

Identificación del sentimiento expresado usando redes sociales en un contexto político

Identification of the sentiment expressed using social networks in a political context

Completed Research

Victor W. Bohorquez Lopez
Pontificia Universidad Católica Madre y
Maestra
victorbohorquez@pucmm.edu.do

Christiam Mendez Lazarte
Universidad de Lima
cmendezl@ulima.edu.pe

Lucas Altube
Universidad Nacional General Sarmiento
laltube@ungs.edu.ar

Enmanuel Santana
Universidad Austral
enmanuel.s@gmail.com

Resumen

Este estudio pretende proponer una solución al problema de identificar el sentimiento de comentarios en español, debido a las variaciones idiomáticas existentes en los diversos países Latinoamericanos, plasmados en redes sociales usando como ejemplo el contexto político de una provincia de Argentina. Para lograrlo, se utilizó una combinación de un algoritmo de aprendizaje no supervisado, para hacer la pseudo clasificación, con un algoritmo de aprendizaje supervisado, para el modelo de clasificación. Los resultados muestran que el nivel de precisión obtenido es 93%, lo cual es mayor que los niveles de precisión encontrados en estudios previos. Entre las contribuciones del estudio podemos resaltar la necesidad de incluir una capa de pre-procesamiento, para corregir faltas ortográficas y reducir la vectorización al generar un clasificador con mayor precisión; y un proceso de pseudo-clasificación, como alternativa de clasificar de forma manual miles de comentarios para lograr un dataset para entrenamiento de un clasificador.

Palabras Clave

Análisis de sentimiento, redes sociales, Facebook, candidatos políticos, Argentina.

Abstract

This study aims to propose a solution to the problem of identifying the feeling of comments in Spanish, due to the linguistic variations existing in the different Latin American countries, expressed in social networks using as an example a political context of an Argentinian Province. To achieve this, a combination of an unsupervised machine-learning algorithm was used to do the pseudo classification, with a supervised machine-learning algorithm, for the classification model. The results show that the level of accuracy obtained is 93%, which is higher than the levels of accuracy found in previous studies. Among the contributions of the study, we can highlight the need to include a layer of pre-processing, to correct spelling errors and reduce vectorization by generating a classifier with greater precision; and a pseudo-classification process, as an alternative to manually classifying thousands of comments to achieve a dataset for training a classifier.

Keywords

Sentiment Analysis, social networks, Facebook, political candidates, Argentina.

Introducción

Las redes sociales se han vuelto un espacio donde se puede transmitir el estado emocional y sentimental de las personas. En ese contexto, Stieglitz & Dang-Xuan (2012) argumentan que los usuarios transmiten información afectiva y emocional al conectarse a blogs, foros de discusión y portales webs, obteniendo atención a sus opiniones y reciprocidad entre ellos y los demás participantes. Esta situación es corroborada en estudios previos como los de Bayer et al. (2012), Huffaker (2010), y Joyce y Kraut (2006). Para analizar esta gran cantidad de datos generados por los usuarios en Internet se utilizan diversas herramientas, entre las que destaca el análisis de sentimiento. Arcila-Calderón y sus colegas (2017) encontraron dos enfoques del análisis de sentimiento; el primero se inició con la técnica tradicional de clasificar los textos de las opiniones en base a un diccionario de lexicons que determina la polaridad del mensaje, en positivo, negativo o neutral. Por otro lado, el segundo enfoque, y que ha sido más desarrollado con el tiempo, es el análisis de sentimientos supervisado, donde se usa un clasificador que es entrenado con un algoritmo de aprendizaje supervisado para intentar entender la estructura sintáctica del enunciado, teniendo en cuenta las sutilezas del lenguaje, como la negación, subjetividad, ironía, etc. (Arcila-Calderón et al., 2017).

Crear y utilizar un diccionario de palabras ya codificadas es un gran paso hacia una mayor eficiencia en el análisis de sentimiento, ya que se puede averiguar rápidamente si una nueva unidad de texto contiene una palabra del diccionario y recuperar su valor de sentimiento (Haselmayer & Jenny, 2017). Al comparar el uso de diccionarios en inglés versus un enfoque de aprendizaje automático, Soroka y sus colegas (2015) encontraron que los diccionarios tienen muy buena precisión, pero muy poca recordación, mientras que el aprendizaje automático muestra mayor cobertura, pero más error. Otro problema con el uso de diccionarios surge con la especificidad de dominio, ya que las palabras extraídas de un conjunto de entrenamiento de textos de un dominio no se pueden generalizar a los textos de otros dominios, por lo que Grimmer y Stewart (2013) recomiendan usar diccionarios personalizados.

En el idioma español, el problema de la generalización de la asignación de valor positivo, negativo o neutro de los textos extraídos en diferentes dominios se vuelve más importante, debido a las variaciones idiomáticas que tiene el lenguaje en los diversos países Latinoamericanos. Por lo tanto, este estudio pretende proponer una solución al problema de identificar el sentimiento de comentarios plasmados en forma de texto en redes sociales en el idioma español, usando como ejemplo el contexto político de una provincia de Argentina. El artículo está organizado de la siguiente manera: comenzamos con una revisión de literatura sobre redes sociales y análisis de sentimiento en política. A continuación, describimos la metodología utilizada, detallando las cuatro etapas consideradas. Luego siguen los resultados del estudio, y finalmente las conclusiones de la investigación, mostrando algunas líneas de trabajo futuro.

Revisión de Literatura

Redes Sociales y Política

En el contexto político, las redes sociales tienen cada vez un papel más importante y pueden aumentar la participación política ya que favorecen la creación de un diálogo entre el candidato y el elector con mayor alcance (Stieglitz & Dang-Xuan, 2012). Tradicionalmente, el diálogo era iniciado y organizado por políticos, empresas y periodistas (Chadwick, 2006); mientras que ahora, las personas manifiestan sus opiniones y sentimientos de un determinado acontecimiento acerca del candidato o grupo político mediante publicaciones o valoraciones en las redes sociales, por lo que es importante para los políticos tener una idea del valor emocional y sentimental que expresan las personas en dichas plataformas, independientemente que sea positivo o negativo (Stieglitz & Dang-Xuan, 2012).

Las redes sociales pueden dar información complementaria a las encuestas tradicionales, ya que no solo es una herramienta para obtener información de una manera más económica y rápida, sino que se puede monitorear el día a día de cualquier evento, incluso se puede hacer seguimiento minuto a minuto (Ceron et al., 2015). Otra posibilidad que ofrecen las redes sociales es el rastreo de las tendencias en tiempo real, pudiendo incluso capturar los cambios repentinos en la opinión pública con antelación a que se pueda

detectar dicho cambio con los métodos tradicionales, como las encuestas o los debates televisivos (Jensen y Anstead, 2013). Tjong Kim Sang & Bos (2012) afirman que analizando las redes sociales de forma adecuada se puede pronosticar con cierto nivel de confiabilidad el resultado final de unas elecciones. Sin embargo, dada la gran cantidad de datos sobre la opinión pública disponible en línea y los diferentes métodos para analizarlos, el problema es seleccionar el método más apropiado (Ceron et al., 2015).

En Estados Unidos, las elecciones presidenciales del 2012 fueron escenario de diversas investigaciones por la célebre participación de Barack Obama como candidato. Wang et al. (2012) y Groshek y Al-Rawi (2013) estudiaron el desempeño de la campaña electoral y las reacciones de la opinión pública vía Twitter. Los resultados mostraron la variación constante de los sentimientos y emociones del público ante los eventos y noticias electorales. En el contexto Latinoamericano, un estudio reciente muestra el impacto del discurso usado en las redes sociales en la opinión pública de los ciudadanos (Bohorquez, en prensa). Estas investigaciones no hacen más que abrir el camino de nuevos estudios para profundizar en el tema.

Análisis de Sentimiento: Definición y Aplicación en Política

El análisis del sentimiento se utiliza para identificar la polaridad o la tonalidad de los textos evaluando las expresiones que las personas usan (Mohammad, 2016). Dado que las opiniones textuales de los electores pueden ser difíciles de ser procesadas y analizadas manualmente; se precisa un sistema automático que extraiga de las opiniones de las personas los sentimientos expresados, por ello se creó el análisis del sentimiento; el cual es un proceso que analiza el juicio, sentimientos, apreciaciones, actitudes y emociones de las personas con respecto a un producto, servicio, organización, persona, evento o problema (Liu, 2012). Según Nasukawa & Yi (2003), en el campo del Procesamiento del Lenguaje Natural (PNL), el análisis de sentimiento determina si un texto presenta una connotación positiva, negativa o neutral; de manera que conlleva a la identificación de expresiones de sentimientos, polaridad, fuerza de las expresiones, y su relación con el sujeto estudiado.

Esta área del conocimiento está dominada por los enfoques automatizados cuyo progreso varía mucho según el idioma (Mohammad, 2016). Haselmayer & Jenny (2017) indican que tanto el análisis de texto automatizado como el manual requieren un paso inicial de codificación del sentimiento de una unidad de texto: Los enfoques automatizados, supervisados y no supervisados, emplean textos de muestra con calificaciones de sentimiento codificadas para que el algoritmo pueda aprender el sentimiento de las palabras, y pueda luego ser escalable a grandes corpus de texto. Por otro lado, la codificación manual no se escala bien, ya que se depende de los codificadores humanos, quienes no pueden calificar grandes cantidades de textos (Haselmayer & Jenny, 2017).

Esta herramienta se ha utilizado en múltiples campos, incluido el contexto político, para establecer la polarización de los debates parlamentarios (Monroe et al., 2008), para identificar las posiciones de la opinión pública en los debates en línea (Ceron et al., 2012), para predecir los resultados de las contiendas electorales (Ceron et al., 2015), entre otras aplicaciones. Las primeras investigaciones en el marco electoral empezaron en Alemania con la elección federal del Parlamento Nacional en Alemania. Tumasjan et al. (2010) utilizó el análisis de sentimientos con la data de las publicaciones en Twitter para comprobar si coincidían entre los sentimientos online y los sentimientos offline de los usuarios, y con ello analizar si la herramienta cumplía el rol de predictor de las elecciones; los resultados fueron positivos al concluir que los usuarios si proyectan sus sentimientos y emociones en Twitter, y reflejan en dicha red su intención de voto.

Metodología

Para obtener la clasificación de sentimiento positivo o negativo, se utilizó la combinación de distintas técnicas de pre-procesamiento de datos para crear un lexicón de términos polarizados (diccionario de polaridad) que luego utiliza un algoritmo de clasificación. Para entrenar el clasificador se realizaron las siguientes etapas:

Etapas:

- Capa de correcciones ortográficas
- Clasificación manual de primeros casos usando word2vec para identificar términos negativos y positivos basados en términos conocidos

- Proceso de pseudo clasificación utilizando primera clasificación manual
- Creación de modelo de clasificación

Corrección ortográfica

Las palabras escritas de forma incorrecta constituyen uno de los problemas encontrados en los comentarios al momento de entrenar un clasificador con la técnica bag-of-words, donde cada palabra se representada como un vector. En estos casos palabras como “vergüenza” y “berguenza”, eran representadas como vectores diferentes. El caso de la palabra vergüenza, representaba un 4.6% escrita de forma incorrecta, mientras que otras palabras como hipócrita eran escritas sin h en un 13,8% de los casos.

Para compensar este escenario, se utilizó la técnica de sustitución de letras con misma fonética, logrando así la colisión entre palabras. Otro procedimiento realizado fue el eliminar la letra h al inicio de todas las palabras que la contengan, así se lograba colisión entre palabras escritas sin h de forma incorrecta y palabras escritas correctamente. Las sustituciones que tuvieron mayor cantidad colisiones se muestran en la Tabla 1.

w → u
np → mp
nb → mb
ce → se
ci → si
v → b
z → s

Tabla 1. Sustituciones por corrección ortográfica

La implicación de agregar una capa de corrección ortográfica consistió en que se dieron algunos casos de palabras que colisionaron y que no necesariamente tenían mismo significado. Ejemplo de colisiones encontradas:

Siervo (palabra original: siervo de iglesia) transformada a "sierbo"

Ciervo (palabra original: animal) transformada a "sierbo"

Al analizar los casos encontrados no se identificó un deterioro de la performance del clasificador con las palabras colisionadas con significado diferente. Estos casos fueron considerados como casos atípicos.

Clasificación manual de primeros casos usando word2vec para identificar términos negativos y positivos basados en términos comunes

Para clasificar los primeros textos de forma manual, un único analista, con conocimiento del contexto político regional, analizó los comentarios con palabras negativas para dicho contexto; tales como corrupción, ladrón, mentira, etc. Para esta tarea se entrenó el algoritmo word2vec (utilizando la librería gensim de Python, con los siguientes parámetros: vector_size = 300; window = 3; type= continuous bag-of-words (CBOW); iteraciones = 150), que calcula la cercanía entre términos, permitiendo identificar palabras similares dentro de un contexto político. Una búsqueda de estas palabras arrojó términos similares, que luego permitieron buscar y analizar comentarios que contengan estas palabras, tal como se muestra en la Tabla 2.

<i>CORRUPCIÓN</i>	<i>LADRON</i>	<i>MENTIRA</i>
<i>pobreza</i>	<i>chorro</i>	<i>promesa</i>
<i>violencia</i>	<i>mentiroso</i>	<i>joda</i>
<i>impunidad</i>	<i>chanta</i>	<i>pavada</i>
<i>injusticia</i>	<i>traidor</i>	<i>farsa</i>
<i>soberbia</i>	<i>sinverguenza</i>	<i>estupidez</i>
<i>mafia</i>	<i>inutil</i>	<i>rata</i>
<i>conservadores</i>	<i>infeliz</i>	<i>porqueria</i>
<i>atraso</i>	<i>bandido</i>	<i>laca</i>
<i>delincuencia</i>	<i>oligarca</i>	<i>lakra</i>
<i>grieta</i>	<i>corupto</i>	<i>cosa</i>

Tabla 2. Palabras cercanas identificadas, en un contexto político

Al analizar algunos comentarios que contenían estas palabras, pudimos determinar que este contenido al ser identificado como negativo evitaba que el comentario fuera clasificado como positivo. Ejemplos: “Felicidades gobernador, por fin se van los corruptos”; “Eres el mejor, no como el otro que era corrupto”. Estos casos también se consideraron como atípicos.

Proceso de pseudo clasificación utilizando primera clasificación manual

Luego de encontrar y clasificar comentarios negativos, usando la técnica de búsqueda por palabras negativas, se entrenó un modelo usando el algoritmo random forest, que trataba de modelar la clasificación correcta para estos comentarios sobre el resto de los comentarios. Una vez obtenido el modelo, se ejecuta la predicción sobre todo el dataset de entrenamiento, y se analizan los comentarios con mayor probabilidad de ser negativo arrojados por el modelo, para así incluirlos como reales comentarios negativos. Posteriormente, se realizaron varias iteraciones hasta agotar la existencia de comentarios clasificados como negativos por el algoritmo random forest. Se muestra un esquema de la pseudo clasificación en la Figura 1.

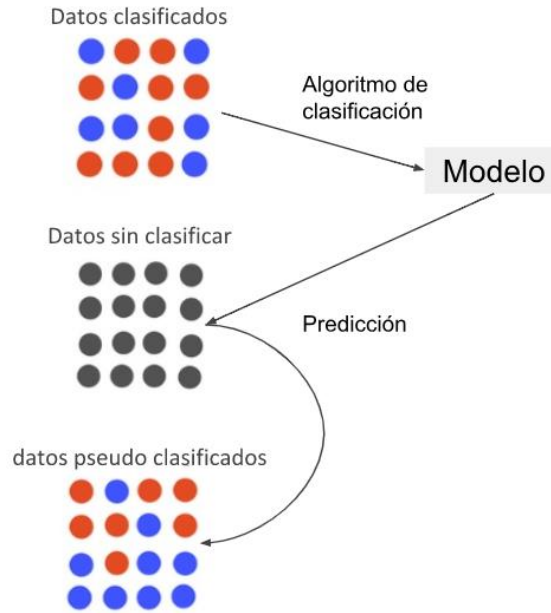


Figura 1. Esquema de pseudo clasificación

Creación de modelo de clasificación

Luego de tener el data set con comentarios negativos, se entrenaron tres clasificadores: El primero de ellos utilizando una Regresión Logística (one vs. all), luego Support Vector Machine (SVM), y finalmente Random Forest; utilizando diferentes proporciones de datos para entrenamiento y test. Se muestra un esquema del modelo de clasificación en la Figura 2. Con la predicción de estos tres modelos, se utilizó la técnica de stacking, combinando estas salidas o predicciones con una nueva Regresión Logística, que arrojaba la probabilidad final de tal o cual sentimiento para cada comentario.

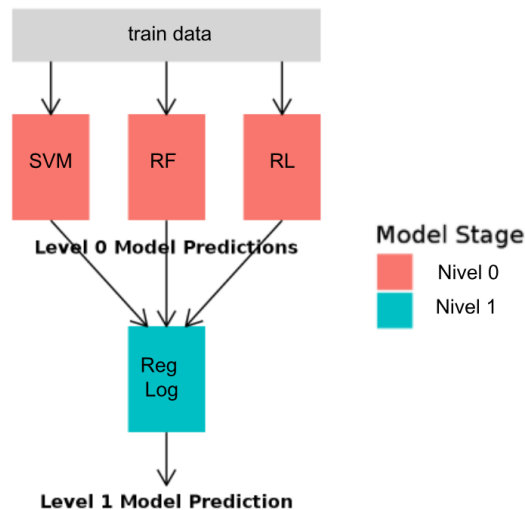


Figura 2. Esquema del modelo de clasificación

Resultados

De acuerdo con la metodología descrita, se utilizó inicialmente una base de datos referida a comentarios realizados por ciudadanos en cuentas de Facebook de candidatos políticos de la Provincia de Corrientes de la Argentina, durante el periodo marzo a mayo del 2018, totalizando 89.782 comentarios.

Con el objetivo de identificar aquellos comentarios de índole negativa para el candidato, se utilizaron técnicas de búsqueda por palabras negativas y se entrenó un modelo utilizando el algoritmo random forest, que trataba de modelar la clasificación correcta para estos comentarios sobre el resto de los comentarios. Esto tuvo como resultado un 6% de comentarios clasificados como negativos sobre el total de comentarios.

Luego, a este data set se le aplicaron las técnicas referidas en la sección anterior: Regresión Logística (one vs. all), luego SVM (Support Vector Machine), y finalmente Random Forest, para obtener el modelo de clasificación deseado.

A continuación, se exponen los resultados obtenidos de aplicar la técnica de stacking combinada con Regresión Logística, sobre el dataset definido, y considerando un nuevo split aleatorio de entrenamiento y test restante; donde la salida obtenida arrojó un 93% de precisión en la prueba realizada. Aunque los resultados de estudios previos no son comparables por haber utilizados otros dataset, a nivel referencial vale mencionar que obtuvieron desde un 59% de precisión (Wang et al., 2012) a un 72.8% (Yaqub et al., 2017). Los resultados del presente estudio se muestran en la Figura 3.

```

creating staking_matrix
PREDICCION NEG POS SEM
REAL
NEG      181    1    32
POS       1 1865   105
SEM       13   114 1003
precision recall f1-score support
NEG      0.93    0.85    0.89    214
POS      0.94    0.95    0.94   1971
SEM      0.88    0.89    0.88   1130
micro avg 0.92    0.92    0.92   3315
macro avg 0.92    0.89    0.90   3315
weighted avg 0.92    0.92    0.92   3315
    
```

Figura 3. Precisión de la predicción sobre data set

Posteriormente, se realizaron nuevas pruebas con diferentes distribuciones de data set para entrenamiento y test y se obtuvieron resultados similares, validando la robustez del modelo, tal y como se puede apreciar en la Figura 4.

```

creating staking_matrix
PREDICCION NEG POS SEM
REAL
NEG      201    5    27
POS       3 1840   111
SEM       17   101 1010
precision recall f1-score support
NEG      0.91    0.86    0.89    233
POS      0.95    0.94    0.94   1954
SEM      0.88    0.90    0.89   1128
micro avg 0.92    0.92    0.92   3315
macro avg 0.91    0.90    0.91   3315
weighted avg 0.92    0.92    0.92   3315

creating staking_matrix
PREDICCION NEG POS SEM
REAL
NEG      176    4    28
POS       4 1866   117
SEM       11   116 993
precision recall f1-score support
NEG      0.92    0.85    0.88    208
POS      0.94    0.94    0.94   1987
SEM      0.87    0.89    0.88   1120
micro avg 0.92    0.92    0.92   3315
macro avg 0.91    0.89    0.90   3315
weighted avg 0.92    0.92    0.92   3315
    
```

```

creating staking_matrix
PREDICCIÓN NEG POS SEM
REAL
NEG      192    6   30
POS       4  1871  85
SEM       17   136 974
      precision recall  f1-score  support
NEG      0.90    0.84    0.87    228
POS      0.93    0.95    0.94   1960
SEM      0.89    0.86    0.88   1127
micro avg 0.92    0.92    0.92   3315
macro avg 0.91    0.89    0.90   3315
weighted avg 0.92    0.92    0.92   3315

creating staking_matrix
PREDICCIÓN NEG POS SEM
REAL
NEG      2859   42   302
POS       35 27961 1228
SEM       170 1489 15590
      precision recall  f1-score  support
NEG      0.93    0.89    0.91   3203
POS      0.95    0.96    0.95  29224
SEM      0.91    0.90    0.91  17249
micro avg 0.93    0.93    0.93  49676
macro avg 0.93    0.92    0.92  49676
weighted avg 0.93    0.93    0.93  49676

```

Figura 4. Precisión de la predicción usando otros data sets

Conclusiones

Este estudio ofrece una solución a la problemática de identificar el sentimiento de comentarios en español en la red social Facebook, debido a las variaciones idiomáticas existentes en los diversos países Latinoamericanos, usando como ejemplo un escenario de comunicación política de una provincia de Argentina, con textos no conocidos. Esta problemática ha sido analizada y para resolverla se propone la combinación de un algoritmo de aprendizaje no supervisado, para hacer la pseudo clasificación, con un algoritmo de aprendizaje supervisado, para el modelo de clasificación. Esta solución surge como alternativa a clasificar manualmente miles de comentarios para lograr un dataset para entrenamiento del clasificador.

El análisis de sentimientos diseñado en este estudio es útil a cualquier investigador para que pueda implementarlo sin dificultad, ya que no hace falta partir previamente con un dataset clasificado y revisado de manera manual. El procedimiento descrito para monitorizar los comentarios políticos puede ayudar a mejorar las predicciones electorales, a probar los enfoques teóricos tradicionales y emergentes en la investigación de la opinión pública que requieren de datos longitudinales en series temporales.

Entre las contribuciones del estudio podemos resaltar que incluir una capa de pre-procesamiento, para corregir faltas ortográficas, es una alternativa válida para mejorar la representación del texto, reduciendo la vectorización y generando un clasificador con mayor precisión. Además, incluir un proceso de pseudo-clasificación ha mostrado ser un método útil ante la alternativa de clasificar de forma manual miles de comentarios para lograr un dataset a ser usado para entrenamiento de un clasificador.

Esta técnica también puede contribuir al contraste de hipótesis en estudios experimentales que necesitan entradas en tiempo determinados para crear o adaptar estímulos, y validar sus modelos teóricos, especialmente para académicos que puedan utilizar la técnica para llevar a cabo estudios descriptivos y correlacionales. Asimismo, puede ser utilizada por profesionales de marketing para complementar la monitorización y estudio que hacen a actos políticos en una región y planificar estrategias de comunicación y promoción política, especialmente en ocasiones donde el análisis e interpretación de sentimientos derivados de intervenciones políticas requiere análisis y conclusiones proactivos.

Como trabajo futuro se propone validar la metodología usada en otro contexto, por ejemplo, en una campaña política en otro país, de tal forma que se pueda comprobar la precisión del algoritmo. Otro campo interesante de aplicación podría ser su uso en el sector turístico, ya que identificando los comentarios negativos que se les da a los hoteles se pueden identificar oportunidades de mejora que sirvan para mejorar la satisfacción de los clientes.

REFERENCIAS

- Arcila-Calderón, C., Ortega-Mohedano, F., Jiménez-Amores, J., & Trullenque, S. (2017). Análisis supervisado de sentimientos políticos en español: clasificación en tiempo real de tweets basada en aprendizaje automático. *El profesional de la información*, 26(5), 973-982.
- Bayer, M., Sommer, W., & Schacht, A. (2012). Font size matters—Emotion and attention in cortical responses to written words. *PLOS ONE*, 7(5), e36042.
- Bohorquez, V. (en prensa). Efecto Mariposa de los Medios de Comunicación Sociales en la Opinión Pública: La revocatoria de la alcaldesa de Lima, Perú. *Estudios sobre el Mensaje Periodístico*.
- Ceron, A., Curini, L., & Iacus, S. M. (2015). Using Sentiment Analysis to Monitor Electoral Campaigns: Method Matters—Evidence From the United States and Italy. *Social Science Computer Review*, 33(1), 3-20.
- Ceron, A., Curini, L., & Iacus, S. M. (2012). Every tweet counts? How sentiment analysis of social media can improve our knowledge of citizens' political preferences with an application to Italy and France. *New Media & Society*, 16(2), 340-358.
- Chadwick, A. (2006). *Internet politics: states, citizens, and new communications technologies*. Oxford University Press: New York, NY, USA.
- Grimmer, J., & Stewart, B. M. (2013). Text as data: the promise and pitfalls of automatic content analysis methods for political texts. *Political Analysis*, 21(3), 267-297.
- Groshek, J., & Al-Rawi, A. (2013). Public Sentiment and Critical Framing in Social Media Content During the 2012 U.S. Presidential Campaign. *Social Science Computer Review*, 31(5), 563-576.
- Haselmayer, M., & Jenny, M. (2017). Sentiment analysis of political communication: combining a dictionary approach with crowdcoding. *Quality & Quantity*, 51(6), 2623-2646.
- Huffaker, D. (2010). Dimensions of leadership and social influence in online communities. *Human Communication Research*, 36(4), 593-617.
- Jensen, M. J., & Anstead, N. (2013). Psephological investigations: Tweets, votes, and unknown unknowns in the republican nomination process. *Policy & Internet*, 5, 161-182.
- Joyce, E., & Kraut, R. (2006). Predicting continued participation in newsgroups. *Journal of Computer-Mediated Communication*, 11(3), 723-747.
- Liu, B. (2012). *Sentiment Analysis and Opinion Mining*. Synthesis Lectures on Human Language Technologies. Morgan & Claypool Publishers: San Rafael, CA, USA.
- Mohammad, S. M. (2016). Sentiment analysis: detecting valence, emotions, and other affectual states from text. In: Meiselman, H. (ed.) *Emotion Measurement*, pp. 201-238. Elsevier: Amsterdam.
- Nasukawa, T., & Yi, J. (2003). Sentiment analysis: Capturing favorability using natural language processing. *Proceedings of the 2nd international conference on Knowledge capture*, 70-77. Sanibel Island, FL, EE.UU. - Octubre 23-25. Recuperado de <https://dl.acm.org/citation.cfm?doid=945645.945658>
- Soroka, S., Young, L., & Balmas, M. (2015). Bad news or mad news? Sentiment scoring of negativity, fear, and anger in news content. *The ANNALS of the American Academy of Political and Social Science*, 659(1), 108-121.
- Stieglitz, S., & Dang-Xuan, L. (2012). Social media and political communication: a social media analytics framework. *Social Network Analysis and Mining*, 3(4), 1277-1291.
- Stieglitz, S., & Dang-Xuan, L. (2012). Impact and diffusion of sentiment in public communication on Facebook. *Proceedings of 20th European Conference on Information Systems*. Paper 98. Barcelona, España - Jun 11-13. Recuperado de <http://aisel.aisnet.org/ecis2012/98>
- Tjong Kim Sang, E., & Bos, J. (2012). Predicting the 2011 Dutch senate election results with twitter. *Proceedings of SASN 2012, the EACL 2012 Workshop on Semantic Analysis in Social Networks*, Avignon, France.
- Wang, H., Can, D., Kazemzadeh, A., Bar, F., & Narayanan, S. (2012). A System for Real-time Twitter Sentiment Analysis of 2012 U.S. Presidential Election Cycle. *Proceedings of the ACL 2012 System Demonstrations*, 115-120. Jeju Island, Corea del Sur - Julio 8-14. Recuperado de <https://dl.acm.org/citation.cfm?id=2390490>
- Yaqub, U., Chun, S. A., Atluri, V., & Vaidya, J. (2017). Analysis of political discourse on twitter in the context of the 2016 US presidential elections. *Government Information Quarterly*, 34(4), 613-626.