

# Ampliación de lexicones de opinión específicos de dominio usando representaciones continuas de palabras

## *Expansion of domain-specific opinion lexicons using word embeddings*

**Tomás López Solaz**  
Universidad de Sevilla  
tlopez2@us.es

**Fermín L. Cruz**  
Universidad de Sevilla  
fcruz@us.es

**Fernando Enríquez**  
Universidad de Sevilla  
fenros@us.es

**Resumen:** En este trabajo abordamos la ampliación de lexicones de opinión específicos de dominio a partir de textos del dominio elegido. El método se basa en la construcción de clasificadores que catalogan las palabras de entrada como positivas, negativas o neutras, y en un criterio estricto de selección de las palabras que pretende garantizar la precisión de las nuevas incorporaciones al lexicon. Se utilizan representaciones continuas de palabras (*word embeddings*) como espacio de características de los clasificadores. Los resultados confirman que dichas representaciones contienen información relativa a la polaridad de las palabras, obteniéndose una precisión en la selección de los candidatos y en la estimación de su polaridad de alrededor del 94 % para los tres dominios analizados, con una cobertura en torno al 50 % de las palabras de opinión contenidas en los textos de partida.

**Palabras clave:** Análisis del sentimiento, lexicones de opinión, representaciones continuas de palabras

**Abstract:** In this work we present a domain-specific opinion lexicon expansion method. The method is based on classifiers which categorize words as positive, negative or neutral, and a strict selection criteria of words intended to ensure the precision of the new additions to the lexicon. We use word embeddings as the feature space of the classifiers. The results confirm that these representations contain information on the polarity of the words, obtaining a precision in the selection of candidates and the estimation of its polarities of about 94 % for the three domains analyzed, covering around 50 % of the opinion words contained in the initial texts.

**Keywords:** Sentiment analysis, opinion lexicons, word embeddings

## 1 *Introducción*

En el contexto del análisis de opiniones textuales, un recurso de amplia utilización son los lexicones de opinión, diccionarios de términos con connotaciones subjetivas, acompañados de estimaciones de las implicaciones positivas o negativas de los mismos. Existen muchas aproximaciones distintas: lexicones de propósito general o específicos de un dominio, lexicones con estimaciones binarias de la polaridad o con un mayor grado de granularidad (incluyendo información no sólo de la polaridad sino también de la intensidad de las connotaciones afectivas), lexicones basados en palabras o en recursos lexico-semánticos como WordNet, etc. En la sección 2 comentamos algunos trabajos sobre generación de lexicones de opinión.

El sistema de extracción automática de opiniones orientado al dominio TOES (Cruz et al., 2013) se basa en recursos generados a

partir de documentos de opinión anotados. A pesar de ser supervisado, se intenta usar el menor número posible de documentos anotados en este proceso, ampliando posteriormente los recursos a partir de otros documentos sin anotar. Entre los recursos generados se encuentra un lexicon de opiniones a nivel de palabras orientado al dominio. En este trabajo exponemos un método de ampliación de estos lexicones de opinión, que a partir de un conjunto de documentos sin anotar extrae nuevos términos a incluir en el lexicon, junto a una estimación de sus polaridades. Nuestra intención es asegurar en todo momento una altísima precisión, de manera que podamos estar seguros de que la inmensa mayoría de los términos añadidos y sus polaridades son correctos.

Como objetivo secundario de este trabajo, pretendemos corroborar las bondades de las representaciones continuas de palabras o

*word embeddings* al ser aplicadas a tareas de clasificación de la polaridad, en concreto mediante el uso de la herramienta *word2vec*. Son manifiestas las relaciones entre la geometría de las representaciones vectoriales de palabras obtenidas mediante dicha herramienta y el contenido semántico de las mismas, de manera que por ejemplo palabras semánticamente próximas son representadas mediante vectores similares (a diferencia de lo que ocurre con representaciones vectoriales discretas como las basadas en *tf-idf* u otras). Nuestra hipótesis de partida es que también existe una relación similar entre las representaciones continuas de palabras de la misma polaridad, como ya parecen confirmar algunos trabajos previos que se expondrán en la siguiente sección.

La estructura del resto del artículo es la que se expone a continuación. En la sección 2 se repasan algunos trabajos previos relacionados con la inducción de lexicones de opinión y su ampliación, y se introducen las principales técnicas y algunas aplicaciones de las representaciones continuas de palabras. En la sección 3 se define la tarea de ampliación de lexicones de opinión, se detalla el método utilizado para llevarla a cabo. En la sección 4 se muestran los resultados experimentales y, finalmente, en la sección 5 se comentan las conclusiones del trabajo y se proponen líneas de continuación del mismo.

## 2 Trabajos relacionados

### 2.1 Inducción de lexicones de opinión

En los últimos años se han propuesto diversos métodos para la creación de lexicones de opinión. Existen trabajos que abordan la tarea de forma totalmente manual (Stone, 1966; Cerini et al., 2007), y otros que se basan en un corpus anotado a nivel de opiniones, a partir del cual extraen las palabras de opinión y las polaridades de las mismas (Cruz et al., 2013). Algunos de ellos se basan en recursos léxico-semánticos para obtener los lexicones de opinión de manera automática o semiautomática. Por ejemplo, en (Kamps et al., 2004) se utiliza una función de distancia semántica sobre WordNet que es utilizada para decidir la polaridad de las palabras del lexicón en función de la distancia a una semilla positiva (“good”) y una negativa (“bad”). Otros trabajos se basan en una idea similar pero utilizando un mayor número de semillas

(Hu y Liu, 2004; Kim y Hovy, 2004). En los trabajos de Esuli y Sebastiani (Esuli y Sebastiani, 2006; Baccianella, Esuli, y Sebastiani, 2010) la idea de partida es que si una palabra tiene una polaridad determinada, es probable que las palabras de su glosa (pequeñas definiciones de los términos que conforman WordNet) compartan dicha polaridad. Partiendo de unas semillas positivas y negativas, y aplicando un proceso iterativo de expansión basado en las relaciones de sinonimia y antonimia de WordNet, se obtienen conjuntos de entrenamiento para las clases positiva y negativa, usando las glosas de los términos de cada conjunto. Se construye un clasificador de textos mediante representaciones discretas de las palabras (*tf-idf*) que es aplicado a todas las palabras que componen el recurso WordNet, para obtener así estimaciones de las polaridades de todas ellas. Posteriormente se aplica un algoritmo de paseo aleatorio (*PageRank*) sobre un grafo construido a partir de las palabras y sus glosas, que refina los valores de orientación semántica asignados a las palabras en el recurso final. Las mismas ideas son aplicadas en (Cruz et al., 2014), variando algunas partes del proceso y aplicando un algoritmo más potente de paseo aleatorio (Cruz et al., 2012) adaptado a la tarea de cálculo de la polaridad. La principal debilidad de los acercamientos basados en recursos léxico-semánticos es su disponibilidad para nuevas lenguas, y que las estimaciones de polaridad obtenidas son independientes del dominio (cuando existen diferencias claras en el vocabulario utilizado en distintos ámbitos).

Otros trabajos se basan en corpus de textos sin anotaciones, como hacemos en el método propuesto en este trabajo. Algunos de ellos se basan en definir conjuntos semilla de términos positivos y negativos y calculan las polaridades de las palabras del lexicón a partir de construcciones conjuntivas observadas en el corpus (Hatzivassiloglou y McKeown, 1997) o de coocurrencias en un contexto dado (Turney y Littman, 2003; Yu y Hatzivassiloglou, 2003) entre las semillas y las palabras objetivo.

### 2.2 Ampliación de lexicones de opinión

En nuestro trabajo la tarea no consiste en la generación de lexicones de opinión desde cero, sino que pretendemos ampliar lexicones previamente obtenidos a partir de un corpus

anotado (Cruz et al., 2013). Existen trabajos previos que comparten este objetivo; en (Kanayama y Nasukawa, 2006) se propone un algoritmo de expansión automática de lexicones basado en la coherencia contextual, esto es, la tendencia a que términos con la misma polaridad aparezcan en un mismo contexto. En (Qiu et al., 2011) se utilizan los términos del lexicon de partida para identificar patrones sintácticos entre las palabras de opinión y las palabras objetivo de su contexto a las que afectan. Estos patrones son aplicados sobre otras apariciones de estas palabras objetivo conformando un proceso de *bootstrapping*. La polaridad de las nuevas palabras de opinión encontradas es decidida de nuevo a partir de reglas contextuales. En (Cruz et al., 2011) se construye un grafo entre las palabras que participan en expresiones conjuntivas en el corpus de partida. Los nodos que representan a las palabras del lexicon inicial son anotados con los valores de polaridad, y posteriormente se aplica un algoritmo de paseo aleatorio (Cruz et al., 2012) sobre el grafo para obtener las polaridades del resto de nodos. En (Molina-González et al., 2015) se expande un lexicon de opiniones en español independiente del dominio (Molina-González et al., 2013), adaptándolo a un dominio concreto a partir de documentos de opinión del dominio de interés. La selección de las palabras y su polaridad se realiza automáticamente a partir de una fórmula basada en la frecuencia de aparición de las mismas en opiniones positivas y negativas.

### 2.3 Representaciones continuas de palabras

Cuando se emplean técnicas de aprendizaje automático sobre textos es frecuente utilizar representaciones numéricas de las palabras o los documentos. Tradicionalmente se han empleado representaciones discretas, por ejemplo vectores de unos y ceros que indican la aparición o no de las palabras del vocabulario en un documento, u otras métricas que acumulen más información (basadas generalmente en la frecuencia de aparición de las palabras). Estas representaciones adolecen de un problema de falta de sentido geométrico; por ejemplo dos palabras cualesquiera siempre estarían representadas por vectores con una única componente no nula, de manera que la distancia entre los vectores no está relacionada con la cercanía semántica de las

palabras. En los últimos años se han producido esfuerzos encaminados a obtener representaciones continuas de las palabras y los documentos, que sobrepasen la limitación anterior. En estas representaciones, los vectores sí pueden ser interpretados geoméricamente, de manera que dos palabras o documentos cercanos desde un punto de vista semántico estarían representados por vectores similares (y viceversa). Las representaciones continuas (también conocidas como *word embeddings*) más utilizadas en los últimos años han sido Latent Semantic Indexing (Dumais, 1995), Latent Semantic Analysis (Dumais, 2004) y, más recientemente, técnicas basadas en redes neuronales (Turian, Ratinov, y Bengio, 2010; Huang et al., 2012; Mikolov et al., 2013b). De estas últimas, *word2vec* (Mikolov et al., 2013a) es la herramienta que más popularidad ha alcanzado. Se basa en la construcción previa de un modelo a partir de un corpus de textos, a partir del cual se entrena una red neuronal de dos niveles en la que las entradas son los contextos de una palabra dada y la salida la palabra en cuestión (o viceversa, intercambiando las entradas por las salidas). El sentido semántico de la geometría de los vectores obtenidos mediante *word2vec*, que puede apreciarse en los ejemplos de operaciones entre vectores mostradas en (Mikolov et al., 2013a), los hace apropiados como entrada a algoritmos de aprendizaje automático para resolver múltiples tareas de NLP (Socher et al., 2013; Tang et al., 2014; Pavlopoulos y Androutsopoulos, 2014; Kim y de Marneffe, 2013), incluida la inducción de lexicones de opinión (Pablos, Cuadros, y Rigau, 2015).

### 3 Propuesta

Partimos de lexicones de opinión obtenidos a partir de corpus de textos de dominios concretos, anotados a nivel de opiniones. Estos lexicones incluyen, además de la polaridad de las palabras, una probabilidad de que el término sea o no de opinión; una probabilidad igual a 1 indica que siempre que ha aparecido en el corpus ha sido anotado como participante en una opinión. Valores inferiores indican cierta ambigüedad en cuanto a si el término expresa opinión o no. Pueden consultarse los detalles sobre el método concreto utilizado para obtener los lexicones en (Cruz et al., 2013).<sup>1</sup> La tarea consiste en ampliar

<sup>1</sup>Los lexicones concretos utilizados en este trabajo no se corresponden con los presentados en dicho

dicho lexicón a partir de términos de textos del dominio sin anotar. A partir de las palabras que aparecen en dichos textos, debemos seleccionar cuáles pasarán a formar parte del lexicón y decidir sus polaridades.

### 3.1 Método

Nuestro método consiste en el entrenamiento de clasificadores ternarios que deciden para cada palabra candidata si se trata de una palabra neutra (no debe ser incluida en el lexicón), positiva o negativa. Estos clasificadores toman como entrada representaciones continuas de las palabras. A continuación detallamos los pasos del método.

En la fase de entrenamiento, seleccionamos aquellas palabras positivas y negativas del lexicón cuya probabilidad sea igual a 1. Como representantes de la categoría neutra, se seleccionan aleatoriamente un número similar de palabras de entre las contenidas en los textos sin anotar. Estas palabras deben ser revisadas para asegurarse de que no se incluyen palabras que pudieran expresar opinión. Para obtener la representación continua de las palabras seleccionadas hacemos uso de la herramienta *word2vec* (Mikolov et al., 2013a). La elección del modelo que utilice dicha herramienta, que puede haber sido construido a partir de textos del dominio o usando un corpus genérico, puede tener consecuencias en los resultados obtenidos. Ambas opciones serán estudiadas en la sección 4. Una vez obtenidos los datos de entrenamiento, entrenamos un clasificador multiclase de tipo *Support Vector Machines (SVM)*.

Tras la fase de entrenamiento, y para cada una de las palabras contenidas en los textos no anotados, obtenemos representaciones continuas de las mismas usando *word2vec* con el mismo modelo utilizado en la fase de entrenamiento. Los vectores obtenidos son pasados por el clasificador, que decidirá si se trata de una palabra neutra, positiva o negativa. Si la palabra es clasificada como neutra, lógicamente es descartada. Pero incluso si la palabra es clasificada como positiva o negativa, puede no ser seleccionada para ser incluida en el lexicón ampliado, si la probabilidad de pertenencia a la clase devuelta por el clasificador no supera un umbral mínimo fijado manualmente. Pretendemos de esta forma aumentar la precisión del método, a costa de una me-

trabajo, sino que fueron obtenidos en el contexto del proyecto AORESCU (P11-TIC-7684 MO).

nor cobertura. Llevamos a cabo un estudio de este valor umbral en la sección 4.4.

## 4 Experimentación

En esta sección mostramos los distintos experimentos llevados a cabo para evaluar distintas variaciones de nuestro método. Trataremos de decidir si es más apropiado el uso de modelos de representación de las palabras entrenados sobre textos del dominio o modelos genéricos. También buscaremos el valor de probabilidad umbral más apropiado, y obtendremos una estimación final de la precisión de nuestro método.

### 4.1 Recursos utilizados

Hemos realizado los experimentos para el idioma español, en tres dominios distintos: alojamientos (principalmente, opiniones sobre hoteles), gastronomía (principalmente, opiniones sobre restaurantes) y actividades culturales (opiniones sobre museos, monumentos, conciertos, teatro, etc.). Los documentos de los que partimos para cada uno de estos dominios fueron extraídos de TripAdvisor<sup>2</sup>. En la Tabla 1 se muestran el número de documentos y el de palabras de cada uno de estos corpus.

Dominio	Opiniones	Palabras
Alojamiento	279.531	38.194.969
Gastronomía	284.782	17.321.589
Cultura	91.263	4.271.481

Tabla 1: Datos de los corpus utilizados.

En la Tabla 2 se muestran el número de términos que conforman cada uno de los lexicones de partida. También se indica el número de términos cuya probabilidad de opinión es igual a 1, es decir, aquellos que serán utilizados para el entrenamiento de los clasificadores. El resto de términos de los lexicones, para los que conocemos la polaridad y que no son usados en el entrenamiento, serán utilizados para evaluar el método.

Dominio	Total	Entren.	Eval.
Alojamiento	1.066	483	447
Gastronomía	1.852	885	462
Cultura	2.310	900	470

Tabla 2: Número de términos en los lexicones iniciales.

Para obtener las palabras neutras necesarias para el entrenamiento y la evaluación,

<sup>2</sup>[www.tripadvisor.com](http://www.tripadvisor.com)

se extrajeron 500 palabras aleatoriamente de entre los tres corpus de documentos. Una vez filtradas las palabras con posibles usos de opinión quedaron 448, de las cuales 200 palabras fueron usadas para entrenamiento y 248 para evaluación.

Finalmente, para la representación continua de las palabras, se construyó un modelo para cada dominio a partir de los textos disponibles. También se dispone del modelo *Spanish Billion Words Corpus and Embeddings* (Cardellino, 2016). Se trata de un modelo entrenado con textos de diversa procedencia, y que podemos considerar por tanto genérico<sup>3</sup>, frente a los modelos específicos del dominio anteriores.

## 4.2 Modelos de representación continua de palabras

Antes de proceder al entrenamiento de los clasificadores tomando como entrada las representaciones continuas de las palabras candidatas, llevamos a cabo una representación bidimensional de dichas representaciones. En la Figura 1 se muestra una proyección bidimensional de los vectores obtenidos mediante la herramienta *word2vec* para las palabras positivas, negativas y neutras del dominio alojamiento. Se empleó el modelo entrenado a partir de los textos del dominio. Parece observarse que existe una correlación entre la posición espacial de dichos vectores y la polaridad semántica de las palabras representadas, lo que refuerza nuestra idea de partida.

## 4.3 Entrenamiento Clasificadores

Para la obtención de los clasificadores se utilizó la herramienta *scikit-learn* (Pedregosa et al., 2011). El tipo de clasificador empleado fue *C-Support Vector Classification*, entrenado con parámetro de penalización  $C = 100$  y un criterio de parada de 0,01. Se entrenaron por un lado clasificadores usando los modelos de representación de palabras específicos del dominio y por otro el modelo genérico.

En las tablas 3 y 4 se muestran los resultados obtenidos al evaluar los clasificadores. En general, se observan mejores resultados utilizando los modelos de representación de palabras entrenados con los textos del dominio, frente al modelo genérico, aunque esta diferencia es menos pronunciada en el dominio de cultura. Esto puede ser debido al menor

<sup>3</sup>Lo llamaremos modelo genérico en el resto del trabajo.




Figura 1: Proyección bidimensional de los vectores representantes de las palabras positivas, negativas y neutras para el dominio alojamiento.

Dominio	clase	p	r	$F_1$
Alojamiento	-1	0,794	0,761	0,777
	0	0,68	0,923	0,783
	1	0,955	0,675	0,791
Gastronomía	-1	0,738	0,842	0,786
	0	0,803	0,823	0,813
	1	0,874	0,779	0,824
Cultura	-1	0,677	0,625	0,650
	0	0,741	0,762	0,752
	1	0,785	0,801	0,793

Tabla 3: Evaluación de los clasificadores ternarios (modelos específicos del dominio).

tamaño del corpus de documentos de dicho dominio. En cualquier caso, nuestro objetivo prioritario es garantizar una alta precisión, por lo que continuamos considerando ambos modelos en la experimentación restante.

## 4.4 Estimación del umbral

Dado que estamos interesados en primar la precisión frente a la cobertura, planteamos un

Dominio	clase	p	r	$F_1$
Alojamiento	-1	0,795	0,743	0,768
	0	0,644	0,919	0,568
	1	0,86	0,568	0,684
Gastronomía	-1	0,597	0,644	0,62
	0	0,641	0,762	0,696
	1	0,772	0,607	0,68
Cultura	-1	0,723	0,685	0,703
	0	0,636	0,790	0,705
	1	0,8	0,665	0,726

Tabla 4: Evaluación de los clasificadores ternarios (modelos genéricos).

método de selección de los candidatos más estricto: establecemos un valor umbral de probabilidad, de manera que sólo las palabras clasificadas como positivas o negativas con una probabilidad mayor o igual al umbral serán seleccionadas.




Figura 2: Precisión (p) y cobertura (r) del método para el dominio alojamiento en función del valor umbral de probabilidad.

En la Figura 2 se muestra cómo varían la precisión y la cobertura del clasificador basado en el modelo de palabras del dominio alojamiento, para todo el rango de valores del umbral mínimo de probabilidades. Nos fijamos únicamente en las clases positiva y negativa, correspondientes a las palabras seleccionadas por el método para ser incluidas en el léxico. Seleccionaremos un valor de umbral mínimo buscando en esta gráfica el punto de la curva donde la cobertura está más próxima a 0.5 (valor que asegura que entorno a la mitad de las palabras de opinión presentes en el corpus serán seleccionadas para ser introducidas en el léxico ampliado). Aplicando este procedimiento a los distintos clasificadores y dominios, se obtienen los valores de precisión y de umbral que se muestran en las tablas 5 y 6. En los dominios alojamiento y gastronomía los mejores valores de precisión se obtienen usando el modelo de representación de palabras del dominio, mientras que en el dominio cultura se obtiene usando el modelo genérico. Este comportamiento es coherente con lo observado al evaluar los clasificadores en la sección anterior, y puede ser achacado al menor tamaño del corpus del dominio cultura.

#### 4.5 Método combinado

De los resultados anteriores se puede concluir que la decisión de usar un modelo de representación de palabras basado en el dominio

Dominio	$prob_{min}$	p
Alojamiento	0,841	0,957
Gastronomía	0,842	0,936
Cultura	0,67	0,836

Tabla 5: Umbrales de probabilidad y precisión media de las clases positiva y negativa (modelos específicos del dominio).

Dominio	$prob_{min}$	p
Alojamiento	0,662	0,909
Gastronomía	0,622	0,835
Cultura	0,671	0,911

Tabla 6: Umbrales de probabilidad y precisión media de las clases positiva y negativa (modelos genéricos).

o uno genérico puede influir sensiblemente a los resultados obtenidos. En lugar de establecer un mecanismo para tomar dicha decisión, proponemos un método de combinación de ambas opciones, basándonos de nuevo en la idea de primar la precisión del proceso: únicamente incluiremos en los lexicones ampliados aquellas palabras que sean igualmente clasificadas como positivas o negativas por ambos clasificadores (el basado en el modelo de representación de palabras del dominio y el basado en el modelo genérico), y siempre que la probabilidad de pertenencia a la clase en ambos casos sea mayor al umbral establecido. Aplicando este método y repitiendo el proceso de selección del umbral mínimo, obtenemos los resultados mostrados en la Tabla 7.

Dominio	$prob_{min}$	p
Alojamiento	0,33	0,959
Gastronomía	0,53	0,933
Cultura	0,49	0,935

Tabla 7: Umbrales de probabilidad y precisión media de las clases positiva y negativa (método combinado).

En los dominios alojamiento y gastronomía se obtienen ahora precisiones similares a los mejores casos anteriores, sin necesidad de decidirnos por el uso del modelo de representación de palabras específico del dominio o por el modelo genérico. En el dominio cultura obtenemos además una mejora de los resultados anteriores de dos puntos porcentuales. Concluimos por tanto que el método combinado es el más apropiado para la tarea abordada.

## 5 Conclusiones

En este trabajo hemos expuesto un método de ampliación de lexicones de opinión, que a partir de un conjunto de documentos sin anotar extrae nuevos términos a incluir en el lexicon, y estima la polaridad de dichos términos. El método está diseñado para asegurar una alta precisión, de manera que podamos estar seguros de que la inmensa mayoría de los términos añadidos y sus polaridades son correctos. Los resultados obtenidos indican que nuestro método es capaz de ampliar los lexicones iniciales capturando la mitad del total de las palabras de opinión contenidas en los textos de partida, y con una muy alta precisión: en torno al 94 % de las palabras seleccionadas son efectivamente palabras de opinión y su polaridad, positiva o negativa, está correctamente asignada. Queda pendiente en nuestro trabajo la evaluación extrínseca del método, mediante la utilización de los lexicones ampliados para la resolución de tareas específicas (por ejemplo, la clasificación de la polaridad de documentos de opinión) para medir qué mejoras se obtienen frente al uso de los lexicones iniciales. Tampoco hemos abordado la selección de multipalabras, lo cual precisaría de un preprocesado de los textos de partida que detectara las colocaciones más frecuentes en el dominio. Una vez representadas como un único token, el método propuesto en este trabajo podría ser aplicado sin variaciones.

## Agradecimientos

Este trabajo ha sido financiado a través del proyecto de investigación AORESCU (P11-TIC-7684 MO).

## Bibliografía

- Baccianella, Stefano, Andrea Esuli, y Fabrizio Sebastiani. 2010. Sentiwordnet 3.0: An enhanced lexical resource for sentiment analysis and opinion mining. En *LREC*, Valletta, Malta. European Language Resources Association (ELRA).
- Cardellino, Cristian. 2016. Spanish Billion Words Corpus and Embeddings, March.
- Cerini, S., V. Compagnoni, A. Demontis, M. Formentelli, y G. Gandini, 2007. *Language resources and linguistic theory: Typology, second language acquisition, English linguistics*. Franco Angeli Editore, Milano, IT.
- Cruz, Fermín L, José A Troyano, Fernando Enríquez, F Javier Ortega, y Carlos G Vallejo. 2013. Long autonomy or long delay? the importance of domain in opinion mining. *Expert Systems with Applications*, 40(8):3174–3184.
- Cruz, Fermín L, José A Troyano, F Javier Ortega, y Fernando Enríquez. 2011. Automatic expansion of feature-level opinion lexicons. En *Proceedings of WASSA*, páginas 125–131. Association for Computational Linguistics.
- Cruz, Fermín L, Carlos G Vallejo, Fernando Enri, José A Troyano, y others. 2012. Polarityrank: Finding an equilibrium between followers and contraries in a network. *Information Processing & Management*, 48(2):271–282.
- Cruz, Fermín L., José A. Troyano, Beatriz Pontes, y F. Javier Ortega. 2014. Building layered, multilingual sentiment lexicons at synset and lemma levels. *Expert Systems with Applications*, 41(13):5984–5994.
- Dumais, Susan T. 1995. Latent semantic indexing (lsi): Trec-3 report. *Nist Special Publication SP*, páginas 219–219.
- Dumais, Susan T. 2004. Latent semantic analysis. *Annual review of information science and technology*, 38(1):188–230.
- Esuli, Andrea y Fabrizio Sebastiani. 2006. Determining term subjectivity and term orientation for opinion mining. En *Proceedings of the European Chapter of the Association for Computational Linguistics (EACL)*.
- Hatzivassiloglou, Vasileios y Kathleen R. McKeown. 1997. Predicting the semantic orientation of adjectives. En *Proceedings of the eighth conference on European chapter of the Association for Computational Linguistics*, páginas 174–181, Morristown, NJ, USA. Association for Computational Linguistics.
- Hu, Mingqing y Bing Liu. 2004. Mining and summarizing customer reviews. En *Proceedings of the ACM SIGKDD Conference on Knowledge Discovery and Data Mining (KDD)*, páginas 168–177.
- Huang, Eric H, Richard Socher, Christopher D Manning, y Andrew Y Ng. 2012.

- Improving word representations via global context and multiple word prototypes. En *Proceedings of the ACL: Long Papers-Volume 1*, páginas 873–882. Association for Computational Linguistics.
- Kamps, Jaap, Maarten Marx, Robert J. Moken, y Maarten De Rijke. 2004. Using wordnet to measure semantic orientation of adjectives. En *National Institute for*, volumen 26, páginas 1115–1118.
- Kanayama, Hiroshi y Tetsuya Nasukawa. 2006. Fully automatic lexicon expansion for domain-oriented sentiment analysis. En *EMNLP*, páginas 355–363, Sydney, Australia, July. Association for Computational Linguistics.
- Kim, Joo-Kyung y Marie-Catherine de Marneffe. 2013. Deriving adjectival scales from continuous space word representations. En *EMNLP*, páginas 1625–1630.
- Kim, Soo-Min y Eduard Hovy. 2004. Determining the sentiment of opinions. En *COLING*.
- Mikolov, Tomas, Kai Chen, Greg Corrado, y Jeffrey Dean. 2013a. Efficient estimation of word representations in vector space. *arXiv preprint arXiv:1301.3781*.
- Mikolov, Tomas, Ilya Sutskever, Kai Chen, Greg S Corrado, y Jeff Dean. 2013b. Distributed representations of words and phrases and their compositionality. En *Advances in neural information processing systems*, páginas 3111–3119.
- Molina-González, M Dolores, Eugenio Martínez-Cámara, M Teresa Martín-Valdivia, y L Alfonso Ureña-López. 2015. A spanish semantic orientation approach to domain adaptation for polarity classification. *Information Processing & Management*, 51(4):520–531.
- Molina-González, M Dolores, Eugenio Martínez-Cámara, María-Teresa Martín-Valdivia, y José M Perea-Ortega. 2013. Semantic orientation for polarity classification in spanish reviews. *Expert Systems with Applications*, 40(18):7250–7257.
- Pablos, Aitor García, Montse Cuadros, y German Rigau. 2015. Unsupervised word polarity tagging by exploiting continuous word representations. *Procesamiento del Lenguaje Natural*, 55:127–134.
- Pavlopoulos, John y Ion Androutsopoulos. 2014. Aspect term extraction for sentiment analysis: New datasets, new evaluation measures and an improved unsupervised method. *Proceedings of LASMEACL*, páginas 44–52.
- Pedregosa, F., G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, y E. Duchesnay. 2011. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12:2825–2830.
- Qiu, Guang, Bing Liu, Jiajun Bu, y Chun Chen. 2011. Opinion word expansion and target extraction through double propagation. *Computational Linguistics*, 37(1).
- Socher, Richard, Alex Perelygin, Jean Y Wu, Jason Chuang, Christopher D Manning, Andrew Y Ng, y Christopher Potts. 2013. Recursive deep models for semantic compositionality over a sentiment treebank. En *EMNLP*, volumen 1631, página 1642. Citeseer.
- Stone, Philip J. 1966. *The General Inquirer: A Computer Approach to Content Analysis*. The MIT Press.
- Tang, Duyu, Furu Wei, Nan Yang, Ming Zhou, Ting Liu, y Bing Qin. 2014. Learning sentiment-specific word embedding for twitter sentiment classification. En *ACL (1)*, páginas 1555–1565.
- Turian, Joseph, Lev Ratinov, y Yoshua Bengio. 2010. Word representations: a simple and general method for semi-supervised learning. En *Proceedings of the ACL*, páginas 384–394. Association for Computational Linguistics.
- Turney, Peter D. y Michael L. Littman. 2003. Measuring praise and criticism: Inference of semantic orientation from association. *ACM Transactions on Information Systems*, 21:315–346.
- Yu, Hong y Vasileios Hatzivassiloglou. 2003. Towards answering opinion questions: Separating facts from opinions and identifying the polarity of opinion sentences. En *Proceedings of EMNLP*.