (Hogenboom et al., 2013).

## **1.2. OBJETIVOS**

En esta sección se describen los objetivos que guían el trabajo y el estudio de la cuestión. En la primera parte se profundiza sobre el objetivo general (sección 1.2.1) y en el punto siguiente se enlistan los objetivos específicos derivados del objetivo general (sección 1.2.2).

### **1.2.1. Objetivo general**

El objetivo principal del presente trabajo consiste en lo siguiente:

- Describir el estado de la cuestión de los diferentes métodos y/o técnicas utilizadas actualmente para análisis de sentimientos, a través de emoticones o emojis en la red social Twitter, con el fin de identificar los recursos más empleados para esta tarea y las características de los mismos que permitan determinar la clasificación de la polaridad y su aplicación sobre el lenguaje español.

### **1.2.2. Objetivos específicos**

Los objetivos específicos que se definen en esta obra para el soporte del objetivo general son:

- Identificar el estado del arte del análisis de sentimientos con emoticones para la detección de lenguaje figurativo.
- Describir la importancia de los emoticones en la detección de lenguaje figurativo en el análisis de sentimientos.
- Identificar los desafíos que tiene la detección de lenguaje figurativo en el análisis de sentimientos.

## **1.3. ALCANCE**

El presente trabajo se orienta al estudio e identificación de los diferentes métodos y/o técnicas utilizadas para el análisis de sentimientos a través de emoticones o emojis en la red social Twitter, se realiza una revisión del estado de la cuestión, y se presentan las conclusiones del estudio realizado. Queda excluido de esta investigación el desarrollo de un léxico de emoticones o herramienta para el análisis de sentimientos a través de emoticones o emojis.

## 2. METODOLOGÍA

El tema a estudiar se piensa abordar a través del lente de una filosofía Constructivista. El Constructivismo, o Constructivismo Social, habla de la importancia del estudio de las experiencias personales, el intercambio de las mismas con otros y las normas y contextos históricos y culturales con los cuales interactúa. A diferencia de visiones como el Postpositivismo, no se parte de una hipótesis concreta sino que esta se va formando a medida que el estudio progresa (Cresswell 2014).

Relacionado a la visión que se establece en el punto anterior, el estudio sistemático de la problemática se llevará a cabo a través de un enfoque cuantitativo. De esta forma, las investigaciones producen preguntas de forma dinámica, ya que pueden ocurrir antes, durante o después de la recolección y análisis de los datos (Hernández-Sampieri y Mendoza Torres 2018).

A diferencia del enfoque cualitativo, la forma en la que se estudia un fenómeno en este enfoque es analizando los hechos y trabajos previos a fin de desarrollar una explicación. En este punto, es posible que la revisión de la literatura sea complementada en cualquiera de las etapas de la investigación (Hernández-Sampieri & Mendoza Torres, 2018). Algunas de las técnicas cualitativas que acompañan este enfoque que aplicarían al trabajo a desarrollar son la observación directa, revisión documental y recolección de datos por medio de encuestas digitales.

El estudio de la comunicación en una red social y el uso de lenguaje subjetivo e informal es un tema de una naturaleza social, por lo que se reconoce que el análisis de estos textos se adapta al enfoque cuantitativo. De la misma forma, los diversos objetivos establecidos en la sección anterior se pueden encarar por medio de la metodología establecida.

El diseño de la investigación se centra en lo descriptivo, ya que se busca identificar las características de interés relacionadas a la problemática, los desafíos y la posible solución, por medio de la revisión de la literatura y la observación de las expresiones en las conversaciones de la red social. Como señala Hernández Sampieri, Fernández Collado y Baptista Lucio (2010), la claridad sobre las preguntas de investigación y la hipótesis resultante surgirá de la recolección y análisis de estos datos.

La recolección de los datos se obtiene directamente de la plataforma. Estos datos pueden ser recuperados por medio del API de Twitter. Los mensajes pueden ser filtrados haciendo uso de palabras clave, una técnica utilizada a menudo en los estudios para crear corpora con mensajes que contengan ironía, sarcasmo, lenguaje figurado, opiniones sobre un tema específico o con una característica particular.

La validación del recurso léxico producto de la investigación se lleva a cabo por medio de un clasificador entrenado para realizar análisis de sentimientos, aplicando las métricas comúnmente empleadas para la tarea (Giachanou & Crestani, 2016), mismas

que ha adoptado TASS para calificar a los participantes de la competencia. Las métricas a verificar, conocidas por sus nombre en inglés, son: Accuracy, Precision, Recall y F-score.

### 3. ESTADO DE LA CUESTIÓN

En este capítulo se expande sobre el tema de la red social a estudiar, así como las características que hacen única la naturaleza del análisis de las opiniones que en ella se comparten (sección3.1). En un segundo punto, se introduce el concepto del análisis de sentimientos para la explotación de información en textos subjetivos (sección3.2).

#### 3.1. TWITTER

Twitter, propiedad y operado por Twitter Inc., es el servicio de microblogging más popular entre otros equivalentes existentes, como Friendfeed, Tumblr e Identi.ca. Los usuarios de Twitter pueden publicar mensajes cortos, llamados tweets, en su perfil de usuario y leer los mensajes de otros usuarios en una sola lista en orden cronológico inverso, llamada línea de tiempo. Los tweets son publicaciones basadas en texto limitadas a 140 caracteres UTF-8, actualmente con un límite del doble del original de hasta 280 caracteres (Twitter, 2017), donde puede publicar sobre cualquier actualización de pequeñas cosas que suceden en la vida diaria del usuario. La breve naturaleza de las actualizaciones permite a los usuarios publicar rápidamente en tiempo real, llegando a su audiencia de inmediato (Chamlertwat et al., n.d.). Existen acerca de 500 millones de Tweets enviados cada día y se envían aproximadamente 350,000 tweets por minuto (“Estadísticas y datos de Twitter 2020,” 2020) (Twitter, Inc. - Home, n.d.) .

Twitter cuenta con un conjunto de características que lo hacen único entre las redes sociales que se han popularizado con los usuarios de Internet. Estas características específicas se enumeran a continuación (Giachanou & Crestani, 2016), las mismas están ordenadas en orden de importancia dentro de twitter:

- **Tweet:** un tweet es un mensaje único publicado en Twitter. El contenido de un tweet, que puede tener un máximo de 280 caracteres, puede variar desde información personal u opinión personal sobre productos o eventos a otros, como enlaces, noticias, fotos o videos.
- **Usuario / Nombre de usuario:** un usuario debe estar registrado en la plataforma para publicar tweets. El usuario selecciona un seudónimo (nombre de usuario) durante el registro, que luego se utilizará para publicar mensajes.
- **Mención:** las menciones en un tweet indican que la publicación menciona a otro usuario. Para hacer referencia a un nombre de usuario, los usuarios usan el

- símbolo @ seguido del nombre de usuario específico al que se refieren (@username). Las menciones se colocan en cualquier parte del cuerpo del tweet.
- Respuestas: las respuestas en un tweet se usan para indicar que la publicación es una respuesta a otro tweet y generalmente se emplean para crear conversaciones. De manera similar a las menciones, se crean usando el símbolo @ seguido del nombre de usuario al que se refieren. Las respuestas se colocan al lado del nombre de usuario que crea la respuesta.
  - Seguidor: los seguidores se refieren a los usuarios que siguen los tweets y la actividad de un usuario. Seguir a otros usuarios es la forma principal de conectarse con otros usuarios en Twitter. Los usuarios en Twitter reciben actualizaciones de quienes siguen y envían sus actualizaciones a quienes los siguen.
  - Retweet: Retweets se refieren a los tweets que se redistribuyen. Cuando un usuario encuentra un tweet interesante, puede volver a publicarlo utilizando la funcionalidad de retweeting. El retweeteo se considera una herramienta poderosa para diseminar información. El tweet que se comparte permanece sin cambios y generalmente está marcado con la abreviatura RT seguida del nombre de usuario del autor (RT @ nombre de usuario). El retweet también puede contener un breve comentario.
  - Hashtag: los hashtags se usan para indicar la relevancia de un tweet para un tema determinado. Los hashtags que se crean usando el carácter # seguido del nombre del tema (#topic) han surgido de la necesidad de etiquetar la información en los mensajes que se publicaron. Los usuarios generan etiquetas de forma espontánea y pueden utilizarse para obtener todos los tweets con el mismo hashtag. Los hashtags que aparecen en una gran cantidad de tweets se caracterizan como temas de tendencia.
  - Privacidad: Twitter da la opción a un usuario de decidir si sus tweets serán visibles para todos o solo para sus seguidores aprobados de Twitter.

A continuación, se ilustra en la figura 1 un ejemplo de cómo se visualizan los tweets y sus características.



Figura 1 Ejemplo de un tweet

Además de las anteriores se pueden identificar dentro de los tweets características estilística (Giachanou & Crestani, 2016), algunos ejemplos son emoticones, intensificadores, abreviaturas, términos de argot y signos de puntuación. Una de estas características es importante, y es la presencia de emoticones, cuya utilidad ha sido ampliamente examinada en la literatura. A continuación, en la figura 2 de los emoticones más comunes dentro de los tweets.

😊 smile	:-) :) :] =)	😬 unsure	:/ :-/ :\ :-\
😞 frown	:- ( :( [ =(	😭 cry	:'(
😛 tongue	:-P :P :-p :p =P	😈 devil	3:) 3:-)
😄 grin	:-D :D =D	👼 angel	O:) O:-)
😮 gasp	:-O :O :-o :o	😘 kiss	:-* :*
😉 wink	;-) ;)	❤️ heart	<3
🕶️ glasses	8-) 8) B-) B)	😄 kiki	^_^
🕶️ sunglasses	8-  8  B-  B	😏 squint	^-^
😠 grumpy	>:( >:-(	😵 confused	o.o O.o
😞 upset	>:O >:-O >:o >:-o	😬 curly lips	:3

Figura 2 Emoticones en twitter

### 3.1.1. EMOTICONES EN TWITTER

Aunque el término "emoticon" era originalmente una mezcla de "emoción" e "icono", los emoticones ahora representan un conjunto cada vez mayor de símbolos que van mucho más allá de indicar emoción (Thompson & Filik, 2016).

Un emoticon (o icono emocional) generalmente se define como "un glifo ASCII utilizado para indicar un estado emocional" (Filik et al., 2016). Los emoticones son símbolos producidos mediante la reutilización creativa y la combinación de caracteres existentes para representar algo nuevo: significar algo ausente en el lenguaje escrito, o algo más efectivamente "dicho" a través del símbolo. Con mayor frecuencia toman la forma de

caras expresivas, como :D, >:(, -\_- , o (^o^), pero también puede incluir otros símbolos, como <3. Mediante el uso de caracteres existentes, los emoticones se pueden producir fácilmente en cualquier teclado o dispositivo, y se pueden modificar fácilmente o crear otros nuevos para adaptarse a un contexto dado.

Los emoticones laterales comúnmente utilizados (p. Ej. :-)) se originaron en la cultura occidental. También hay una variedad de otros tipos de emoticones, que afirman que son específicos de ciertos contextos culturales, como el kaomoji (emoticones de manera correcta ^.^) que es específico de Japón. Sin embargo, estas otras categorías de emoticones se utilizan cada vez con más frecuencia en diversas culturas y contextos (Thompson & Filik, 2016).

El uso de emoticones se remonta al siglo XIX. La primera persona documentada que usó los emoticones :-)) y :-( en Internet fue Scott Fahlman de la Universidad Carnegie Mellon en un mensaje fechado el 19 de septiembre de 1982.

Las señales no verbales han surgido en la comunicación mediada por computadora. Sin embargo, estas señales son conceptualmente diferentes de las señales no verbales en la comunicación cara a cara: las señales como reír y llorar a menudo se conocen como formas involuntarias de expresarse en una comunicación cara a cara, mientras que el uso de sus respectivas los equivalentes “:-))” y “:-(” en la comunicación mediada por computadora son intencionales (Hogenboom et al., 2013).

Como tal, los emoticones permiten a las personas indicar cambios sutiles de humor, señalar ironía, sarcasmo y chistes, y expresar, enfatizar, o desambiguar su sentimiento, tal vez incluso más que las señales no verbales en la comunicación cara a cara. Por lo tanto, la recolección de información de emoticones es una estrategia viable para mejorar el análisis de sentimientos (Zhang et al., 2013).

Twitter contiene más información que solo una bolsa de palabras, como emoticones, hashtag, video, posición, etc. En particular, los emoticones, que tienen una fuerte asociación con la subjetividad y los sentimientos de los usuarios, se están volviendo cada vez más populares para que los usuarios expresen directamente sus sentimientos, emociones y estados de ánimo (Zhang et al., 2013).

Con la estandarización de Unicode, el uso de emojis se ha expandido (Tomihira et al., 2018). Algunos emoticones como caracteres están incluidos en el estándar Unicode: tres en el bloque Símbolos misceláneos y más de sesenta en el bloque Emoticones (*The Unicode Standard, Version 13.0*, n.d.).

Los emoticones se pueden clasificar como:

- Emoticones felices (Positivo)

- Emoticones tristes (Negativo)
- Emoticones neutros

A continuación, se muestra en la tabla 1 ejemplos de algunos emoticones, el sentimiento que éstos representan y la clasificación que estos pueden tener.

Sentimiento	Emotición	Clasificación
Alegría		Positivo
Gusto		Positivo
Alivio		Positivo
Dolor		Negativo
Disgusto		Negativo
Miedo		Negativo
Enfado		Negativo
Vergüenza		Neutro
Sorpresa		Neutro

Tabla 1: Ejemplo de emoticones y el sentimiento que representa.

Con la estandarización en los últimos años de los emojis, éstos han tenido un uso común. Hace apenas unos años se estaba haciendo enfoque en la investigación sobre emojis, sin embargo, a medida que su uso se ha extendido, la investigación relacionada con los emojis ha comenzado a llamar la atención (Nikhil & Srivastava, 2018)(Naderi et al., 2018)(Karthik et al., 2018)(Lu et al., 2018)(Baziotis, Athanasiou, et al., 2018)(Park et al., 2018).

### 3.2. ANÁLISIS DE SENTIMIENTOS

El análisis de sentimientos se puede definir como un proceso que automatiza la extracción de actitudes, opiniones, puntos de vista y emociones a partir de texto, discurso, tweets y fuentes de bases de datos a través del procesamiento del lenguaje natural (PNL). El análisis de sentimientos implica clasificar las opiniones en el texto en categorías como "positivo" o "negativo" o "neutral". También se conoce como análisis de subjetividad, minería de opinión y extracción de evaluaciones.

Análisis de sentimientos es un término que incluye muchas tareas, como extracción de sentimientos, clasificación de sentimientos, clasificación de subjetividad, resumen de opiniones o detección de spam de opiniones, entre otros. Su objetivo es analizar los sentimientos de las personas, actitudes, opiniones, emociones, etc. hacia elementos tales como productos, individuos, temas, organizaciones y servicios (Naderi et al., 2018).

El lenguaje figurativo plantea un desafío especialmente significativo para los sistemas de análisis de sentimientos, ya que los enfoques estándar anclados en el afecto definido

por el diccionario de palabras y frases individuales a menudo se muestran inadecuados frente a los significados figurativos indirectos. Sería conveniente si dicho lenguaje fuera raro y se limitara a géneros específicos de texto, como la poesía y la literatura. Sin embargo, la realidad es que el lenguaje figurativo es dominante en casi cualquier género de texto, y es especialmente común en los textos de la Web y en las plataformas de redes sociales como Twitter (Ghosh et al., 2015).

Casi todos los sentimientos objetivo se tratan como un sentimiento positivo / negativo. El sentimiento positivo / negativo es suficiente para determinar la reputación de los productos en la comercialización de productos o es efectivo como información para los sistemas de recomendación. Sin embargo, cuando se utilizan sentimientos para sistemas de recomendación y resumen dirigidos a películas, programas de televisión, libros y deportes, el sentimiento positivo / negativo es insuficiente (Yamamoto et al., 2014).

De alrededor de 90,000 tweets se encuentra que alrededor del 20% de los tweets (17,647 tweets) tienen emoticones. En muchos casos, los emoticones afectan profundamente los sentimientos de los tweets. Por ejemplo, el tweet “Hoy estaba feliz :)” es aparentemente más feliz que “Hoy estaba feliz”, mientras que el tweet “Estaba enojado :)” no está más enojado que “Estaba enojado”. En estos ejemplos, los emoticones alteran el sentimiento de los tweets al mejorar o suavizar su sentimiento original (Yamamoto et al., 2014).

La ironía y el sarcasmo son dos conceptos interesantes y muy relacionados. Estos dispositivos figurativos nos dan la oportunidad de explorar la interacción entre cognición y lenguaje. En términos generales, la ironía y el sarcasmo son dispositivos de lenguaje figurativo que sirven para lograr diferentes propósitos de comunicación. La definición más común de ironía se refiere a un enunciado por el cual el hablante expresa un significado opuesto al dicho literalmente (Farias & Rosso, 2017).

La ironía y el sarcasmo son formas de lenguaje no literal que a menudo se usan para comunicar lo contrario de lo que se dice literalmente. El sarcasmo es una forma específica de ironía, que se utiliza cuando el objetivo del comentario es una persona (Filik et al., 2016).

La detección de ironía y sarcasmo se consideran casos especiales de clasificación de texto, donde el objetivo principal es distinguir los textos irónicos (o sarcásticos) de los no irónicos (o no sarcásticos). Para analizar dispositivos figurativos de este tipo, es necesario considerar no solo el nivel textual sintáctico y léxico (para extraer características sobresalientes como la posición de la palabra y los signos de puntuación) (Farias & Rosso, 2017). A continuación se muestran en la tabla 2 ejemplos extraídos del corpus de la tarea 11 de SemEval 2015. En la columna “Polaridad” se especifica la polaridad con la que se puntuó de media el tweet mostrado como ejemplo.

Tweet	Polaridad
There is nothing better than Pitbull singing 'playoffs' as Timber plays in the background. <b>#sarcasm</b>	-2.5
Updated my router and it froze. Now I can't access the internet to google a solution. <b>#irony</b> <b>#thankfulformartphones</b>	-4.14
I've had a lot of wake up calls in my day, but I've always been good at hitting the snooze <b>#metaphor</b> <b>#nailedit</b>	0.22

Tabla 2: Ejemplos extraídos del corpus de la tarea 11 de SemEval 2015.

El sarcasmo escrito puede ser difícil de entender correctamente debido a la ausencia de los marcadores habituales disponibles en las conversaciones cara a cara, como el tono de voz y la expresión facial. Por lo tanto, el uso del sarcasmo en una conversación mediada por computadora puede ser arriesgado, ya que el remitente deja abierta la posibilidad de que el receptor interprete el mensaje literalmente. Sin embargo, el uso de emoticones y otros dispositivos podría ayudar a interpretar un comentario sarcástico en este medio (Filik et al., 2016). Además existe una amplia gama de emoticones que se usan con frecuencia para expresar emociones, aclarar el significado de un mensaje ambiguo, marcar ironía y sarcasmo, o en general compensar la falta de señales no verbales (Filik et al., 2016).

### 3.3. ANÁLISIS DE SENTIMIENTOS EN TWITTER

En una primera aproximación, puede decirse que analizar el sentimiento en Twitter supone asignar a cada mensaje publicado un valor relacionado con la carga emocional que transmite. En relación a esta carga emocional se pueden distinguir algunos tipos de variables diferentes (Bravo-Marquez et al., 2014).

- Polaridad: indica si el mensaje tiene un sentimiento positivo o negativo. En algunos análisis se introduce una tercera categoría para clasificar los mensajes neutros.
- Intensidad: proporciona un valor numérico en relación con la intensidad del sentimiento. Se puede distinguir entre una intensidad positiva y una intensidad negativa.
- Emoción: clasifica el texto según los distintos tipos de emociones, como puede ser la alegría, la tristeza o la ira.

La dificultad del análisis de sentimiento aplicado a grandes volúmenes de datos viene implícita en el mismo objetivo pretendido: evaluar el sentimiento o la polaridad o incluso el tipo de emoción no siempre resulta algo unívoco. Incluso cuando se realiza manualmente, el resultado puede variar según el codificador. En este punto se aprecia ya la importancia que va a tener en ambas herramientas la posibilidad de evaluar su fiabilidad (Baviera, 2017).

### 3.4. ENFOQUES DEL ANALISIS DE SENTIMIENTOS

El análisis de sentimientos se ha practicado en una variedad de temas. Por ejemplo, estudios de análisis de opinión para críticas de películas (Pang & Lee, 2008), reseñas de productos (Dave et al., 2003) y noticias y blogs (Bautin, 2009). La investigación sobre el análisis de sentimientos hasta ahora se ha centrado principalmente en dos cosas: identificar si una entidad textual dada es subjetiva u objetiva, e identificar la polaridad de los textos subjetivos (Prager, 2006). La mayoría de los estudios de análisis de sentimientos utilizan enfoques de aprendizaje automático.

En el dominio del análisis de sentimientos, los textos pertenecen a clases positivas o negativas. También puede haber clases de valores múltiples o binarios como positivo, negativo y neutral (o irrelevante). La complejidad central de la clasificación de textos en el análisis de sentimientos con respecto a la de otra catalogación basada en temas se debe a la falta de usabilidad de las palabras clave (Turney, 2001).

A menudo, las técnicas empleadas para el reconocimiento de la polaridad de los textos subjetivos pueden ser separadas en tres enfoques: basadas en el léxico, en aprendizaje automático y el abordaje híbrido (Wehrmann et al., 2017). Sin embargo, las clasificaciones nombradas no son exhaustivas y en la literatura es posible encontrar soluciones que no se adaptan por completo a uno de los tres paradigmas mencionados. A continuación, en la figura 3 se muestran las características de cada uno de estos enfoques.

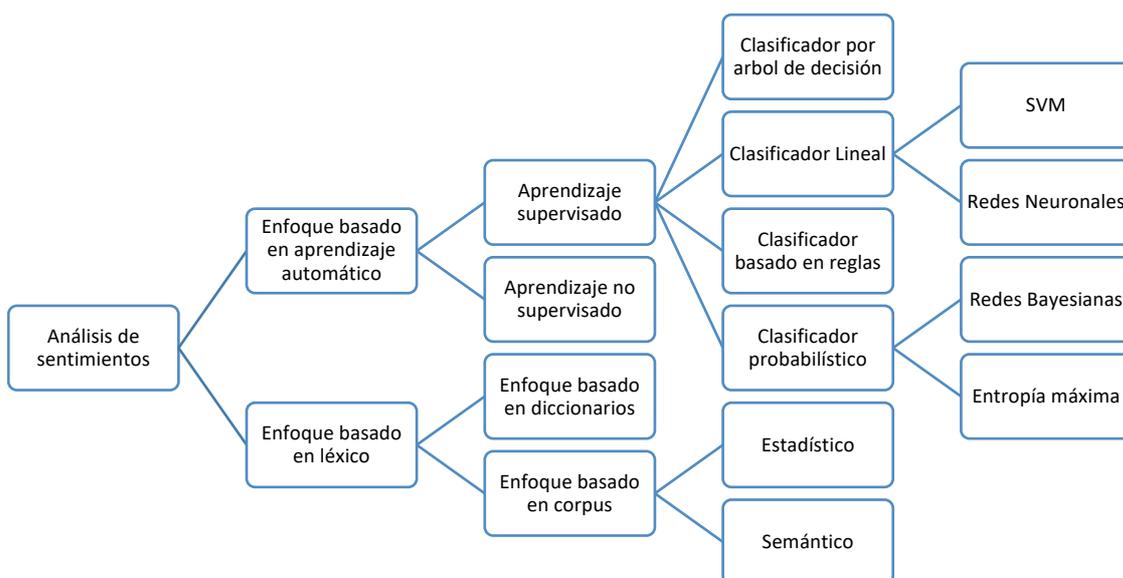


Figura 3 Enfoques del Análisis de Sentimientos

### 3.4.1. Enfoque Basado En Léxico

Uno de los primeros enfoques que se popularizó entre la comunidad de investigadores dedicada al análisis de sentimientos fue el uso de técnicas basadas en léxico. Los métodos encontrados en esta categoría tratan de realizar las clasificaciones de polaridad de los textos por medio de colecciones de elementos que han sido previamente analizados, a menudo en un proceso manual realizado por humanos con conocimiento de los términos (Devika et al., 2016). Es común que en los léxicos se marquen estos elementos con etiquetas que describan la connotación a la que tienden (negativo o positivo, en el caso más básico), o con valores numéricos en una escala predeterminada para indicar tanto su polaridad como su intensidad (-5 a +5, por ejemplo). Existen algunos diccionarios que además realizan una asociación de las palabras a distintos sentimientos, entre los que se pueden encontrar el enojo, la tristeza, el miedo o la sorpresa.

Formalmente, los términos que se recolectan en un léxico se pueden entender como secuencias de uno o varios elementos; secuencias que se componen únicamente por un elemento reciben el nombre especial de unigramas, mientras que a las secuencias que tienen dos y tres elementos se les denomina bigramas y trigramas, respectivamente. Para generalizar, n-grama se refiere entonces a una cadena con n elementos. Si bien un elemento sigue siendo una abstracción, para el caso del procesamiento del lenguaje natural en textos esto puede ser entendido como una letra, sílaba o palabra. Posiblemente por ser una de las opciones más naturales, muchos de los léxicos que se usan para el AS se pueden definir como diccionarios de palabras, aunque estos no siempre se limitan al uso de unigramas en sus listas.

Esta técnica se rige por el uso de un diccionario que consiste en léxicos pre-etiquetados. El tokenizador convierte el texto de entrada en tokens. Cada token nuevo encontrado se compara con el léxico en el diccionario. Si hay una coincidencia positiva, la puntuación se agrega al grupo total de puntuación para el texto de entrada. Por ejemplo, si "dramático" es una coincidencia positiva en el diccionario, la puntuación total del texto se incrementa. De lo contrario, la puntuación se reduce o la palabra se etiqueta como negativa. Aunque esta técnica parece ser de naturaleza amateur, sus variantes han demostrado ser dignas (Kamps et al., 2004). A continuación, en la figura 4 se muestra como trabaja este enfoque.

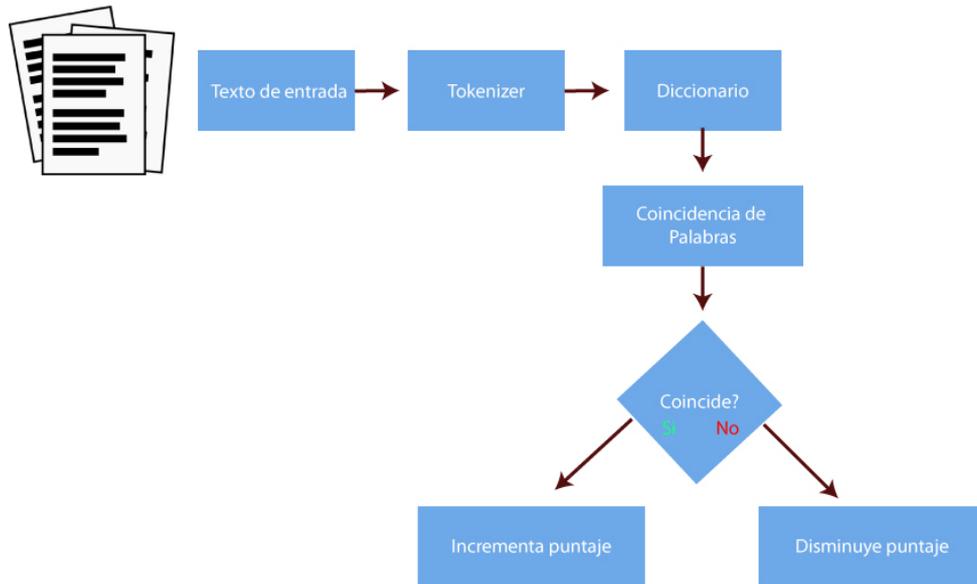


Figura 4 Análisis de sentimientos con enfoque basado en léxico

### 3.4.2. Enfoque Basado en Aprendizaje Automático

El aprendizaje automático es una de las técnicas más destacadas que atrae el interés de los investigadores debido a su adaptabilidad y precisión. En el análisis de sentimientos, se emplean principalmente las variantes de aprendizaje supervisado de esta técnica. Se compone de tres etapas: recopilación de datos, pre procesamiento, datos de capacitación, clasificación y resultados de trazado. En los datos de capacitación, se proporciona una colección de corpus etiquetados. El clasificador presenta una serie de vectores de características de los datos anteriores. Se crea un modelo basado en el conjunto de datos de entrenamiento que se emplea sobre el texto nuevo / invisible para fines de clasificación. En la técnica de aprendizaje automático, la clave para la precisión de un clasificador es la selección de las características apropiadas. Generalmente, los unigramas (frases de una sola palabra), bigramas (dos frases consecutivas), trigramas (tres frases consecutivas) son seleccionados como vectores de características (Thakkar & Patel, 2010).

La identificación de sentimientos en su contenido se centra alrededor de técnicas relacionadas a la inteligencia artificial utilizadas en conjunto con grandes volúmenes de datos. En este sentido, la tarea resulta particularmente adecuada para este tipo de soluciones debido al rol que redes sociales como Twitter pueden tener como grandes repositorios de datos. Tradicionalmente, el objetivo es planteado en este campo como un problema de clasificación (Hurtado & Pla, 2017)(Rosa et al., 2017). La aplicación de técnicas estadísticas sobre un set de datos es lo que le permite a una computadora

aprender y realizar las predicciones o clasificaciones correspondientes, aunque puede que estas no siempre sean acertadas.

La generalización necesaria para la clasificación de los mensajes se da a raíz de una serie ejemplos proporcionados en forma de un dataset o corpus en una etapa inicial (He, 2012). A esta etapa, en la jerga del dominio, se le denomina fase de entrenamiento y su correcto desempeño tiene un impacto sobre los resultados del clasificador. Los datos en los conjuntos de entrenamiento tienen características especiales que dependen del tipo de aprendizaje automático empleado. En la bibliografía del análisis de sentimientos se pueden encontrar aplicaciones de métodos supervisados, no supervisados y semi-supervisados. A continuación, en la figura 5 se muestra el funcionamiento del enfoque basado en aprendizaje automático



Figura 5 Análisis de sentimientos con enfoque de aprendizaje automático

### 3.4.2.1. Aprendizaje supervisado

El aprendizaje supervisado es una solución madura y exitosa en la clasificación tópica tradicional y se ha adoptado e investigado para la detección de opinión con resultados satisfactorios (Z. Liu et al., 2013).

Las técnicas de aprendizaje supervisado están relacionadas con la existencia de conjuntos de datos de entrenamiento etiquetados (Hassan et al., 2010). Las etiquetas de polaridad, al igual que en el enfoque basado en léxicos, suelen indicar si el mensaje tiene una connotación positiva o negativa, y pueden extenderse para describir neutralidad, falta de emoción o diversas intensidades. Los procesos de clasificación

de los datos de entrenamiento tienden a ser realizados por equipos de humanos que leen, interpretan y asignan la etiqueta idónea para cada mensaje.

El aprendizaje supervisado se utiliza para descubrir qué se ha aprendido del pasado a los datos nuevos. En el aprendizaje supervisado, se da un conjunto de datos de capacitación y ya tienen la idea de lo que se verá como resultado, incluso saben que hay una correlación de la vista y el logro correcto (Punde & Wagh, 2018).

Una vez que se ha determinado el set de entrenamiento, cada mensaje etiquetado es procesado para realizar una extracción de características. Se debe prestar especial atención a la selección de las mismas, ya que éstas, al igual que el algoritmo de aprendizaje automático elegido para la tarea, tendrán un impacto sobre el desempeño del clasificador resultante.

La mayor limitación asociada con el aprendizaje supervisado es que es sensible a la cantidad y calidad de los datos de entrenamiento y puede fallar cuando los datos de entrenamiento son sesgados o insuficientes. La detección de opinión a nivel de subdocumento plantea desafíos adicionales para los enfoques basados en el aprendizaje supervisado porque existe poca información para el clasificador (Madhoushi et al., 2015).

### **3.4.2.2. Aprendizaje no supervisado**

En la clasificación de texto, a veces es difícil crear documentos de capacitación etiquetados, pero es fácil recopilar los documentos no etiquetados. Los métodos de aprendizaje sin supervisión superan estas dificultades (Madhoushi et al., 2015).

El objetivo de este enfoque es tomar ventaja de la vasta cantidad de mensajes, originalmente sin anotaciones de polaridad en su estado natural, para mejorar la eficacia de los clasificadores; esto se logra por medio de un proceso iterativo en el que se combina el uso de datos etiquetados y no etiquetados (Davidov et al., 2010). Los pasos básicos para llevar a cabo el método semi-supervisado involucran, en una primera instancia, preparar un clasificador con el corpus de mensajes de entrenamiento que incluye etiquetas de polaridad. Una vez finalizado el primer entrenamiento del modelo, se aplica el clasificador sobre un segundo corpus compuesto por datos no etiquetados para generar probabilidades de clases de sentimiento para cada mensaje. De los resultados se seleccionan aquellas publicaciones con una alta probabilidad para integrarse al corpus de entrenamiento, mientras que el resto se queda en el set no etiquetado. El proceso se puede repetir por un número definido de iteraciones o hasta que el estado del corpus de entrenamiento sea satisfactorio.

La limitación de los enfoques no supervisados es que normalmente necesitan un gran volumen de datos para ser entrenados con precisión. Los modelos totalmente sin supervisión a menudo producen temas incoherentes porque las funciones objetivas de los modelos de temas no siempre se correlacionan bien con los juicios humanos. A pesar de esta desventaja, el aprendizaje no supervisado aún nos ofrece una forma de obtener conocimiento sobre los datos sin ninguna anotación (Madhoushi et al., 2015).

### 3.4.3. Enfoque Híbrido

Este enfoque trata de mejorar el desempeño de los clasificadores automáticos complementando los enfoques descritos hasta el momento por medio de la combinación de dos o más de sus técnicas. Por ejemplo, en este grupo se ubican los trabajos que experimentan con el uso de un clasificador SVM o Naive Bayes, los dos del tipo de aprendizaje automático supervisado, alimentado por puntuaciones realizadas por un proceso en base a léxico (Kolchyna et al., 2015)(Rathi et al., 2018). De la misma forma califican aquellos estudios que realizan minería de opiniones por medio de una combinación de SVM y redes neuronales (Rosa et al., 2017), ambos del área del aprendizaje automático supervisado y no supervisado, respectivamente. En los dos trabajos anteriores, los investigadores reportan haber obtenido resultados superiores en el caso de los métodos híbridos en comparación a las soluciones que se centraron únicamente en resolver el problema con un enfoque, ya sean basadas en léxico o en aprendizaje automático.

## 3.5. RECURSOS

Los recursos en esta sección fueron identificados tras una revisión de los trabajos presentados en la edición 2015 (Tabla 3) y edición 2018 (Tabla 4) del SemEval (International Workshop on Semantic Evaluation). Son una serie de talleres internacionales de investigación sobre procesamiento del lenguaje natural cuya misión es avanzar el estado actual del arte en análisis semántico, ayudar a crear conjuntos de datos anotados de alta calidad en una gama de problemas cada vez más desafiantes en la semántica del lenguaje natural, y otros fueron identificados durante la revisión sistemática.

Grupo	Trabajo
CLaC	(Özdemir & Bergler, 2015)
CPH	(McGillion et al., 2015)
DsUniPi	(Karanasou et al., 2015)
Elirf	(Giménez et al., 2015)
KELabTeam	(Nguyen et al., 2015)
LLT_PolyU	(Xu et al., 2015)

Grupo	Trabajo
LT3	(Van Hee et al., 2015)
PKU	(Han et al., 2015)
PRHLT	(Gupta & Gómez, 2015)
SHELLFBK	(Dragoni, 2015)
UPF	(Barbieri et al., 2015)
ValenTo	(Hernández Farías et al., 2015)

Tabla 3: Participantes del SemEval 2015 por orden alfabético

Grupo	Trabajo
#NonDicevoSulSerio	(Pamungkas & Patti, 2018)
ALANIS	(Swanberg et al., 2018)
Binarizer	(Nikhil & Srivastava, 2018)
CTSys	(Sherif et al., 2018)
ECNU	(Yin et al., 2018)
EliRF	(González et al., 2018)
HashCount	(Cho et al., 2018)
IIIDYT	(Marrese-Taylor et al., 2018)
INAOE	(Hernández Farías, Sánchez-Vega, et al., 2018)
Irony Detector	(Ahmed et al., 2018)
IronyMagnet	(Ghosh & Veale, 2018)
KLUEnicorn	(Dürlich, 2018)
Lancaster	(Dearden & Baron, 2018)
LDR	(Ghanem et al., 2018)
NEUROSENT	(Dragoni, 2018)
NIHRIO	(Vu et al., 2018)
NLPRL	(Rangwani et al., 2018)
NTUA	(Baziotis, Nikolaos, et al., 2018)
PunFields	(Mikhalkova et al., 2018)
Random Decision Syntax Trees	(San, 2018)
SSN MLRG1	(S et al., 2018)
THU_NGN	(Wu et al., 2018)
UWB	(Hercig, 2018)
ValenTO	(Hernández Farías, Patti, et al., 2018)
WLV	(Rohanian et al., 2018)
YNU-HPCC	(Peng et al., 2018)

Tabla 4: Participantes del SemEval 2018 por orden alfabético

En la Tabla 5 y Tabla 6 se exhiben un listado en orden alfabético de los equipos que participaron en una, o ambas tareas dedicadas al análisis de sentimientos y de detección de lenguaje figurativo en el SemEval, acompañados por el enfoque de su solución y el

modelo específico que fue implementado. Además, se ha realizado una identificación de los recursos utilizados en cada trabajo, según sus respectivos autores, para auxiliar en la tarea del análisis de sentimientos. Los recursos han sido separados en tres categorías para los participantes del SemEval 2015: Corpora, Recursos Léxicos y Herramientas/Técnicas de Análisis, para los participantes del SemEval 2018 en dos categorías: Corpora y Recursos Léxicos

<b>Grupo</b>	<b>Enfoque</b>	<b>Modelo</b>	<b>Corpora</b>	<b>Recursos Léxicos</b>	<b>Herramientas/ Técnicas de Análisis</b>
CLaC	Hybrid	- SVM - Decision Tree regressor	- Gezi Corpus	- AFINN - MPQA - BingLiu - Gezi	- Regression Technique (Cosine, MSE)
CPH	Hybrid	- Ridge Regression - PCA GMM Ridge Regression - Embeddings with Bayesian Ridge			- RegressionTechnique (Cosine, MSE)
DsUniPi	Supervised	- Naïve Bayes - Decision trees - SVM	- 9000 tweets tagged	- SentiWordNet	- ScikitLearn
Elirf	Supervised	- SVM	- Semeval2013 corpora	- AFINN - Pattern - SentiWordNet - Jeffrey - NRC	- ScikitLearn
KELabTeam	Supervised		- 8000tweets collected from Twitter tagged	- Figurative Language Analysisusing Statistical Approach	
LLT_PolyU	Hybrid	- Decision Tree regressor - SVR		- Stanford parser - Opinion Lexicon - AFINN - SentiWordNet	- WEKA - LIBSVM

<b>Grupo</b>	<b>Enfoque</b>	<b>Modelo</b>	<b>Corpora</b>	<b>Recursos Léxicos</b>	<b>Herramientas/ Técnicas de Análisis</b>
LT3	Hybrid	- SVM - Regression-based	-8,000 tweets tagged	- WordNet - DBpedia	- LIBSVM
PKU	Supervised	- SVM	- Semeval2013 corpora	- MPQA	- Ten-fold cross validation
PRHLT	Unsupervised	- Deep auto-encoder		Bags of character 3-grams.	- Classification Technique (Cosine Similarity) - Regression Technique (Cosine Similarity)
SHELLFBK	Supervised	- Information Retrieval (IR) - Retrieval Status Value (RSV)		- Stanford parser	- SHELLFBK system
UPF	Supervised	- Regression with a Random-Sub-Space using M5P	- SemEval 2015 Corpus - 8000 figurative tweets tagged - American National Corpus - VU Amsterdam Metaphors Corpus	- NRC Hash-tag Sentiment Lexicon - NRC Hashtag Emotion Lexicon - Depeche Mood - TwitIE - Word-Net - SentiWord Net3.0	- Weka
ValenTo	Supervised	- Naive Bayes - Decision Tree - SVM	- 9000 figurative tweets with sentiment scores	- AFINN - ANEW - DAL - HL - GI - SentiWordNet - SenticNet - LIWC - NRC	- Weka

Tabla 5: Participantes, Soluciones y recursos en SemEval 2015 por orden alfabético

<b>Grupo</b>	<b>Enfoque</b>	<b>Modelo</b>	<b>Corpora</b>	<b>Recursos Léxicos</b>
#NonDicevoSulSerio	Supervised	Support vector machine (SVM)	SemEval 2018 Twitter Corpus	- AFINN - Emolex - EmoSenticNet - Linguistic Inquiry and Word Count (LIWC) - Dictionary of Affect in Language (DAL) - Emoji Sentiment Ranking.
ALANIS	Supervised	- Logistic regression - Support vector machine (SVM) - Random Forest classifier		- WordNet - NLTK
Binarizer	Supervised	LSTM	4600 Tweets	- Tweeboparser - DeepMoji
CTSys	Supervised	- NaiveBayes Classifier. - Support vector machine (SVM) - Decision Trees - K-Nearest Neighbor Classifier	SemEval 2018 Twitter Corpus	- Word2Vec
ECNU	Supervised	- Logistic Regression - DecisionTree - NaiveBayes - KNN - RandomForest - Support vector machine (SVM) - SGD - AdaBoost - Bi-LSTM	- SemEval 2018 Twitter Corpus - 67 emotions labeled with positive and negative scores	- TweetTokenizer NLTK - NER - Word2Vec - GloVe - BingLiu lexicon - General Inquirer lexicon - IMD-B - MPQA - NRC Emotion SentimentLexicon - AFINN - NRC Hashtag SentimentLexicon - NRC Sentiment Lexicon
EliRF	Supervised	- CNN - LSTM	- 400 million English tweets - 87 million Spanish tweets	Ingles - AFFIN - Bing Liu's Opinion Lexicon - MPQA - SentiWordnet - NRC Emotion Lexicon - NRC Hashtag Emotion Lexicon - LIWC2007 - Word2Vec (Ingles y Español) Español - ISOL - MLSenticon
HashCount	Supervised	- CNN - BiLSTM	- 27 billion token Twitter	- NLTK

<b>Grupo</b>	<b>Enfoque</b>	<b>Modelo</b>	<b>Corpora</b>	<b>Recursos Léxicos</b>
		-Support vector machine (SVM)	- 4,792 tweets with emojis	
IIDYT	Supervised	- BiLSTM	- 4,792 tweets	- Natural Language Toolkit - NLTK TweetTokenizer - GloVe
INAOE	Supervised	- Support vector machine (SVM)	- 165,000 tweets	- Word Embeddings based classifier (wEmb) - Coverage-based ensemble (ENS cov) - Majority vote ensemble (ENS vot)
Irony Detector	Supervised	- Tree-based Pipeline Optimization Tool (TPOT)	- GitHub source dataset - 3000 tweets	- SenticNet - SMOTE
IronyMagnet	Supervised	- LSTM	- 4618 tweets	- GloVe word embedding
KLUEnicorn	Supervised	- Naive Bayes	- 3,834 tweets	- Unix wordlist - Ark TweetNLP - TfidfVectorizer(scikitLearn) - AFINN - SentiWordNet - Stanford CoreNLP
Lancaster	Supervised	- Support vector machine (SVM)		- NLTK - NLTK Tweet Tokeniser - Linear SVC (scikitLearn)
LDR	Supervised	- Low dimensional representation (LDR) - DecisionStump classifier - Majority Vote	- SemEval2018 Twitter corpus - 67,800 tweets	
NEUROSENT	Supervised	- Support Vector Machine (SVM) - Naive Bayes - Maximum Entropy - CNN - NeuroSent	SNAP dataset	- Stanford CoreNLP Toolkit - Word2Vec
NIHRIO	Supervised	- Multilayer Perceptron (MLP) - LSTM - CNN	4,618 tweets	-NLTK toolkit - GloVe - Normalization dictionary
NLPRL	Hybrid	- CNN - Linguistic features	4,618 tweets	- XGBoost Classifier - SMOTE - SentiStrength - GloVe - WordNet - TextBlob - DeepMoji
NTUA	Supervised	- BiLSTM - RNN	550 million Tweets	- word2vec - ekphrasis tool

<b>Grupo</b>	<b>Enfoque</b>	<b>Modelo</b>	<b>Corpora</b>	<b>Recursos Léxicos</b>
PunFields	Hybrid	- Bag of words - Support vector machine (SVM)	tweets from other SemEval competitions	- NLTK
Random Decision Syntax Trees	Supervised	- LSTM - RNN	100 billion words Google News Dataset	- Word2Vec - Emoji2Vec - SentiWordNet
SSN MLRG1	Supervised	- Rule based approach - MultiLayer Perceptron (MLP)	4792 tweets	- WordNet Lemmatizer - NLTKtoolkit
THU_NGN	Supervised	LSTM	4629 tweets	- TweetToLexiconFeatureVector - TweetToSentiStrengthFeatureVector
UWB	Supervised	- Maximum Entropy classifier	4618 tweets	- Character n-grams (ChN ) - Bag of Morphological features (BoM) - Bag of Parse Tree Tags (BoT) - First Words (FW) - Last Words (LW) - N-gram Shape (NSh) - Root Bag of Words (R-BoW) - TF-IDF - Verb Bag of Words
ValenTO	Supervised	- Support vector machine (SVM) - Decision Tree	SemEval 2018 Corpus	- General Inquirer - EffectWordNet - Subjectivity lexicon - EmoLex - AFINN - SWN - Semantic Orientation lexicon - SenticNet - EmoSenticNet - ANEW
WLV	Supervised	- Logistic regression (LR) - Support vector machine (SVM)	SemEval 2018 Corpus (With Emoticons)	- NLTK - Ekphrasis toolkit
YNU-HPCC	Supervised	LSTM	3834 Tweets	- GloVe

Tabla 6: Participantes, Soluciones y recursos en SemEval 2018 por orden alfabético

## 4. CONCLUSIONES

En este capítulo se expone, en un primer punto, un resumen del trabajo presente y sus logros (sección 4.1). Para finalizar, se declaran posibles líneas de investigación a futuro que se desprenden del análisis realizado en las secciones anteriores (sección 4.2).

### 4.1. RESUMEN DE LOS RESULTADOS DEL TRABAJO

En el presente trabajo se ha llevado a cabo una revisión del estado del arte en el dominio del análisis de sentimientos para la detección de lenguaje figurativo con emoticones, específicamente en el ambiente de la red social y servicio de microblogging de Twitter.

En un inicio, se ha dado una explicación de la evolución del intercambio de textos subjetivos y el estado actual en el contexto de una red social determinada, justificado por su creciente importancia y utilidad en la vida de sus usuarios y de las empresas y organizaciones interesadas en la explotación de la información que generan. Como parte del análisis, se han identificado características que hacen único el desafío del análisis de sentimientos en Twitter y sobre todo para la detección de lenguaje figurativo, por ejemplo, la abundancia de mensajes cortos, el uso de un lenguaje informal, con slang, en múltiples idiomas, el uso de características estilísticas como emoticones, hashtag, videos. Los retos mencionados han dado forma a los procesos actuales para la implementación de soluciones. Es en este punto en el que se describen los enfoques principales encontrados en la mayoría de los trabajos de investigación que engloban el estado del arte: el enfoque basado en léxico, los enfoques basados en aprendizaje automático, ya sean supervisados, no supervisados, enfoques híbridos y otros enfoques novedosos que no se logran clasificar en las categorías anteriores. También se ha realizado una identificación de recursos empleados para la tarea del análisis de sentimientos, decidiendo investigarlos bajo los grupos de corpora, recursos léxicos y herramientas de análisis. Es durante este análisis en el que se exploran los trabajos, uno de los más prominentes talleres para el análisis de sentimientos en Twitter: SemEval en el cual se realiza un histórico de los trabajos presentados durante el Task 11 de la edición 2015 del SemEval para la detección de lenguaje figurativo y al más reciente Task 3 de la edición 2018 del SemEval donde realizan más estudios y avances para la detección de lenguaje figurativo en los cuales incluyen dataset con emoticones, recursos léxicos para emoticones como Deepmoji para detección de características estilísticas.

## **4.2. FUTURAS LÍNEAS DE INVESTIGACIÓN**

De las tablas se pueden apreciar puntos de mejora en lo relacionado análisis de sentimientos en español a través de emoticones en twitter para detección de sarcasmo:

- Expandir el análisis realizado a otros trabajos en la bibliografía del análisis de sentimientos en Twitter con emoticones, pudiendo explorar soluciones independientes, trabajos presentados en competencias similares o participaciones en ediciones pasadas o futuras del SemEval.
- Definir y analizar nuevas dimensiones de recursos adicionales a las categorías reconocidas en este trabajo.
- Relacionado a los recursos léxicos utilizados ampliamente en las propuestas de los investigadores, se observa que pocos recursos de este tipo toman en cuenta el manejo de emoticones entre los elementos que los conforman, por lo cual se justificaría incursionar en un trabajo de investigación y creación de estos recursos.
- Dentro de los recursos analizados en cuanto el manejo de léxicos en español para la detección de sarcasmos, son muy pocos los que utilizan este lenguaje. Si bien hay un

análisis y varias herramientas para detección de sarcasmo, en su gran mayoría son para el idioma inglés; por esta razón, se justifica un trabajo similar que contemple el uso léxicos en español para detección de sarcasmos.

Finalmente se indica que los clasificadores pueden variar ampliamente dependiendo de la calidad de los recursos léxicos y las herramientas para el pre-procesamiento de los datos involucrados. En este contexto se considera pertinente focalizar la atención y el esfuerzo en el área de los recursos para la detección de sarcasmo en el análisis de sentimientos con emoticones. La falta de variedad en los recursos es una problemática que ha sido identificada por parte de la comunidad dedicada al estudio del análisis de sentimientos en la detección de sarcasmo en Twitter en español, por lo que la creación de nuevos recursos exclusivos para el idioma podría reducir la brecha entre los materiales disponibles para el español y lenguajes como el inglés, los cuales cuentan con un gran número de diccionarios, corpora y otras herramientas de calidad para el desarrollo de la tarea como también la aplicación de las tecnologías, técnicas y recursos en el idioma español.

#### **4.3. PUBLICACIONES PRESENTADAS**

- XI Congreso Internacional sobre Aplicación de Tecnologías de la Información y Comunicaciones Avanzadas (ATICA 2020)

#### **5. REFERENCIAS**

A., V., & Sonawane, S. S. (2016). Sentiment Analysis of Twitter Data: A Survey of Techniques.

*International Journal of Computer Applications*, 139(11), 5–15.

<https://doi.org/10.5120/ijca2016908625>

Ahmed, U., Zafar, L., Qayyum, F., & Arshad Islam, M. (2018). Irony Detector at SemEval-2018

Task 3: Irony Detection in English Tweets using Word Graph. *Proceedings of The 12th*

*International Workshop on Semantic Evaluation*, 581–586.

<https://doi.org/10.18653/v1/S18-1095>

Barbieri, F., Ronzano, F., & Saggion, H. (2015). UPF-taIn: SemEval 2015 Tasks 10 and 11.

Sentiment Analysis of Literal and Figurative Language in Twitter. *Proceedings of the 9th*

*International Workshop on Semantic Evaluation (SemEval 2015)*, 704–708.

<https://doi.org/10.18653/v1/S15-2119>

Bautin, M. (2009). *International Sentiment Analysis for News and Blogs*. 8.

- Baviera, T. (2017). *Técnicas para el análisis del sentimiento en Twitter: Aprendizaje Automático Supervisado y SentiStrength*. 18.
- 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. *ArXiv:1804.06658 [Cs]*. <http://arxiv.org/abs/1804.06658>
- Baziotis, C., Nikolaos, A., Papalampidi, P., Kolovou, A., Paraskevopoulos, G., Ellinas, N., & Potamianos, A. (2018). NTUA-SLP at SemEval-2018 Task 3: Tracking Ironic Tweets using Ensembles of Word and Character Level Attentive RNNs. *Proceedings of The 12th International Workshop on Semantic Evaluation*, 613–621. <https://doi.org/10.18653/v1/S18-1100>
- Bharti, S. K., Babu, K. S., & Jena, S. K. (2015). Parsing-based Sarcasm Sentiment Recognition in Twitter Data. *Proceedings of the 2015 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining 2015 - ASONAM '15*, 1373–1380. <https://doi.org/10.1145/2808797.2808910>
- Bharti, S. K., Naidu, R., & Babu, K. S. (2017). Hyperbolic Feature-based Sarcasm Detection in Tweets: A Machine Learning Approach. *2017 14th IEEE India Council International Conference (INDICON)*, 1–6. <https://doi.org/10.1109/INDICON.2017.8487712>
- Bravo-Marquez, F., Mendoza, M., & Poblete, B. (2014). Meta-level sentiment models for big social data analysis. *Knowledge-Based Systems*, 69, 86–99. <https://doi.org/10.1016/j.knosys.2014.05.016>
- Chamlertwat, W., Bhattarakosol, P., Rungkasiri, T., & Haruechaiyasak, C. (n.d.). *Discovering Consumer Insight from Twitter via Sentiment Analysis*. 20.
- Chen, Y., Yuan, J., You, Q., & Luo, J. (2018). Twitter Sentiment Analysis via Bi-sense Emoji Embedding and Attention-based LSTM. *2018 ACM Multimedia Conference on*

- Multimedia Conference - MM '18*, 117–125.  
<https://doi.org/10.1145/3240508.3240533>
- Cho, W. I., Kang, W. H., & Kim, N. S. (2018). HashCount at SemEval-2018 Task 3: Concatenative Featurization of Tweet and Hashtags for Irony Detection. *Proceedings of The 12th International Workshop on Semantic Evaluation*, 546–552.  
<https://doi.org/10.18653/v1/S18-1089>
- Dave, K., Lawrence, S., & Pennock, D. M. (2003). *Mining the Peanut Gallery: Opinion Extraction and Semantic Classification of Product Reviews*. 10.
- Davidov, D., Tsur, O., & Rappoport, A. (2010). *Semi-Supervised Recognition of Sarcastic Sentences in Twitter and Amazon*. 10.
- Dearden, E., & Baron, A. (2018). Lancaster at SemEval-2018 Task 3: Investigating Ironic Features in English Tweets. *Proceedings of The 12th International Workshop on Semantic Evaluation*, 587–593. <https://doi.org/10.18653/v1/S18-1096>
- Devika, M. D., Sunitha, C., & Ganesh, A. (2016). Sentiment Analysis: A Comparative Study on Different Approaches. *Procedia Computer Science*, 87, 44–49.  
<https://doi.org/10.1016/j.procs.2016.05.124>
- Dragoni, M. (2018). NEUROSENT-PDI at SemEval-2018 Task 3: Understanding Irony in Social Networks Through a Multi-Domain Sentiment Model. *Proceedings of The 12th International Workshop on Semantic Evaluation*, 512–519.  
<https://doi.org/10.18653/v1/S18-1083>
- Dragoni, M. (2015). SHELLFBK: An Information Retrieval-based System For Multi-Domain Sentiment Analysis. *Proceedings of the 9th International Workshop on Semantic Evaluation (SemEval 2015)*, 502–509. <https://doi.org/10.18653/v1/S15-2084>
- Dürlich, L. (2018). KLUEnicorn at SemEval-2018 Task 3: A Naive Approach to Irony Detection. *Proceedings of The 12th International Workshop on Semantic Evaluation*, 607–612.  
<https://doi.org/10.18653/v1/S18-1099>

- Estadísticas y datos de Twitter 2020. (2020, January 4). *Website Hosting Rating*.  
<https://www.websitehostingrating.com/es/twitter-statistics/>
- Farias, D. I. H., & Rosso, P. (2017). Irony, Sarcasm, and Sentiment Analysis. In *Sentiment Analysis in Social Networks* (pp. 113–128). Elsevier. <https://doi.org/10.1016/B978-0-12-804412-4.00007-3>
- Filik, R., Turcan, A., Thompson, D., Harvey, N., Davies, H., & Turner, A. (2016). Sarcasm and emoticons: Comprehension and emotional impact. *Quarterly Journal of Experimental Psychology*, 69(11), 2130–2146. <https://doi.org/10.1080/17470218.2015.1106566>
- Ghanem, B., Rangel, F., & Rosso, P. (2018). LDR at SemEval-2018 Task 3: A Low Dimensional Text Representation for Irony Detection. *Proceedings of The 12th International Workshop on Semantic Evaluation*, 531–536. <https://doi.org/10.18653/v1/S18-1086>
- Ghiassi, M., Skinner, J., & Zimbra, D. (2013). Twitter brand sentiment analysis: A hybrid system using n-gram analysis and dynamic artificial neural network. *Expert Systems with Applications*, 40(16), 6266–6282. <https://doi.org/10.1016/j.eswa.2013.05.057>
- Ghosh, A., Li, G., Veale, T., Rosso, P., Shutova, E., Barnden, J., & Reyes, A. (2015). SemEval-2015 Task 11: Sentiment Analysis of Figurative Language in Twitter. *Proceedings of the 9th International Workshop on Semantic Evaluation (SemEval 2015)*, 470–478.  
<https://doi.org/10.18653/v1/S15-2080>
- Ghosh, A., & Veale, T. (2018). IronyMagnet at SemEval-2018 Task 3: A Siamese network for Irony detection in Social media. *Proceedings of The 12th International Workshop on Semantic Evaluation*, 570–575. <https://doi.org/10.18653/v1/S18-1093>
- Giachanou, A., & Crestani, F. (2016). Like It or Not: A Survey of Twitter Sentiment Analysis Methods. *ACM Computing Surveys*, 49(2), 1–41. <https://doi.org/10.1145/2938640>
- Giménez, M., Pla, F., & Hurtado, L.-F. (2015). ELiRF: A SVM Approach for SA tasks in Twitter at SemEval-2015. *Proceedings of the 9th International Workshop on Semantic Evaluation (SemEval 2015)*, 574–581. <https://doi.org/10.18653/v1/S15-2096>

- González, J.-Á., Hurtado, L.-F., & Pla, F. (2018). ELiRF-UPV at SemEval-2018 Tasks 1 and 3: Affect and Irony Detection in Tweets. *Proceedings of The 12th International Workshop on Semantic Evaluation*, 565–569. <https://doi.org/10.18653/v1/S18-1092>
- Gupta, P., & Gómez, J. A. (2015). PRHLT: Combination of Deep Autoencoders with Classification and Regression Techniques for SemEval-2015 Task 11. *Proceedings of the 9th International Workshop on Semantic Evaluation (SemEval 2015)*, 689–693. <https://doi.org/10.18653/v1/S15-2116>
- Han, X., Li, B., Ma, J., Zhang, Y., Ou, G., Wang, T., & Wong, K. (2015). UIR-PKU: Twitter-OpinMiner System for Sentiment Analysis in Twitter at SemEval 2015. *Proceedings of the 9th International Workshop on Semantic Evaluation (SemEval 2015)*, 664–668. <https://doi.org/10.18653/v1/S15-2111>
- Hassan, E. A., Gayar, N. E., & Moustafa, M. G. (2010). Emotions analysis of speech for call classification. *2010 10th International Conference on Intelligent Systems Design and Applications*, 242–247. <https://doi.org/10.1109/ISDA.2010.5687259>
- He, Y. (2012). Incorporating Sentiment Prior Knowledge for Weakly Supervised Sentiment Analysis. *ACM Transactions on Asian Language Information Processing*, 11(2), 1–19. <https://doi.org/10.1145/2184436.2184437>
- Hercig, T. (2018). UWB at SemEval-2018 Task 3: Irony detection in English tweets. *Proceedings of The 12th International Workshop on Semantic Evaluation*, 520–524. <https://doi.org/10.18653/v1/S18-1084>
- Hernández Farías, D. I., Patti, V., & Rosso, P. (2018). ValenTO at SemEval-2018 Task 3: Exploring the Role of Affective Content for Detecting Irony in English Tweets. *Proceedings of The 12th International Workshop on Semantic Evaluation*, 643–648. <https://doi.org/10.18653/v1/S18-1105>
- Hernández Farías, D. I., Sánchez-Vega, F., Montes-y-Gómez, M., & Rosso, P. (2018). INAOE-UPV at SemEval-2018 Task 3: An Ensemble Approach for Irony Detection in Twitter.

- Proceedings of The 12th International Workshop on Semantic Evaluation*, 594–599.  
<https://doi.org/10.18653/v1/S18-1097>
- Hernández Farías, D. I., Sulis, E., Patti, V., Ruffo, G., & Bosco, C. (2015). ValenTo: Sentiment Analysis of Figurative Language Tweets with Irony and Sarcasm. *Proceedings of the 9th International Workshop on Semantic Evaluation (SemEval 2015)*, 694–698.  
<https://doi.org/10.18653/v1/S15-2117>
- Hogenboom, A., Bal, D., Frasincar, F., Bal, M., de Jong, F., & Kaymak, U. (2013). Exploiting emoticons in sentiment analysis. *Proceedings of the 28th Annual ACM Symposium on Applied Computing - SAC '13*, 703. <https://doi.org/10.1145/2480362.2480498>
- Hurtado, L.-F., & Pla, F. (2017). *ELiRF-UPV en TASS 2017: Análisis de Sentimientos en Twitter basado en Aprendizaje Profundo*. 6.
- Kamps, J., Marx, M., Mokken, R. J., & de Rijke, M. (2004). *Using WordNet to Measure Semantic Orientations of Adjectives*. 4.
- Karanasou, M., Doukeridis, C., & Halkidi, M. (2015). DsUniPi: An SVM-based Approach for Sentiment Analysis of Figurative Language on Twitter. *Proceedings of the 9th International Workshop on Semantic Evaluation (SemEval 2015)*, 709–713.  
<https://doi.org/10.18653/v1/S15-2120>
- Karthik, V., Nair, D., & J, A. (2018). Opinion Mining on Emojis using Deep Learning Techniques. *Procedia Computer Science*, 132, 167–173.  
<https://doi.org/10.1016/j.procs.2018.05.200>
- Kolchyna, O., Souza, T. T. P., Treleaven, P., & Aste, T. (2015). Twitter Sentiment Analysis: Lexicon Method, Machine Learning Method and Their Combination. *ArXiv:1507.00955 [Cs, Stat]*. <http://arxiv.org/abs/1507.00955>
- Liu, B. (2010). Sentiment Analysis and Subjectivity. *Handbook of Natural Language Processing, Second Edition*, 38.

- Liu, Z., Dong, X., Guan, Y., & Yang, J. (2013). *Reserved Self-training: A Semi-supervised Sentiment Classification Method for Chinese Microblogs*. 8.
- Lu, X., Mao, X., Lan, M., & Wu, Y. (2018). ECNU at SemEval-2018 Task 2: Leverage Traditional NLP Features and Neural Networks Methods to Address Twitter Emoji Prediction Task. *Proceedings of The 12th International Workshop on Semantic Evaluation*, 433–437. <https://doi.org/10.18653/v1/S18-1068>
- Madhoushi, Z., Hamdan, A. R., & Zainudin, S. (2015). Sentiment analysis techniques in recent works. *2015 Science and Information Conference (SAI)*, 288–291. <https://doi.org/10.1109/SAI.2015.7237157>
- Marrese-Taylor, E., Ilic, S., Balazs, J., Prendinger, H., & Matsuo, Y. (2018). IIIDYT at SemEval-2018 Task 3: Irony detection in English tweets. *Proceedings of The 12th International Workshop on Semantic Evaluation*, 537–540. <https://doi.org/10.18653/v1/S18-1087>
- McGillion, S., Martínez Alonso, H., & Plank, B. (2015). CPH: Sentiment analysis of Figurative Language on Twitter #easypeasy #not. *Proceedings of the 9th International Workshop on Semantic Evaluation (SemEval 2015)*, 699–703. <https://doi.org/10.18653/v1/S15-2118>
- Mikhalkova, E., Karyakin, Y., Voronov, A., Grigoriev, D., & Leoznov, A. (2018). PunFields at SemEval-2018 Task 3: Detecting Irony by Tools of Humor Analysis. *Proceedings of The 12th International Workshop on Semantic Evaluation*, 541–545. <https://doi.org/10.18653/v1/S18-1088>
- Naderi, H., Haji Soleimani, B., Mohammad, S., Kiritchenko, S., & Matwin, S. (2018). DeepMiner at SemEval-2018 Task 1: Emotion Intensity Recognition Using Deep Representation Learning. *Proceedings of The 12th International Workshop on Semantic Evaluation*, 305–312. <https://doi.org/10.18653/v1/S18-1045>
- Nguyen, H. L., Nguyen, T. D., Hwang, D., & Jung, J. J. (2015). KELabTeam: A Statistical Approach on Figurative Language Sentiment Analysis in Twitter. *Proceedings of the 9th*

- International Workshop on Semantic Evaluation (SemEval 2015)*, 679–683.  
<https://doi.org/10.18653/v1/S15-2114>
- Nikhil, N., & Srivastava, M. M. (2018). Binarizer at SemEval-2018 Task 3: Parsing dependency and deep learning for irony detection. *ArXiv:1805.01112 [Cs]*.  
<http://arxiv.org/abs/1805.01112>
- Özdemir, C., & Bergler, S. (2015). CLaC-SentiPipe: SemEval2015 Subtasks 10 B,E, and Task 11. *Proceedings of the 9th International Workshop on Semantic Evaluation (SemEval 2015)*, 479–485. <https://doi.org/10.18653/v1/S15-2081>
- Pamungkas, E. W., & Patti, V. (2018). #NonDicevoSulSerio at SemEval-2018 Task 3: Exploiting Emojis and Affective Content for Irony Detection in English Tweets. *Proceedings of The 12th International Workshop on Semantic Evaluation*, 649–654.  
<https://doi.org/10.18653/v1/S18-1106>
- Pang, B., & Lee, L. (2008). *Using Very Simple Statistics for Review Search: An Exploration*. 4.
- Park, J. H., Xu, P., & Fung, P. (2018). PlusEmo2Vec at SemEval-2018 Task 1: Exploiting emotion knowledge from emoji and #hashtags. *ArXiv:1804.08280 [Cs]*.  
<http://arxiv.org/abs/1804.08280>
- Peng, B., Wang, J., & Zhang, X. (2018). YNU-HPCC at SemEval-2018 Task 3: Ensemble Neural Network Models for Irony Detection on Twitter. *Proceedings of The 12th International Workshop on Semantic Evaluation*, 622–627. <https://doi.org/10.18653/v1/S18-1101>
- Prager, J. (2006). Open-Domain Question–Answering. *Foundations and Trends® in Information Retrieval*, 1(2), 91–231. <https://doi.org/10.1561/1500000001>
- Punde, P. K., & Wagh, R. S. (2018). A Survey Paper on Different Approaches for Sentiment Analysis. *2018 Second International Conference on Electronics, Communication and Aerospace Technology (ICECA)*, 203–207. <https://doi.org/10.1109/ICECA.2018.8474791>
- Rangwani, H., Kulshreshtha, D., & Kumar Singh, A. (2018). NLPRL-IITBHU at SemEval-2018 Task 3: Combining Linguistic Features and Emoji pre-trained CNN for Irony Detection in

- Tweets. *Proceedings of The 12th International Workshop on Semantic Evaluation*, 638–642. <https://doi.org/10.18653/v1/S18-1104>
- Rathi, M., Malik, A., Varshney, D., Sharma, R., & Mendiratta, S. (2018). Sentiment Analysis of Tweets Using Machine Learning Approach. *2018 Eleventh International Conference on Contemporary Computing (IC3)*, 1–3. <https://doi.org/10.1109/IC3.2018.8530517>
- Rohanian, O., Taslimipoor, S., Evans, R., & Mitkov, R. (2018). WLV at SemEval-2018 Task 3: Dissecting Tweets in Search of Irony. *Proceedings of The 12th International Workshop on Semantic Evaluation*, 553–559. <https://doi.org/10.18653/v1/S18-1090>
- Rosa, A., Chiruzzo, L., Etcheverry, M., & Castro, S. (2017). *RETUYT en TASS 2017: Análisis de Sentimiento de Tweets en Español utilizando SVM y CNN*. 7.
- Rosenthal, S., Farra, N., & Nakov, P. (2019). SemEval-2017 Task 4: Sentiment Analysis in Twitter. *ArXiv:1912.00741 [Cs]*. <http://arxiv.org/abs/1912.00741>
- S, R., S, A. D., Rajendram, S. M., & T T, M. (2018). SSN MLRG1 at SemEval-2018 Task 3: Irony Detection in English Tweets Using MultiLayer Perceptron. *Proceedings of The 12th International Workshop on Semantic Evaluation*, 633–637. <https://doi.org/10.18653/v1/S18-1103>
- San, A. (2018). Random Decision Syntax Trees at SemEval-2018 Task 3: LSTMs and Sentiment Scores for Irony Detection. *Proceedings of The 12th International Workshop on Semantic Evaluation*, 560–564. <https://doi.org/10.18653/v1/S18-1091>
- Sherif, M., Mamdouh, S., & Ghazi, W. (2018). CTSys at SemEval-2018 Task 3: Irony in Tweets. *Proceedings of The 12th International Workshop on Semantic Evaluation*, 576–580. <https://doi.org/10.18653/v1/S18-1094>
- Swanberg, K., Mirza, M., Pedersen, T., & Wang, Z. (2018). ALANIS at SemEval-2018 Task 3: A Feature Engineering Approach to Irony Detection in English Tweets. *Proceedings of The 12th International Workshop on Semantic Evaluation*, 507–511. <https://doi.org/10.18653/v1/S18-1082>

- Thakkar, H., & Patel, D. (2010). *Approaches for Sentiment Analysis on Twitter: A State-of-Art study*. 8.
- The Unicode Standard, Version 13.0*. (n.d.). 8.
- Thompson, D., & Filik, R. (2016). Sarcasm in Written Communication: Emoticons are Efficient Markers of Intention: Sarcasm in writing: Emoticons mark intention. *Journal of Computer-Mediated Communication*, 21(2), 105–120.  
<https://doi.org/10.1111/jcc4.12156>
- Tomihira, T., Otsuka, A., Yamashita, A., & Satoh, T. (2018). What Does Your Tweet Emotion Mean?: Neural Emoji Prediction for Sentiment Analysis. *Proceedings of the 20th International Conference on Information Integration and Web-Based Applications & Services - IIWAS2018*, 289–296. <https://doi.org/10.1145/3282373.3282406>
- Turney, P. D. (2001). Thumbs up or thumbs down?: Semantic orientation applied to unsupervised classification of reviews. *Proceedings of the 40th Annual Meeting on Association for Computational Linguistics - ACL '02*, 417.  
<https://doi.org/10.3115/1073083.1073153>
- Twitter, A. R., Ikuhiro Ihara. (2017, August 26). *Giving you more characters to express yourself* [Blog]. Giving You More Characters to Express Yourself.  
[https://blog.twitter.com/official/en\\_us/topics/product/2017/Giving-you-more-characters-to-express-yourself.html](https://blog.twitter.com/official/en_us/topics/product/2017/Giving-you-more-characters-to-express-yourself.html)
- Twitter, Inc. - Home*. (n.d.). Retrieved August 12, 2020, from  
<https://investor.twitterinc.com/home/default.aspx>
- Van Hee, C., Lefever, E., & Hoste, V. (2015). LT3: Sentiment Analysis of Figurative Tweets: piece of cake #NotReally. *Proceedings of the 9th International Workshop on Semantic Evaluation (SemEval 2015)*, 684–688. <https://doi.org/10.18653/v1/S15-2115>
- Vu, T., Nguyen, D. Q., Vu, X.-S., Nguyen, D. Q., Catt, M., & Trenell, M. (2018). NIHRIO at SemEval-2018 Task 3: A Simple and Accurate Neural Network Model for Irony

- Detection in Twitter. *Proceedings of The 12th International Workshop on Semantic Evaluation*, 525–530. <https://doi.org/10.18653/v1/S18-1085>
- Wang, H., & Castanon, J. A. (2015). Sentiment expression via emoticons on social media. *2015 IEEE International Conference on Big Data (Big Data)*, 2404–2408. <https://doi.org/10.1109/BigData.2015.7364034>
- Wehrmann, J., Becker, W., Cagnini, H. E. L., & Barros, R. C. (2017). A character-based convolutional neural network for language-agnostic Twitter sentiment analysis. *2017 International Joint Conference on Neural Networks (IJCNN)*, 2384–2391. <https://doi.org/10.1109/IJCNN.2017.7966145>
- Wu, C., Wu, F., Wu, S., Liu, J., Yuan, Z., & Huang, Y. (2018). THU\_NGN at SemEval-2018 Task 3: Tweet Irony Detection with Densely connected LSTM and Multi-task Learning. *Proceedings of The 12th International Workshop on Semantic Evaluation*, 51–56. <https://doi.org/10.18653/v1/S18-1006>
- Xu, H., Santus, E., Laszlo, A., & Huang, C.-R. (2015). LLT-PolyU: Identifying Sentiment Intensity in Ironic Tweets. *Proceedings of the 9th International Workshop on Semantic Evaluation (SemEval 2015)*, 673–678. <https://doi.org/10.18653/v1/S15-2113>
- Yamamoto, Y., Kumamoto, T., & Nadamoto, A. (2014). Role of Emoticons for Multidimensional Sentiment Analysis of Twitter. *Proceedings of the 16th International Conference on Information Integration and Web-Based Applications & Services - liWAS '14*, 107–115. <https://doi.org/10.1145/2684200.2684283>
- Yin, Z., Wang, F., Lan, M., & Wang, W. (2018). ECNU at SemEval-2018 Task 3: Exploration on Irony Detection from Tweets via Machine Learning and Deep Learning Methods. *Proceedings of The 12th International Workshop on Semantic Evaluation*, 600–606. <https://doi.org/10.18653/v1/S18-1098>
- Zhang, L., Pei, S., Deng, L., Han, Y., Zhao, J., & Hong, F. (2013). Microblog sentiment analysis based on emoticon networks model. *Proceedings of the Fifth International Conference*

*on Internet Multimedia Computing and Service - ICIMCS '13, 134.*

<https://doi.org/10.1145/2499788.2499832>