

## Minería de opiniones aplicada a la evaluación docente de la Universidad Autónoma de Ciudad Juárez

Rafael Jiménez Castro, Vicente García, Rogelio Florencia Juárez,  
Gilberto Rivera Zarate, Francisco López Orozco

Universidad Autónoma de Ciudad Juárez,  
División Multidisciplinaria en Ciudad Universitaria,  
México

al117955@alumnos.uacj.mx

{vicente.jimenez, rogelio.florencia, gilberto.rivera, francisco.orozco}@uacj.mx

**Resumen.** La Universidad Autónoma de Ciudad Juárez lleva a cabo una evaluación docente cada semestre con la finalidad de encontrar las fortalezas, debilidades y áreas de oportunidad entre los profesores. En este artículo mostramos como la minería de opiniones puede ser útil para etiquetar comentarios de estudiantes en positivos y negativos. Para ello, se construyó una base de datos reales construida a partir opiniones obtenidas de cinco profesores de la UACJ a lo largo de cuatro años, abarcando un total de 20 materias. Sobre la base de datos se utilizaron técnicas de procesamiento de lenguaje natural para normalizar los datos contenidos en ella. Resultados experimentales utilizando los clasificadores 1-NN y SMO mostraron que es posible etiquetar de forma automática comentarios en positivos y negativos con una exactitud del 79.46%.

**Palabras clave:** minería de opiniones, evaluación docente, estudiantes, clasificación.

### Opinion Mining for Instructor Evaluations at the Autonomous University of Ciudad Juarez

**Abstract.** The Universidad Autónoma de Ciudad Juárez performs an instructor evaluation each semester to find strengths, weaknesses, and areas of opportunity during the teaching process. In this article we show how opinion mining can be useful for labeling student comments as positives and negatives. For this, a database was created using real opinions obtained from 5 professors of the UACJ over 4 years, covering a total of 20 subjects. Natural language processing techniques were used on the database to normalize its data. Experimental results using 1-NN and SMO classifiers shows that it is possible to automatically label positive and negative comments with an accuracy of 79.46%.

**Keywords:** opinion mining, instructor evaluation, students, classification.

## 1. Introducción

Las opiniones son actividades centrales para casi todos los seres humanos y cuando tenemos que tomar decisiones es importante saber la valoración de los demás, por ello, las opiniones son una fuente valiosa de información. El análisis de sentimientos o minería de opiniones es un área que clasifica de forma automática los sentimientos, expresados por una persona sobre un objeto determinado, en positivos, negativos o neutros [1]. La minería de opiniones es utilizada por las compañías para conocer las percepciones que tienen los clientes sobre sus productos o servicios, así como para identificar áreas de oportunidad o mejorar las estrategias de mercadotecnia utilizadas [2].

La evaluación docente que realiza la Universidad Autónoma de Ciudad Juárez (UACJ) cada semestre es un método por el cual, se registra la opinión escrita de los estudiantes para identificar las fortalezas, debilidades y áreas de oportunidad en el desempeño de los profesores [3].

Durante el periodo de evaluación, la jefatura de evaluación docente pone a disposición de los alumnos una plataforma en la que, además de otras métricas, aparecen dos casillas para que puedan escribir de forma libre comentarios positivos y negativos sobre sus maestros durante el semestre en curso. En este proceso, el estudiante erróneamente escribe comentarios negativos en la casilla de positivos y viceversa, así como una combinación de ambos. Esto ocasiona que la evaluación docente no dé una fácil retroalimentación al docente al estar todos los comentarios positivos y negativos mezclados.

En este artículo se emplean técnicas de análisis de sentimientos a las opiniones emitidas por los estudiantes, con la finalidad de categorizar los comentarios en positivos y negativos. Para ello, se construyó una base de datos con opiniones de estudiantes emitidas durante cuatro años, las cuales fueron categorizadas manualmente en positivas y negativas, para posteriormente construir vectores de características, los cuales fueron empleados en el entrenamiento de una máquina de soporte vectorial (SMO) y el algoritmo de los k-vecinos más cercanos (1-NN). Un trabajo en la misma línea fue presentado por Gutiérrez et al. [4], en el cual se analiza el desempeño de los maestros utilizando reseñas que hacían por tuits los alumnos de la Universidad Politécnica de Aguascalientes.

El artículo está organizado de la siguiente manera. La Sección 2 se describe brevemente los trabajos relacionados en minería de opiniones. En la Sección 3, la metodología empleada en el desarrollo de la investigación. En la Sección 4 se muestra la configuración experimental adoptada. Posteriormente, en la Sección 5 se describen y discuten los resultados. Finalmente, en la Sección 6 se concluye y proponen líneas futuras de investigación.

## 2. Trabajos relacionados

La minería de opiniones tiene un gran campo de aplicación. Existen compañías grandes y pequeñas que sólo se dedican a la minería de opiniones [5,6,7,8]; otras, la utilizan como una parte fundamental de sus operaciones [9,10,11].

## 2.1. Reseñas en la web

La minería de opiniones en la web [12] se emplea para automatizar el mantenimiento de reseñas y opiniones, ya que las redes sociales son una fuente rica de información a gran escala. Los usuarios las utilizan para expresar sus sentimientos sobre varios temas, muchos de ellos, sobre productos. Estos comentarios se pueden clasificar en positivos, negativos o neutros y de ellos se puede extraer información valiosa para los reportes de mercado de las compañías. Algunos ejemplos de aplicaciones en el mercado son:

- *Meaning cloud* [13]: Es una aplicación en línea que ofrece los servicios de clasificación de textos, extracción de temas, análisis de sentimiento, identificación de idioma, tematización y análisis morfosintáctico, reputación corporativa y *clustering* de texto. La aplicación tiene soporte para varios lenguajes, entre ellos el inglés, español, francés, italiano, portugués y catalán. La forma en la que funciona Meaning Cloud es por medio un *plugin* de Excel o por medio de un API a su servicio en línea que contiene todas las librerías en un solo paquete para realizar la extracción de opiniones.
- Vivek Sentiment [14]: Esta aplicación web fue creada utilizando un modelo naïve Bayes y utiliza reseñas de la base de datos de películas IMDB.com. El sistema evalúa los comentarios como positivos, negativos o neutros, además de dar el nivel de confianza en el resultado. La aplicación tiene un API para poder utilizar el clasificador de forma externa, pero solo si se cuenta con conexión a Internet. Otra de las limitantes que tiene es el lenguaje, ya que su dominio abarca solamente el idioma inglés.

## 2.2. En negocios

Las compañías interesadas en conocer las percepciones de los clientes sobre sus productos o servicios emplean minería de opiniones. La información recabada de encuestas es clasificada, lo que permite mejorar un producto, identificar áreas de oportunidad o mejorar las estrategias de mercadotecnia utilizadas [12]. Un ejemplo de ello es Meltwater [15], la cual es una consultora que ofrece servicios y paquetes que ayudan a crear un análisis sobre la presencia de la marca ante los consumidores y la competencia. Entre los análisis que se realizan, está el análisis de sentimientos, el cual monitorea qué tan bien recibido fue un mensaje de la compañía en redes sociales.

## 2.3. Inteligencia gubernamental

La minería de opiniones gubernamental extrae el comportamiento y opiniones públicas sobre cuestiones políticas. El uso del análisis de sentimientos ayuda a identificar las opiniones de los votantes con relación a un candidato antes de las elecciones para así mejorar las estrategias de campaña [12]. Un ejemplo de ello es el Instituto Nacional de Estadística, Geografía e Informática (INEGI), el cual desarrolló una herramienta que clasificó 63 millones de tuits con georreferencia escritos entre el

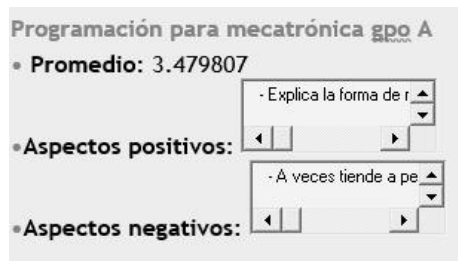


Fig. 1. Forma en la cual los comentarios de la evaluación docente aparecen a los profesores.

2014 y 2015. Esto con la finalidad de generar estadísticas de movilidad y turismo, así como conocer el estado de ánimo de la población por estado del país [16].

### 3. Metodología

Los pasos que se llevaron a cabo para la clasificación de comentarios de la evaluación docente fueron los siguientes: 1) Recolección de comentarios de la evaluación docente, 2) Preprocesamiento de los comentarios, 3) Creación de un vector de características y 4) Clasificación de los comentarios. Estos pasos se describirán brevemente en las siguientes secciones.

#### 3.1. Recolección de comentarios

La recolección de comentarios se llevó a cabo durante el mes de enero del 2017 con ayuda de los profesores de la División Multidisciplinaria de la UACJ en Ciudad Universitaria (CU). Los comentarios corresponden a 4 años, 20 materias y 5 profesores. Para la extracción de los comentarios, cada profesor realizó los siguientes pasos:

1. Ingreso a su página de resultados en la evaluación docente.
2. Selección de una materia ya impartió con anterioridad.
3. Localizar el área de comentarios, como la que se muestra en la Fig. 1.

Al tener en pantalla las casillas de comentarios se escogieron todos los positivos y negativos, los cuales se almacenaron en un archivo de texto simple por separado.

#### 3.2. Preprocesamiento de los comentarios

Antes de crear el vector de características de los comentarios, se realizó un preprocesamiento manual, el cual consistió en la validación de comentarios. Durante esta etapa se eliminaron los comentarios que no tuvieran relevancia a la evaluación docente, así como redistribuir los comentarios positivos que estaban en el archivo de comentarios negativos, así como también los negativos que estaban en el archivo de comentarios positivos. Algunos ejemplos de comentarios no relevantes son:

- “Profesor en serio yo nunca le explique a Yair el método mini, Max el asumió que sí, pero está tonto. Se lo juro.”
- Validación de escritura: La validación de escritura fue la etapa en la cual se corrigió la escritura en los comentarios, editando las palabras que estuvieran mal escritas. Ejemplo: “inpuntual” → “impuntual”
- Eliminación de caracteres y agregación de punto final: Ya que FreeLing requiere que todos los comentarios terminen con un punto final, este punto se agregó mientras se hacía la eliminación de otros caracteres en el comentario como el carácter de guión (“ - “) que aparece al principio de todos los comentarios recolectados.

También se eliminaron otros símbolos como guiones, emojis e ideogramas. Asimismo, se agregó punto al final de una frase. Ejemplo de ello es:

- “- Tiene dominio sobre su tema” → “Tiene dominio sobre su tema.”  
“es una muy buena maestra ❤️” → “es una muy buena maestra”

También se utilizó preprocesamiento automático con la función de normalización, la cual consistió en:

- Cambio de mayúsculas a minúsculas para eliminar posibles errores al comparar las palabras.
- Eliminación de acentos en las palabras ya que los alumnos no acentúan las palabras y ocasionaba que las palabras no fueran detectadas.
- Eliminación de caracteres, comillas y guión bajo. Este tipo de caracteres no contribuyen nada.

### **3.3. Creación de un vector de características**

Un vector de características es un vector de n-elementos o atributos que describen un objeto. Para poder convertir un comentario a un vector, se definió previamente los atributos que lo conformaran. A partir de una lista de palabras indicadoras de opinión en español independiente del dominio, que contienen palabras positivas y negativas se construyó el vector de características. La lista fue proporcionada por la Red Temática en Tratamiento de la Información Multilingüe y Multimodal [17], la cual consta de 2509 palabras positivas y 5626 palabras negativas.

Para reducir la dimensionalidad del vector, se utilizó FreeLing [18]. Esta librería permite extraer el lema de cada una de las palabras y excluir lemas duplicados, lo que produjo una disminución a 1313 palabras positivas y 2949 negativas.

Para disminuir aún más la dimensionalidad, se realizó un análisis de la raíz de las palabras. Para ello se tomó una palabra y se buscó entre todas las palabras del mismo archivo (positivo o negativo) aquellas que tengan la misma raíz. Esto disminuyó el número de características a solo 584 palabras positivas y 1270 palabras negativas.

**Tabla 1.** Ejemplo de palabras positivas y negativas como características de un vector.

<b>Lista de palabras</b>	Bueno	proactivo	decisivo	mejor
	impuntual	fastidio	aburrir	inexperto

**Tabla 2.** Vector resultante del comentario con el vector de características.

<b>Lista de palabras</b>	Bueno	proactivo	decisivo	mejor
<b>Vector</b>	1	0	0	1
<b>Lista de palabras</b>	impuntual	fastidio	aburrir	inexperto
<b>Vector</b>	1	0	0	0

**Tabla 3.** Descripción breve de la base de datos utilizada en los experimentos.

<b>Numero de instancias</b>			<b>Numero de atributos</b>		
Positivos	Negativos	Total	Positivos	Negativos	Total
187	110	297	591	1225	1816

La creación de un vector de características se llevó a cabo a partir de las palabras raíz de tipo positivo y negativo como se muestra en la Tabla 1, donde las palabras bueno, proactivo, decisivo y mejor son ejemplos de palabras positivas e impuntual, fastidio, aburrir e inexperto son palabras negativas, es decir, la dimensionalidad del vector está determinada por las palabras raíces de tipo positivo o negativo.

Por ejemplo, dado un comentario “Es un buen profesor, pero podría ser mejor si no fuera tan impuntual”, este se preprocesa con la función de normalización antes de ser convertido a tokens con ayuda de FreeLing, lo cual quedaría como {“es”, “un”, “buen”, “profesor”, “pero”, “podría”, “ser”, “mejor”, “si”, “no”, “fuera”, “tan”, “impuntual”}, luego se extrae el lema de las palabras {“ser”, “uno”, “bueno”, “profesor”, “pero”, “podría”, “ser”, “mejor”, “si”, “no”, “ser”, “tan”, “impuntual”}. Posteriormente, se indica en cada atributo si la palabra existe con un valor de 1 y en el caso contrario con un 0. Un ejemplo de ello se puede observar en la Tabla 2.

#### 4. Configuración de experimentos

Todas las pruebas fueron realizadas con el software WEKA, empleando para ello una validación cruzada de 5 particiones y la base de datos que se detalla brevemente en la Tabla 3. Los comentarios contenidos en la base de datos pasaron por un preprocesamiento que se describió en la sección 3.2., donde finalmente se pudieron construir 187 y 110 comentarios positivos y negativos, respectivamente.

La dimensionalidad del vector es 1816, de los cuales 591 son atributos que describen palabras positivas y 1225 palabras negativas.

Para los clasificadores SMO (Sequential Minimal Optimization) y 1-NN se utilizaron las configuraciones por defecto en WEKA donde el clasificador SMO utiliza un kernel polinomial, C igual a 1 e información normalizada y el clasificador 1-NN utiliza un kernel de distancia euclidiana y un K=1.

**Tabla 4.** Matriz de confusión de dos clases.

		Etiqueta Predicha	
		Positiva	Negativa
Etiqueta Real	Positiva	D	c
	Negativa	B	a

**Tabla 5.** Tabla de resultados de exactitud global.

	SMO	1-NN
Precisión Global	79.46%	76.76%

Como métricas de evaluación para medir el rendimiento de los clasificadores SMO y 1-NN, se utilizó una matriz de confusión de dos clases como se muestra en la Tabla 4. Con esta matriz podremos determinar el rendimiento de un clasificador con las fórmulas subsecuentes.

La exactitud se determinó con la fórmula:

$$exactitud = \frac{a + d}{a + b + c + d} \quad (1)$$

La tasa de positivos verdaderos (TP) es la proporción de instancias positivas que fueron correctamente clasificadas, y se determina con la fórmula:

$$TP = \frac{d}{c + d} \quad (2)$$

La tasa de negativos verdaderos (TN) es la proporción de instancias negativas que fueron correctamente clasificadas, y se determina con la fórmula:

$$TN = \frac{a}{a + b} \quad (3)$$

La tasa de falsos positivos (FP) es la proporción de instancias negativas clasificadas como positivas, se determina con la fórmula:

$$FP = \frac{b}{a + b} \quad (4)$$

La tasa de falsos negativos (FN) es la proporción de instancias negativas clasificadas como positivas, se determina con la fórmula:

$$FN = \frac{c}{c + d} \quad (5)$$

## 5. Resultados y discusiones

Los resultados globales de exactitud se muestran en la Tabla 5, donde podemos observar que el algoritmo SMO obtuvo los mejores resultados.

**Tabla 6.** Tabla de precisión por clase.

	<b>SMO</b>	<b>1-NN</b>
<b>Positivos</b>	91.44%	89.80%
<b>Negativos</b>	59.10%	54.54%

**Tabla 7.** Matriz de confusión para el clasificador SMO.

	<b>SMO</b>	
	<b>Positivo</b>	<b>Negativo</b>
<b>Positivos</b>	171	16
<b>Negativos</b>	45	65

**Tabla 8.** Matriz de confusión para el clasificador 1-NN.

	<b>1-NN</b>	
	<b>Positivo</b>	<b>Negativo</b>
<b>Positivos</b>	168	19
<b>Negativos</b>	50	60

En la Tabla 6 se muestra la precisión por clase para cada uno de los clasificadores. Como se puede observar los comentarios negativos obtienen una baja tasa de clasificación entre el 54% y el 60%. Mientras que los comentarios positivos obtienen resultados mayores al 88%. Los bajos resultados negativos, afectan a la tasa global de clasificación.

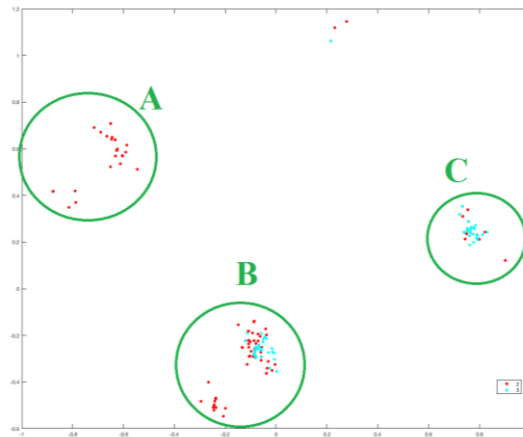
Con la finalidad de analizar el comportamiento por clase de cada uno de los clasificadores, la Tabla 7 y 8 muestran la matriz de confusión promedio para los clasificadores SMO y 1-NN, respectivamente.

La matriz de confusión M muestra que el modelo clasificó correctamente los elementos de la parte superior izquierda M[1,1] y la parte inferior derecha M[2,2]. En la parte inferior izquierda M[2,1] y superior derecha M[1,2], se muestran los falsos positivos y negativos, respectivamente.

De la matriz de confusión para el clasificador SMO en la Tabla 7, se obtiene un TP de 0.9144, TN de 0.5910, el FP de 0.4090 y el FN de 0.0855. Dadas las tasas de FP y FN, podemos observar que este algoritmo de clasificación tiene un menor índice de FP que de FN, lo cual indica que hubo un porcentaje menor de comentarios negativos clasificados como positivos que de comentarios positivos clasificados como negativos. Para el clasificador 1-NN en la Tabla 8, se obtiene un TP de 0.8983, un TN de 0.5454, el FP de 0.4545 y el FN de 0.1016.

Este algoritmo a diferencia del algoritmo SMO, tiene una tasa de FP más alta que FN, por lo que más comentarios negativos fueron clasificados como positivos que viceversa.





**Fig. 2.** Trazado en dos dimensiones de las instancias utilizadas para el entrenamiento.

Dadas los FP y FN de los dos clasificadores, el algoritmo SMO tiene el menor índice de falsos positivos y falsos negativos. Lo que nos indica que con este algoritmo se tienen menos comentarios positivos clasificados como negativos y menos comentarios negativos clasificados como positivos.

Para darnos una mejor idea de cómo están ubicadas las instancias en el espacio y del porqué de los resultados, se utilizó el escalamiento multidimensional (MDS). Este último se suele emplear para visualizar datos con una alta dimensionalidad, en bajas dimensiones. En la Fig. 2 podemos ver cómo están localizadas las instancias positivas (rojo) y negativas (cian) en un plano cartesiano. En la figura se pueden observar tres grupos de datos marcados con las letras A, B y C. En el punto A es un agrupamiento de datos positivos que no presenta ni dentro ni cerca de dicho grupo otro tipo dato. Por lo que se podría decir que las instancias que pertenecen a este espacio serán correctamente clasificadas.

Lo contrario ocurre en los puntos B y C, en donde, existe un solapamiento entre muestras positivas y negativas. Es precisamente en estas zonas donde el clasificador suele cometer los errores. Mirando con detalle el punto C, se podría decir que los comentarios positivos en dicha zona serán clasificados como negativos. Mientras que en la zona B, la mayoría de los comentarios negativos serán clasificados como positivos.

Este solapamiento en el punto B se debe a que los comentarios pueden contener las mismas palabras tanto en comentarios positivos, como en comentarios negativos, por ejemplo, la palabra “bien”, esta palabra se repite tanto en comentarios negativos como:

- “realmente la puedo considero como una maestra que enseña del todo bien aunque cumpla con todos los puntos previos, considero que no es su culpa, el salón que nos tocó este semestre se batalla mucho para escuchar (d4-210).”

También ocurre en comentarios positivos como:

- “sus grupos casi siempre están vacíos, eso habla bien de él, ya que da la clase bien y les da a los alumnos la calificación que se merecen, no deberían abrir esta materia en veranos, los que no hacen nada buscan como pasar y si se gradúan eso da mala imagen a la uacj en la industria, a veces se vuelve difícil conseguir un buen trabajo cuando tienen catalogado a los alumnos de la uacj como inútiles y flojos.”

Al tener este tipo de comentarios que contienen la misma palabra y que son subjetivamente ambiguos por una cantidad similar de palabras positivas y negativas que contienen, se podría considerar este comentario como neutro.

## 6. Conclusiones

En este trabajo se empleó la minería de opiniones a una base de datos de comentarios de estudiantes provenientes de la evaluación docente de la UACJ. Los comentarios corresponden a cuatro años, 20 materias y cinco profesores. Para ello, se realizaron una serie de pasos que fueron desde la captura de los comentarios, pasando por el procesamiento hasta el entrenamiento y prueba con dos clasificadores.

Los resultados mostraron que de los clasificadores empleados, SMO y el 1-NN, el mejor fue el primero con el cual se pudo alcanzar una exactitud de clasificación de un 79.46. Asimismo, se pudo observar que los errores fueron producidos por una serie de comentarios que fueron etiquetados como positivos o negativos, pero que se caracterizan por ser comentarios que pudieran ser considerados neutros.

Como trabajos futuros se probará integrar la librería CoreNLP de la Universidad de Stanford para ayudar con las dependencias entre palabras y la identificación de entidades como personas, lugar y organización. Asimismo, se agregará una nueva etiqueta de clase de comentario denominado neutro. Finalmente, se propone emplear técnicas de preprocesamiento como edición, condensado, entre otros.

**Agradecimientos.** Este trabajo fue parcialmente financiado por el Programa Para el Desarrollo Profesional Docente, para el tipo superior (PRODEP), con clave UACJ-PTC-373.

## Referencias

1. Cortizo, J.C.: Minería de Opiniones. BrainSINS, [www.brainsins.com/es/blog/mineria-opiniones/3555](http://www.brainsins.com/es/blog/mineria-opiniones/3555) (2016)
2. Huddy, G.: What Is Sentiment Analysis? The importance of understanding how your audience feels about your brand. Crimson Hexagon, <https://www.crimsonhexagon.com/blog/what-is-sentiment-analysis/> (2018)
3. Universidad Autónoma de Ciudad Juárez.: Evaluación Docente. <http://www.uacj.mx/sa/ed/Paginas/default.aspx> (2018)
4. Gutiérrez, G., Ponce, J., Ochoa, A., Álvarez, M.: Analyzing Students Reviews of Teacher Performance Using Support Vector Machines by a Proposed Model. *Communications in Computer and Information Science*, 820, pp. 113–122 (2018)

5. Revuze: Revuze Products. Revuze. <http://revuze.it/product/> (2018)
6. Aspectiva.: Aspectiva About Us. Aspectiva, <http://www.aspectiva.com/company/> (2018)
7. Brandwatch.: How it works. Brandwatch, <https://www.brandwatch.com/>. (2018)
8. Google: Sentiment Analysis Tutorial. Google Analytics. <https://cloud.google.com/natural-language/docs/sentiment-tutorial> (2018)
9. Amazon Web Services: Big Data on AWS. Amazon.com <https://aws.amazon.com/big-data/> (2018)
10. Waterloo University: Capital One Data Mining Cup. Waterloo University. <https://uwaterloo.ca/computing-financial-management/events/capital-one-data-mining-cup> (2014)
11. Jadhavar, R., Komaraji, A.K.: Sentiment Analysis of Netflix and Competitor Tweets to Classify Customer Opinions. SAS Global Forum (2018)
12. Smeureanu, I., Bucur, C.: Applying Supervised Opinion Mining Techniques on Online User Reviews. *Informatica Economică*, 16(2), pp. 81–91 (2012)
13. Meaning Cloud: General questions. Meaning Cloud. <https://www.meaningcloud.com/> (2018)
14. Narayanan, V., Arora, I., Bhatia, A.: Fast and accurate sentiment classification using an enhanced Naive Bayes model Cornell. <http://sentiment.vivekn.com/about/> (2016)
15. Meltwater: About Meltwater. Meltwater: <https://www.meltwater.com/about/> (2016)
16. Instituto Nacional de Estadística y Geografía.: Estado de ánimo de los tuiteros en los Estados Unidos Mexicanos. [http://internet.contenidos.inegi.org.mx/contenidos/Productos/prod\\_serv/contenidos/espanol/bvinegi/productos/nueva\\_estruc/702825099718.pdf](http://internet.contenidos.inegi.org.mx/contenidos/Productos/prod_serv/contenidos/espanol/bvinegi/productos/nueva_estruc/702825099718.pdf) (2017)
17. Molina-González, D., Martínez-Cámara, E., Martín-Valdivia, M.T., Perea-Ortega, J.: iSOL. Red Temática en Tratamiento de la Información Multilingüe y Multimodal. <http://timm.ujaen.es/recursos/isol/> (2013)
18. Freeling: FreeLing Home Page. Universitat Politècnica de Catalunya. <http://nlp.lsi.upc.edu/freeling/node/1> (2015)