

EL ANÁLISIS DE REDES SOCIALES (ARS) PARA EL ESTUDIO DEL EFECTO BUMERÁN EN LAS CAMPAÑAS DE COMUNICACIÓN EN REDES SOCIALES

Rafael CARRASCO POLAINO
Universidad Complutense de Madrid

Miguel Ángel MARTÍN CÁRDABA
Universidad Villanueva

1. INTRODUCCIÓN

El análisis de redes sociales (ARS) se ha consolidado como una metodología eficaz para estudiar la dinámica de la comunicación en plataformas digitales. Esta técnica permite mapear y cuantificar las relaciones e interacciones entre individuos, grupos y organizaciones, proporcionando una visión profunda de cómo fluye la información y cómo se forman las opiniones en entornos sociales. En el contexto de las campañas de comunicación, el ARS es particularmente útil para identificar y comprender fenómenos complejos como el efecto bumerán, donde un mensaje o campaña puede producir resultados contrarios a los esperados¹.

El efecto bumerán, conceptualizado por primera vez en estudios de comunicación persuasiva, se refiere a la reacción adversa que pueden generar ciertos mensajes, especialmente cuando estos son percibidos

¹ D. J. WATTS (2004), pp. 243-270.

como manipuladores o intrusivos². Este fenómeno es de particular relevancia en el entorno digital contemporáneo, donde las campañas de comunicación son rápidamente difundidas y comentadas en redes sociales, amplificando tanto sus impactos positivos como negativos³.

El ARS permite no sólo visualizar estas dinámicas, sino también identificar a los actores clave y comunidades que pueden amplificar o mitigar el efecto bumerán. Los nodos (individuos o entidades) y las aristas (conexiones entre nodos) en una red social proporcionan una estructura que facilita la comprensión de cómo se disemina la información y cómo se forman las respuestas colectivas⁴. Mediante el análisis de la centralidad y la detección de comunidades, es posible identificar a los líderes de opinión y los grupos más susceptibles al efecto bumerán.

En este contexto, la presente investigación se centra en la aplicación del ARS para analizar el efecto bumerán en campañas de comunicación. Utilizando datos extraídos de plataformas de redes sociales como X y Facebook, este estudio busca mapear las interacciones y evaluar cómo ciertos mensajes pueden desencadenar respuestas negativas, proporcionando así una herramienta valiosa para diseñadores de campañas que buscan maximizar el impacto positivo de sus comunicaciones y minimizar efectos adversos.

2. FUNDAMENTOS DEL ANÁLISIS DE REDES SOCIALES

El ARS se basa en la teoría de grafos, donde las entidades son representadas como nodos y las relaciones entre ellas como aristas. Esta representación permite analizar la estructura y la dinámica de las redes sociales de manera cuantitativa y cualitativa⁵.

Algunos de los conceptos clave en el ARS son:

En primer lugar, la centralidad, que mide la importancia de un nodo dentro de la red, identificando nodos que son cruciales para la diseminación de información. La centralidad puede ser de varios tipos, incluyendo centralidad de grado, de cercanía, y de intermediación⁶.

Los nodos se agrupan en comunidades. Subgrupos dentro de una red que tienen más conexiones internas que externas. La detección de

² C. I. HOVLAND, I. L. JANIS Y H. H. KELLEY (1953).

³ A. M. KAPLAN Y M. HAENLEIN (2010), pp. 59-68.

⁴ L. C. FREEMAN (2004).

⁵ M. E. J. NEWMAN (2010).

⁶ S. P. BORGATTI (2005), pp. 55-71.

comunidades es crucial para entender cómo se organizan y funcionan las redes sociales⁷.

Además, existen los puentes estructurales, que son nodos que conectan diferentes comunidades, jugando un papel crucial en la diseminación de información entre subgrupos⁸.

3. EL EFECTO BUMERÁN EN LA COMUNICACIÓN

El efecto bumerán en la comunicación se refiere a situaciones donde una campaña o mensaje produce resultados contrarios a los esperados. Este fenómeno fue inicialmente descrito en estudios de comunicación persuasiva, donde se observó que mensajes percibidos como manipulativos o coercitivos pueden generar resistencia y rechazo⁹. En el contexto de las redes sociales, el efecto bumerán puede ser amplificado debido a la rápida y extensa difusión de los mensajes y las reacciones de los usuarios¹⁰.

La teoría de la reactancia de Brehm (1966) es fundamental para entender el efecto bumerán. Esta teoría postula que los individuos experimentan una reacción emocional negativa cuando perciben una amenaza a su libertad de elección, lo que puede llevarlos a adoptar actitudes y comportamientos opuestos a los promovidos por el mensaje. En el entorno de las redes sociales, esta reactancia puede ser exacerbada por la naturaleza pública y viral de las interacciones¹¹.

4. APLICACIONES DEL ARS EN EL ESTUDIO DEL EFECTO BUMERÁN

El ARS ofrece una metodología robusta para estudiar el efecto bumerán en campañas de comunicación. Mediante el análisis de las interacciones y la estructura de las redes sociales, es posible identificar patrones y factores que contribuyen a este fenómeno.

Algunas aplicaciones específicas que incluye esta metodología podrían ser la identificación de influencers y líderes de opinión detectando nodos con alta centralidad de intermediación que pueden ser identificados como influenciadores clave que tienen la capacidad de amplificar o mitigar el efecto bumerán¹².

⁷ S. FORTUNATO (2010), pp. 75-174.

⁸ M.S. GRANOVETTER (1973), pp. 1360-1380.

⁹ J.W. BREHM (1966).

¹⁰ T. VAN LAER y K. DE RUYTER (2010).

¹¹ H. LEE y S.M. JANG (2013), pp. 1422-1436.

¹² E. KATZ, y P.F. LAZARSFELD (1955).

También se puede realizar un análisis de sentimiento, que consiste en evaluar el sentimiento de los mensajes en la red social puede proporcionar información sobre la percepción del público hacia la campaña, permitiendo identificar rápidamente reacciones negativas¹³.

Además, la detección de comunidades a la hora de analizar cómo se forman y evolucionan las comunidades alrededor de un tema puede ayudar a entender cómo se difunde el efecto bumerán y qué grupos son más susceptibles a este¹⁴.

El ARS proporciona, en definitiva, una herramienta poderosa para analizar y entender el efecto bumerán en campañas de comunicación. Al combinar técnicas de análisis estructural y de contenido, los investigadores y profesionales de la comunicación pueden diseñar estrategias más efectivas para minimizar los impactos negativos y maximizar la eficacia de sus mensajes.

5. PROCESO DEL ANÁLISIS DE REDES SOCIALES

Como se indicaba anteriormente, el análisis de redes sociales (ARS) se basa en la teoría de grafos y la teoría de redes, proporcionando un marco teórico y metodológico robusto para el estudio de las estructuras sociales. Esta metodología permite mapear y analizar las relaciones e interacciones entre individuos, grupos y organizaciones, revelando patrones y estructuras subyacentes que no son evidentes a simple vista¹⁵.

En el ARS, las entidades individuales se representan como nodos y las relaciones entre ellos como aristas. Esta representación gráfica permite la visualización y el análisis cuantitativo de las redes sociales. La teoría de grafos, desarrollada inicialmente en el ámbito de las matemáticas, proporciona las herramientas necesarias para analizar las propiedades estructurales de las redes, tales como la conectividad, la distancia y la centralidad¹⁶.

Dentro de la metodología ARS existen una serie de conceptos fundamentales como son el de centralidad como medida de la importancia de un nodo dentro de una red. Existen varios tipos de centralidad, cada uno capturando diferentes aspectos de la posición de un nodo en la red¹⁷.

La centralidad de grado mide el número de conexiones directas que un nodo tiene. Un nodo con alta centralidad de grado es un actor clave

¹³ B. PANG, y L. LEE (2008), pp. 1-135.

¹⁴ M. GIRVAN, y M. E. J. NEWMAN (2002), pp. 7821-7826.

¹⁵ J. SCOTT (2017).

¹⁶ D. B. WEST (2001).

¹⁷ L. C. FREEMAN (1979), pp. 215-239.

debido a su alto número de conexiones¹⁸. Por otro lado, la centralidad de cercanía mide la distancia promedio desde un nodo a todos los demás nodos en la red. Un nodo con alta centralidad de cercanía puede difundir información rápidamente a través de la red¹⁹. Por último, existe la centralidad de intermediación, que mide la frecuencia con la que un nodo actúa como intermediario en las rutas más cortas entre otros nodos. Un nodo con alta centralidad de intermediación tiene una posición estratégica para controlar el flujo de información.

Otro concepto relevante es relacionado con las comunidades, que son subgrupos de nodos dentro de una red que están más densamente conectados entre sí que con el resto de la red. La detección de comunidades es crucial para entender la organización interna y la dinámica de las redes sociales. Los métodos de detección de comunidades, como el algoritmo de Louvain, permiten identificar estas estructuras, proporcionando información sobre cómo se agrupan los nodos y cómo interactúan entre ellos²⁰.

Por último, y como se mencionaba anteriormente, los puentes estructurales son nodos que conectan diferentes comunidades dentro de una red. Estos nodos desempeñan un papel crucial en la diseminación de información entre subgrupos, actuando como enlaces que facilitan la comunicación y la transferencia de conocimiento. La presencia de puentes estructurales puede influir significativamente en la cohesión y la integración de la red.

De esta forma y a través de estos conceptos en el ámbito de la comunicación, el ARS permite analizar cómo se disemina la información y cómo se forman las opiniones en las redes sociales. Esto es particularmente relevante en el estudio del efecto bumerán, donde la identificación de influenciadores y comunidades puede ayudar a entender y mitigar los efectos adversos de las campañas de comunicación.

5.1. Recopilación de datos

La recopilación de datos es una etapa crucial en el análisis de redes sociales (ARS), ya que la calidad y la precisión de los datos afectan directamente la validez de los resultados del análisis. En el contexto del ARS, la recopilación de datos implica la obtención de información sobre las interacciones entre los nodos en una red. Esta información puede ser recolectada a través de diversas fuentes y técnicas, dependiendo del tipo de red y del propósito del estudio²¹.

¹⁸ S. P. BORGATTI y M. G. EVERETT (2006), pp. 466-484.

¹⁹ S. WASSERMAN y K. FAUST (1994).

²⁰ V. D. BLONDEL, J.-L. GUILLAUME, R. LAMBIOTTE y E. LEFEBVRE (2008), pp. 10008.

²¹ J. SCOTT y P. J. CARRINGTON (eds.) (2011).

Para la recopilación de datos las fuentes principales son las plataformas de redes sociales como X, Facebook e Instagram que resultan fuentes ricas de datos para el ARS. Estas plataformas permiten acceder a información detallada sobre las interacciones entre los usuarios, como menciones, comentarios, retweets, likes y compartidos. La API de Twitter, por ejemplo, es una herramienta comúnmente utilizada para extraer datos relacionados con tweets, hashtags y perfiles de usuarios²².

Otra fuente de datos son las encuestas y cuestionarios, que pueden ser diseñados para recoger información específica sobre las relaciones y la comunicación entre individuos. Este método es útil para obtener datos detallados sobre redes egocéntricas y redes personales, donde se requiere información sobre las conexiones directas de un individuo²³.

También existen bases de datos públicas que contienen información estructurada sobre relaciones y redes, como las redes de citas académicas (Google Scholar, Web of Science) y las redes de colaboración en proyectos de investigación. Estas bases de datos son valiosas para estudios longitudinales y análisis de redes grandes y complejas²⁴.

De la misma forma se pueden utilizar también diferentes técnicas de minería de datos como la extracción de Datos a través de APIs, proporcionadas por las plataformas de redes sociales permiten la extracción automatizada de grandes volúmenes de datos. Por ejemplo, la API de Twitter permite acceder a datos sobre tweets, usuarios, y tendencias, facilitando la construcción de redes basadas en menciones, retweets y seguidores²⁵.

El web scraping también es una técnica utilizada para extraer datos de sitios web cuando las APIs no están disponibles o son limitadas. Herramientas como BeautifulSoup y Scrapy en Python son ampliamente utilizadas para este propósito. El web scraping es útil para recolectar datos de comentarios, foros y otros contenidos generados por usuarios en sitios web²⁶.

En relación con la obtención o extracción de datos es importantes tener en cuenta ciertas consideraciones Éticas. La recopilación de datos para el ARS debe realizarse considerando los aspectos éticos, como la privacidad y el consentimiento de los participantes. Es fundamental asegurar que los datos sean anonimizados y que se respeten las políticas de privacidad de las plataformas de redes sociales y las regulaciones legales pertinentes²⁷.

²² A. BRUNS y S. STIEGLITZ (2013), pp. 91-108.

²³ P. V. MARSDEN (2011), pp. 370-388.

²⁴ K. BÖRNER, C. CHEN y K. W. BOYACK (2003), pp. 179-255.

²⁵ F. MORSTATTER, J. PFEFFER, H. LIU y K. M. CARLEY (2013), p. 400-408.

²⁶ R. MITCHELL (2015).

²⁷ M. ZIMMER, (2010), pp. 313-325.

5.2. Creación de la red

La creación de la red es una etapa fundamental en el análisis de redes sociales (ARS). Este proceso implica transformar los datos recopilados en una representación gráfica de la red, donde los nodos representan a los actores y las aristas las relaciones o interacciones entre ellos. La calidad y la precisión de esta representación son cruciales para la validez de los análisis subsiguientes²⁸.

El primer paso en la creación de una red es identificar los nodos y las aristas a partir de los datos recopilados. Los nodos pueden representar individuos, organizaciones o cualquier entidad de interés, mientras que las aristas representan las conexiones o interacciones entre estos nodos.

En una red social, los nodos generalmente representan usuarios o actores. En el contexto de las redes sociales en línea, estos nodos pueden ser perfiles de usuario en plataformas como Twitter, Facebook o Instagram.

Las aristas pueden representar diversos tipos de relaciones, como amistad, seguimiento, menciones, retweets, comentarios, entre otros. La naturaleza de las aristas dependerá del tipo de interacción que se esté analizando.

Las redes pueden ser dirigidas o no dirigidas, ponderadas o no ponderadas, dependiendo de la naturaleza de las interacciones. En las redes dirigidas las aristas tienen una dirección, indicando un flujo de información o influencia de un nodo a otro. Por ejemplo, en Twitter, un retweet o una mención es una relación dirigida. En el caso de las redes no dirigidas las aristas no tienen dirección y representan relaciones bidireccionales. Un ejemplo podría ser una red de amistad en Facebook, donde la amistad es mutua. Por último, existen las redes ponderadas, en donde las aristas tienen un peso que indica la fuerza o frecuencia de la relación. Por ejemplo, la cantidad de mensajes intercambiados entre dos usuarios²⁹.

Una vez identificados los nodos y las aristas, se construye una matriz de adyacencia. Esta matriz es una representación matemática de la red, donde las filas y columnas corresponden a los nodos y las celdas indican la presencia y, en su caso, el peso de una arista entre dos nodos³⁰.

²⁸ D. HANSEN, B. SHNEIDERMAN y M.A. SMITH (2010).

²⁹ A. BARRAT, M. BARTHELEMY, R. PASTOR-SATORRAS y A. VESPIGNANI (2004), pp. 3747-3752.

³⁰ S. BOCCALETTI, V. LATORA, Y. MORENO, M. CHAVEZ y D.-U. HWANG (2006), pp. 175-308.

5.3. Análisis de la estructura de la red

El análisis de la estructura de la red es una etapa esencial en el análisis de redes sociales (ARS), ya que permite comprender la organización y las dinámicas internas de las redes sociales. Este análisis se centra en examinar las propiedades estructurales de la red, identificando patrones de conexión, nodos clave, y comunidades dentro de la red. A través de técnicas cuantitativas y cualitativas, el ARS proporciona insights sobre cómo se disemina la información y cómo se forman las influencias dentro de una red.

Como se ha mencionado anteriormente, las medidas de centralidad son fundamentales para identificar los nodos más importantes dentro de una red. Estas medidas permiten determinar cuáles nodos tienen un papel crucial en la diseminación de información y la formación de influencias. También la detección de comunidades son técnicas muy útiles a la hora de analizar la estructura de la red, pero estos conceptos ya se han descrito con anterioridad.

Los conceptos que hacen referencia a las características básicas de una red en cuanto a su estructura no de forma relativa a las características fundamentales de sus miembros si no en cuanto a cómo se relacionan estos miembros entre sí son la cohesión de la red, que se refiere a la medida en que los nodos están conectados entre sí. Las redes altamente cohesivas tienden a ser más robustas y resistentes a la fragmentación. Los puentes estructurales son nodos que conectan diferentes comunidades y facilitan la diseminación de información entre ellas.

Además, la densidad de la red, que es una medida de la proporción de conexiones presentes en la red en relación con el número total posible de conexiones. Una alta densidad indica una red bien conectada, lo que puede facilitar la rápida difusión de información.

Por último, el coeficiente de agrupamiento, que mide la tendencia de los nodos a formar clústeres o tríadas cerradas. Un alto coeficiente de agrupamiento indica que los amigos de un nodo también tienden a ser amigos entre sí, lo que sugiere una fuerte cohesión local³¹.

5.4. Evaluación del contenido

La evaluación del contenido es una etapa crítica en el análisis de redes sociales (ARS) que complementa el análisis estructural al proporcionar insights sobre la naturaleza y el tono de las interacciones dentro de la red. Este análisis implica examinar el texto y el contexto de las

³¹ D. J. WATTS y S. H. STROGATZ (1998), pp. 440-442.

comunicaciones para entender mejor cómo se perciben y difunden los mensajes. La evaluación del contenido puede incluir análisis de sentimiento, análisis temático y detección de tendencias, lo cual es esencial para estudios de comunicación y marketing, entre otros.

El análisis de sentimiento se utiliza para determinar la polaridad (positiva, negativa o neutral) de los mensajes en las redes sociales. Este tipo de análisis es crucial para evaluar la percepción pública de una campaña de comunicación y para detectar posibles efectos bumerán³².

Para analizar el sentimiento se puede realizar un análisis léxico, que utiliza diccionarios de palabras con etiquetas de sentimiento (por ejemplo, positivo o negativo). Herramientas como VADER (Valence Aware Dictionary for Sentiment Reasoning) son populares para el análisis de sentimiento en redes sociales debido a su precisión y facilidad de uso³³.

También es común el uso de modelos de machine learning, que entrenan algoritmos de aprendizaje automático para clasificar el sentimiento basado en ejemplos etiquetados. Estos modelos pueden utilizar técnicas de procesamiento de lenguaje natural (PLN) como TF-IDF, embeddings de palabras, y redes neuronales recurrentes (RNN)³⁴.

El análisis de sentimiento puede ayudar a identificar la reacción del público a una campaña de comunicación, permitiendo ajustar estrategias en tiempo real. Por ejemplo, un aumento en el sentimiento negativo puede indicar la necesidad de modificar el mensaje o abordar preocupaciones específicas³⁵.

Por otro lado, el análisis temático se centra en identificar y explorar los temas recurrentes en el contenido de las redes sociales. Esta técnica es útil para entender los principales intereses y preocupaciones de los usuarios en relación con una campaña específica³⁶.

Para realizar un análisis temático se puede acudir a la codificación manual, que involucra la revisión manual de textos para identificar temas y patrones recurrentes. Este enfoque es intensivo en tiempo, pero proporciona un entendimiento profundo y contextualizado³⁷. También resulta práctico utilizar algoritmos automáticos que utilizan métodos como LDA (Latent Dirichlet Allocation) para identificar temas de manera automática. Estas técnicas son eficientes para grandes volúmenes de datos, aunque pueden requerir ajustes para mejorar la precisión³⁸.

³² B. LIU (2012).

³³ C. J. HUTTO y E. GILBERT (2014), p. 216-225.

³⁴ R. SOCHER, A. PERELYGIN, J. Y. WU, J. CHUANG, C. D. MANNING, A. Y. NG y C. POTTS (2013), p. 1631-1642.

³⁵ A. PAK y P. PAROUBEK (2010) p. 1320-1326.

³⁶ V. BRAUN y V. CLARKE, (2006), pp. 77-101.

³⁷ G. W. RYAN y H. R. BERNARD (2003), pp. 85-109.

³⁸ D. M. BLEI, A. Y. NG y M. I. JORDAN (2003), pp. 993-1022.

El análisis temático puede revelar cómo los diferentes segmentos de la audiencia perciben una campaña y qué aspectos del mensaje resuenan más con ellos. Esto es útil para segmentar la audiencia y personalizar mensajes futuros para mejorar la efectividad de la comunicación³⁹.

La detección de tendencias implica identificar patrones y cambios en el contenido de las redes sociales a lo largo del tiempo. Esto puede incluir el monitoreo de hashtags, palabras clave y menciones para detectar picos en la actividad o cambios en la percepción pública⁴⁰.

Para detectar tendencias se puede realizar un análisis temporal, que examina cómo cambia la frecuencia de ciertas palabras o temas a lo largo del tiempo. Herramientas como Google Trends y análisis de series temporales pueden ser útiles para este propósito⁴¹ o también, por ejemplo, un análisis de co-ocurrencia: Estudia cómo ciertas palabras o hashtags aparecen juntas en los mensajes, lo que puede indicar asociaciones emergentes y nuevos temas de interés⁴². La detección de tendencias puede alertar a los profesionales de la comunicación sobre cambios importantes en la percepción pública, permitiéndoles reaccionar rápidamente a nuevas oportunidades o amenazas. Por ejemplo, un aumento repentino en la mención de un problema específico puede requerir una respuesta de comunicación inmediata⁴³.

La identificación de patrones de efecto bumerán es crucial en el análisis de redes sociales (ARS) ya que permite comprender cómo ciertas campañas de comunicación pueden generar resultados opuestos a los esperados. A diferencia de los apartados previos que se enfocan en la recopilación y análisis de datos estructurales y de contenido, este apartado se concentra en cómo los datos recopilados pueden revelar reacciones adversas específicas dentro de la red.

El análisis de la difusión de información examina cómo se propagan los mensajes a través de la red. Identificar patrones de difusión puede revelar cómo se expande el efecto bumerán y qué nodos (usuarios) son clave en este proceso⁴⁴. Para ello se pueden crear mapas de difusión utilizando algoritmos de propagación y analizar las rutas de los mensajes negativos. Evaluar la centralidad de intermediación de los nodos para identificar a los principales propagadores de reacciones adversas.

También resulta de interés la identificación de influenciadores negativos, vital para entender quiénes están amplificando las reacciones adversas. Los influenciadores con alta centralidad pueden tener un

³⁹ R. V. KOZINETS (2002), pp. 61-72.

⁴⁰ J. LESKOVEC, L. BACKSTROM y J. KLEINBERG (2009), p. 497-506.

⁴¹ R. H. SHUMWAY y D. S. STOFFER (2017).

⁴² C. D. MANNING, P. RAGHAVAN y H. SCHÜTZE (2008).

⁴³ X. WANG, M. S. GERBER y D. E. BROWN (2012), p. 231-238.

⁴⁴ E. M. ROGERS (2003).

impacto desproporcionado en la percepción pública. Con el cálculo de las medidas de centralidad se puede identificar a los usuarios con mayor grado de influencia negativa y examinar el contenido generado por estos usuarios para entender mejor sus críticas.

De nuevo la detección de clústeres y comunidades dentro de la red permite identificar grupos de usuarios que comparten opiniones similares. Estos grupos pueden ser más susceptibles al efecto bumerán y amplificar las reacciones negativas. Aplicando los anteriormente mencionados algoritmos de detección de comunidades como el de Louvain para identificar subgrupos dentro de la red. Analizar el sentimiento predominante dentro de cada comunidad.

Por último, la evaluación de contenidos específicos que han desencadenado reacciones adversas permite identificar los elementos de la campaña que provocaron el efecto bumerán. Esto incluye el análisis de temas y palabras clave. Este análisis se puede conseguir realizando un análisis temático de los mensajes negativos utilizando LDA (Latent Dirichlet Allocation) para identificar los principales temas de crítica.

5.5. Visualización y reporte.

La visualización y el reporte son etapas cruciales en el análisis de redes sociales (ARS), ya que permiten interpretar y comunicar los hallazgos de manera efectiva. A través de representaciones gráficas y resúmenes analíticos, se pueden destacar patrones, estructuras y dinámicas de la red, facilitando la comprensión y la toma de decisiones⁴⁵.

Las herramientas más comunes para visualizar una red social son Gephi, NodeXL y Pajek.

Gephi es una herramienta de software libre ampliamente utilizada para la visualización y análisis de redes. Permite crear gráficos interactivos y aplicar algoritmos de análisis para identificar comunidades, medir la centralidad y visualizar la evolución de la red a lo largo del tiempo⁴⁶. Ofrece una amplia gama de opciones de visualización, incluyendo layout dinámicos como ForceAtlas, que ayudan a resaltar las estructuras subyacentes en la red⁴⁷.

NodeXL es un complemento de Excel que facilita la creación y análisis de redes sociales directamente en una hoja de cálculo. Es ideal para usuarios que prefieren un entorno más familiar y accesible. Permite importar datos de redes sociales, calcular métricas de red y generar

⁴⁵ S. K. CARD, J. D. MACKINLAY y B. SHNEIDERMAN (1999).

⁴⁶ M. BASTIAN, S. HEYMANN y M. JACOMY (2009), p. 361-362.

⁴⁷ M. JACOMY, T. VENTURINI, S. HEYMANN y M. BASTIAN (2014).

visualizaciones integradas. También ofrece opciones para automatizar la actualización de datos y la creación de informes.

Por último, Pajek es un programa diseñado para el análisis y visualización de redes grandes. Es especialmente útil para redes con un gran número de nodos y aristas, proporcionando herramientas avanzadas para la manipulación y el análisis de datos complejos⁴⁸. Permite trabajar con redes muy grandes, aplicando algoritmos de partición y detección de comunidades, así como generando visualizaciones tridimensionales⁴⁹.

Respecto de las técnicas más utilizadas para mostrar las redes de nodos, además de los mapas de red, que son representaciones gráficas de nodos y aristas que muestran la estructura de las relaciones en la red y que pueden ser ajustados para resaltar diferentes aspectos, como la centralidad, la densidad y las comunidades⁵⁰, existen los diagramas de clústeres, que muestran la agrupación de nodos en comunidades, facilitando la identificación de subestructuras dentro de la red. Estos diagramas son útiles para entender cómo se organizan las interacciones y para detectar grupos cohesivos (Fortunato, 2010).

En último lugar se pueden realizar un análisis temporal, que implica la visualización de cómo cambian las redes a lo largo del tiempo. Esto puede incluir gráficos de series temporales que muestran la evolución de métricas de red, como la centralidad o la densidad⁵¹.

6. CONCLUSIONES.

El uso de la metodología del análisis de redes sociales (ARS) para estudiar el efecto bumerán en campañas de comunicación en redes sociales ha demostrado ser una herramienta poderosa y efectiva. Esta metodología permite una comprensión profunda de las dinámicas de interacción y la propagación de mensajes en plataformas digitales, proporcionando insights valiosos que pueden ser utilizados para diseñar y ajustar estrategias de comunicación de manera más precisa y efectiva.

El ARS facilita la identificación de influenciadores y actores clave dentro de una red social que pueden amplificar o mitigar el efecto bumerán. Al analizar la centralidad de los nodos, se pueden detectar los usuarios que tienen un mayor impacto en la difusión de mensajes negativos o positivos.

⁴⁸ V. BATAGELJ y A. MRVAR (1998), pp. 47-57.

⁴⁹ W. DE NOOY, A. MRVAR y V. BATAGELJ (2011).

⁵⁰ R. DIESTEL (2017).

⁵¹ P. HOLME y J. SARAMÄKI (2012), pp. 97-125.

Mediante algoritmos de detección de comunidades, como el algoritmo de Louvain, es posible identificar subgrupos dentro de la red que comparten opiniones similares. Esto es crucial para entender cómo se forman y se propagan las opiniones adversas y para segmentar las audiencias de manera efectiva.

El ARS permite realizar análisis temporales que ayudan a rastrear la evolución de los sentimientos y las reacciones a lo largo del tiempo. Esto es esencial para identificar momentos críticos en los que el efecto bumerán se manifiesta con mayor intensidad y para ajustar las estrategias de comunicación en tiempo real.

El análisis de sentimiento proporciona una comprensión clara de cómo los mensajes son percibidos por la audiencia. Esto permite detectar rápidamente reacciones negativas y ajustar el contenido de la campaña para reducir el impacto adverso.

La identificación de temas recurrentes y palabras clave en los mensajes negativos permite a los comunicadores comprender mejor las preocupaciones y las percepciones de la audiencia. Esto facilita la creación de respuestas más informadas y dirigidas para abordar las críticas y preocupaciones específicas.

La calidad y precisión de los datos recopilados pueden influir en los resultados del análisis. Es crucial utilizar fuentes de datos confiables y considerar las limitaciones inherentes a los datos disponibles en las plataformas de redes sociales.

El ARS debe realizarse con una consideración cuidadosa de la privacidad y el consentimiento de los usuarios. Es importante cumplir con las políticas de privacidad de las plataformas de redes sociales y las regulaciones legales pertinentes para evitar el uso indebido de los datos.

Con el avance de tecnologías como la inteligencia artificial y el aprendizaje automático, hay oportunidades para desarrollar métodos más sofisticados para el análisis de redes sociales y la detección de efectos bumerán. Investigaciones futuras podrían enfocarse en la integración de estas tecnologías para mejorar la precisión y la eficacia del ARS.

Las redes sociales están en constante evolución, y nuevas plataformas emergen regularmente. Es esencial explorar y adaptar las metodologías del ARS a estas nuevas plataformas para mantenerse al día con las tendencias y los comportamientos de los usuarios.

La metodología del análisis de redes sociales ofrece un marco robusto y versátil para estudiar el efecto bumerán en campañas de comunicación en redes sociales. Al combinar el análisis estructural y de contenido, los comunicadores pueden diseñar estrategias más efectivas y adaptarse rápidamente a las reacciones de la audiencia,

minimizando los efectos adversos y maximizando el impacto positivo de sus campañas.

7. REFERENCIAS.

- BARRAT, A., BARTHELEMY, M., PASTOR-SATORRAS, R., y VESPIGNANI, A. (2004), «The architecture of complex weighted networks» en *National Academy of Sciences*, vol. 101, núm. 11, pp. 3747-3752.
- BASTIAN, M., HEYMANN, S. y JACOMY, M. (2009), «Gephi: An open source software for exploring and manipulating networks» en *International AAAI Conference on Weblogs and Social Media* vol. 3, núm. 1, pp. 361-362.
- BATAGELJ, V. y MRVAR, A. (1998), «Pajek-Program for large network analysis», *Connections*, vol. 21, núm. 2, pp. 47-57.
- BLEI, D. M., NG, A. Y. y JORDAN, M. I. (2003), «Latent Dirichlet Allocation», *Journal of Machine Learning Research*, núm. 3, pp. 993-1022.
- BLONDEL, V. D., GUILLAUME, J.-L., LAMBIOTTE, R. y LEFEBVRE, E. (2008) «Fast unfolding of communities in large networks», *Journal of Statistical Mechanics: Theory and Experiment*, vol. 2008, núm. 10, pp. 10008.
- BOCCALETTI, S., LATORA, V., MORENO, Y., CHAVEZ, M. y HWANG, D.-U. (2006), «Complex networks: Structure and dynamics», *Physics Reports*, vol. 424, núm. 4-5, pp. 175-308.
- BORGATTI, S. P. (2005), «Centrality and network flow», *Social Networks*, vol. 27, núm. 1, pp. 55-71.
- BORGATTI, S. P. y EVERETT, M. G. (2006), «A graph-theoretic perspective on centrality», *Social Networks*, vol. 28, núm. 4, pp. 466-484.
- BÖRNER, K., CHEN, C. y BOYACK, K. W. (2003), «Visualizing knowledge domains», *Annual Review of Information Science and Technology*, vol. 37, núm. 1, pp. 179-255.
- BRAUN, V. y CLARKE, V. (2006), «Using thematic analysis in psychology», *Qualitative Research in Psychology*, vol. 3, núm. 2, pp. 77-101.
- BREHM, J. W. (1966), *A theory of psychological reactance*, Academic Press.
- BRUNS, A. y STIEGLITZ, S. (2013), «Towards more systematic Twitter analysis: Metrics for tweeting activities», *International Journal of Social Research Methodology*, vol. 16, núm. 2, pp. 91-108.
- CARD, S. K., MACKINLAY, J. D. y SHNEIDERMAN, B. (1999), *Readings in information visualization: Using vision to think*, Morgan Kaufmann.
- DE NOOY, W., MRVAR, A. y BATAGELJ, V. (2011), *Exploratory social network analysis with Pajek*, Cambridge University Press.
- DIESTEL, R. (2017), *Graph theory* (5th ed.), Springer.
- FORTUNATO, S. (2010). «Community detection in graphs», *Physics Reports*, vol. 486, núm. 3-5, pp. 75-174.
- FREEMAN, L. C. (1979). «Centrality in social networks conceptual clarification», *Social Networks*, vol. 1, núm. 3, pp. 215-239.
- FREEMAN, L. C. (2004), *The development of social network analysis: A study in the sociology of science*, Empirical Press.
- GIRVAN, M. y NEWMAN, M. E. J. (2002), «Community structure in social and biological networks», *Proceedings of the National Academy of Sciences*, vol. 99, núm. 12, pp. 7821-7826.

- GRANOVETTER, M. S. (1973), «The strength of weak ties», *American Journal of Sociology*, vol. 78, núm. 6, pp. 1360-1380.
- HANSEN, D., SHNEIDERMAN, B. y SMITH, M. A. (2010), *Analyzing social media networks with NodeXL: Insights from a connected world*, Morgan Kaufmann.
- HOLME, P. y SARAMÄKI, J. (2012), «Temporal networks», *Physics Reports*, vol. 519, núm. 3, pp. 97-125.
- HOVLAND, C. I., JANIS, I. L. y KELLEY, H. H. (1953), *Communication and persuasion; psychological studies of opinion change*, Yale University Press.
- HUTTO, C. J. y GILBERT, E. (2014), «VADER: A parsimonious rule-based model for sentiment analysis of social media text» en *Proceedings of the International AAAI Conference on Weblogs and Social Media*, pp. 216-225.
- JACOMY, M., VENTURINI, T., HEYMANN, S. y BASTIAN, M. (2014), «ForceAtlas2, a continuous graph layout algorithm for handy network visualization designed for the Gephi software», *PloS One*, vol. 9, núm. 6.
- KAPLAN, A. M. y HAENLEIN, M. (2010), «Users of the world, unite! The challenges and opportunities of Social Media», *Business Horizons*, vol. 53, núm. 1, pp. 59-68.
- KATZ, E. y LAZARSFELD, P. F. (1955), *Personal influence: The part played by people in the flow of mass communications*, Free Press.
- KOZINETS, R. V. (2002), «The field behind the screen: Using netnography for marketing research in online communities», *Journal of Marketing Research*, vol. 39, núm. 1, pp. 61-72.
- LEE, H. y JANG, S. M. (2013), «Effects of anti-smoking advertisements on an individual's motivation to quit smoking: An application of the reactance theory», *Journal of Health Communication*, vol. 18, núm. 11, pp. 1422-1436.
- LESKOVEC, J., BACKSTROM, L. y KLEINBERG, J. (2009), «Meme-tracking and the dynamics of the news cycle» en *Proceedings of the 15th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 497-506.
- LIU, B. (2012), *Sentiment analysis and opinion mining*. Morgan & Claypool.
- MANNING, C. D., RAGHAVAN, P. y SCHÜTZE, H. (2008), *Introduction to Information Retrieval*, Cambridge University Press.
- MARSDEN, P. V. (2011), «Survey methods for network data» en J. Scott & P. J. Carrington (eds.), *The Sage Handbook of Social Network Analysis*, pp. 370-388, SAGE Publications.
- MITCHELL, R. (2015), *Web Scraping with Python: Collecting Data from the Modern Web*, O'Reilly Media.
- MORSTATTER, F., PFEFFER, J., LIU, H. y CARLEY, K. M. (2013), «Is the sample good enough? Comparing data from Twitter's streaming API with Twitter's Firehose» en *Proceedings of the Seventh International AAAI Conference on Weblogs and Social Media*, pp. 400-408.
- NEWMAN, M. E. J. (2010), *Networks: An introduction*, Oxford University Press.
- PAK, A. y PAROUBEK, P. (2010), «Twitter as a corpus for sentiment analysis and opinion mining», en *Proceedings of the International Conference on Language Resources and Evaluation*, pp. 1320-1326.
- PANG, B. y LEE, L. (2008), «Opinion mining and sentiment analysis», *Foundations and Trends in Information Retrieval*, vol. 2, núm. 1-2, pp. 1-135.
- ROGERS, E. M. (2003), *Diffusion of innovations*, 5.^a ed., Free Press.

- RYAN, G. W. y BERNARD, H. R. (2003), «Techniques to identify themes», *Field Methods*, vol. 15, núm. 1, pp. 85-109.
- SCOTT, J. (2017), *Social network analysis*, SAGE Publications.
- SCOTT, J. y CARRINGTON, P. J. (eds.). (2011), *The Sage Handbook of Social Network Analysis*, SAGE Publications.
- SHUMWAY, R. H. y STOFFER, D. S. (2017), *Time series analysis and its applications: With R examples*, Springer.
- SOCHER, R., PERELYGIN, A., WU, J. Y., CHUANG, J., MANNING, C. D., NG, A. Y. y POTTS, C. (2013), «Recursive deep models for semantic compositionality over a sentiment treebank» en *Proceedings of the 2013 Conference on Empirical Methods in Natural Language Processing*, pp. 1631-1642.
- VAN LAER, T. y DE RUYTER, K. (2010), «In stories we trust: How narrative apologies provide cover for competitive vulnerability after integrity-violating blog posts», *International Journal of Research in Marketing*, vol. 27, núm. 2, pp. 164-174.
- WANG, X., GERBER, M. S. y BROWN, D. E. (2012), «Automatic crime prediction using events extracted from Twitter posts» en *Proceedings of the International Conference on Social Computing, Behavioral-Cultural Modeling, and Prediction*, pp. 231-238.
- WASSERMAN, S. y FAUST, K. (1994), *Social network analysis: Methods and applications*, Cambridge University Press.
- WATTS, D. J. (2004), «The “new” science of networks», *Annual Review of Sociology*, vol. 30, pp. 243-270.
- WATTS, D. J. y STROGATZ, S. H. (1998), «Collective dynamics of ‘small-world’ networks», *Nature*, vol. 393, núm. 6684, pp. 440-442.
- WEST, D. B. (2001), *Introduction to graph theory* (2nd ed.), Prentice Hall.
- ZIMMER, M. (2010), «“But the data is already public”: On the ethics of research in Facebook», *Ethics and Information Technology*, vol. 12, núm. 4, pp. 313-325.