



Munich Personal RePEc Archive

Teleworking on Twitter: Analysis using Deep Learning

Gutierrez-Lythgoe, Antonio

University of Zaragoza

April 2023

Online at <https://mpra.ub.uni-muenchen.de/117101/>
MPRA Paper No. 117101, posted 19 Apr 2023 07:19 UTC

Teletrabajo en Twitter: Análisis mediante Deep Learning

Antonio Gutiérrez-Lythgoe

Abril, 2023

Abstract

In this article we analyse Twitter users' perceptions on remote working. To do so, we use artificial intelligence techniques of natural language processing. Specifically, we run a Sentiment Analysis and Latent Dirichlet Allocation (LDA) on a sample of 12,986 tweets related to remote working published in Spanish. Our results show that 21.2% of the tweets present a positive sentiment, 43.5% a negative sentiment and 35.3% a neutral connotation. This article contributes to the application of Machine learning and Deep learning techniques in the study of social sciences.

Resumen

En este artículo analizamos las opiniones de los individuos sobre la práctica del teletrabajo. Para ello, recurrimos a técnicas de inteligencia artificial de procesamiento de lenguaje natural. Concretamente, realizamos *Sentiment Analysis* y *Latent Dirichlet Allocation* (LDA) en una muestra de 12.986 tuits relacionados con el teletrabajo y publicados en español. Nuestros resultados muestran que 21,2% de los tuits muestran una connotación positiva, el 43,5% de los tuits una connotación negativa y el 35,3 % de los tuits una connotación neutral. Este artículo contribuye a la aplicación de técnicas de *Machine learning* y *Deep learning* en el estudio de las ciencias sociales.

Keywords: Artificial Intelligence, Sentiment analysis, Big Data, remote working, telework

JEL Classification: J22, J23, D83, C88

Introducción

Desde el comienzo de la pandemia del COVID-19 (Andrade et al., 2022), el teletrabajo ha formado parte de la rutina de los trabajadores con la intención de contribuir al equilibrio trabajo-familia (Giménez et al., 2012; Molina, 2021; Daneshfar et al., 2022). Nuevas investigaciones sugieren que este cambio de paradigma en el empleo no es transitorio, convirtiéndose en una práctica habitual (Barrero et al., 2021). La realidad es que el teletrabajo puede transformar y provocar cambios en los comportamientos que realizamos en nuestra rutina como el tiempo que dedicamos al trabajo (Gimenez-Nadal et al., 2020), la movilidad diaria (Mouratidis et al., 2021; Mouratidis & Papagiannakis, 2021; Ozbilen et al., 2021) o la salud mental (Gimenez-Nadal et al., 2018; Charalampous et al., 2019). Por otro lado, ha supuesto un importante reto para las empresas debido a la incertidumbre que genera respecto al rendimiento de los trabajadores (Golden et al., 2008; Bloom et al., 2015; Golden & Gajendran, 2019; Karl et al., 2022). Por estos motivos, es importante conocer la opinión pública del teletrabajo en un contexto post-pandémico (Saura et al., 2022).

Para ello, recurrimos a datos disponibles de las redes sociales; una perspectiva interesante en el contexto de la investigación en ciencias sociales, pues supone una aplicación de Big Data en este campo (Einav & Levin, 2014). Desde esta perspectiva, encontramos varias investigaciones, realizadas durante la pandemia, que incorporan datos obtenidos a través de la huella digital de los usuarios en RRSS (Javadian, 2007; Dubey & Tripathi, 2020; Zhang et al., 2021; Daneshfar et al., 2022; Karl et al., 2022; Saura et al., 2022). En este sentido, esta investigación supone un enfoque distinto, pues incorporamos un marco temporal posterior al establecido en investigaciones relacionadas. Es decir, analizamos los tuits publicados en la red social Twitter durante los meses de octubre y noviembre del año 2022, con el objetivo de comprobar si persisten los patrones establecidos en investigaciones anteriores (Dubey & Tripathi, 2020; Zhang et al., 2021; Daneshfar et al., 2022; Karl et al., 2022; Saura et al., 2022). Por otro lado, tomamos datos publicados en español. Esto supone un enfoque novedoso en esta línea sobre teletrabajo, pues hasta dónde conocemos el análisis de los tuits únicamente se ha realizado en tuits publicados en inglés¹.

En investigaciones previas con técnicas similares los resultados sugieren la existencia de un patrón claro en las connotaciones de los tuits de los usuarios. Estos estudios, realizados durante los meses posteriores al comienzo de la pandemia del coronavirus, muestran el impacto en la opinión pública de la transición hacia el (Daneshfar et al., 2022). En todos ellos, la mayoría de los tuits analizados presentan connotaciones positivas. En este Trabajo, investigamos si, tras esta transición, persiste el mismo patrón en los tuits publicados por los usuarios de Twitter. Con este objetivo, aplicamos un multilingüe modelo pre-entrenado basado en la técnica roBERTa, XLM-T (Barbieri et al., 2021). Este modelo nos permite obtener las probabilidades que cada tuit tenga una connotación positiva, negativa o neutra. Por otro lado, aplicamos un modelo de aprendizaje automático *Latent Dirichlet Allocation* (LDA) para identificar tópicos en los tuits. En este

¹ Encontramos literatura que aplica técnicas similares en tuits publicados en castellano en otros campos como la movilidad urbana (Osorio-Arjona et al., 2021).

estudio observamos que la mayoría de tuits que componen nuestra muestra presentan una connotación negativa.

Este artículo contribuye a la literatura en tres aspectos. Primeramente, incorpora Big Data en la investigación para ciencias sociales (Einav & Levin, 2014). En segundo lugar, contribuye al estudio de las ciencias sociales mediante técnicas de inteligencia artificial de procesamiento de lenguaje natural sobre tuits publicados en español (Lansley & Longley, 2016; Dubey & Tripathi, 2020; Osorio-Arjona et al., 2021; Zhang et al., 2021; Daneshfar et al., 2022; Karl et al., 2022; Saura et al., 2022). En tercer lugar, contribuye a la investigación sobre teletrabajo, ámbito relativamente inexplorado en las épocas previas de la pandemia (Olson et al., 1998), y que en la actualidad suscita gran interés en el entorno académico. Este artículo sigue la siguiente estructura. A continuación, en la Sección 2 incorporamos una breve revisión de la literatura con los trabajos que incorporan procesamiento de lenguaje natural. En la Sección 3, explicamos la recolección de la muestra y los datos empleados. La Sección 4 explica la metodología y el modelo empleado. En la Sección 5, exponemos los principales resultados de la investigación. Finalmente, la Sección 6, muestra las conclusiones fundamentales.

2. Revisión de la literatura. Investigando a partir de las Redes Sociales.

El comienzo de la pandemia condujo inevitablemente a la adopción del teletrabajo como fórmula indispensable para continuar con la jornada laboral sin incurrir en riesgos para la salud de los empleados (Daneshfar et al., 2022). Las últimas predicciones publicadas por Global Workplace Analytics en 2020, estimaban que el 25-30% de la fuerza de trabajo permanecería teletrabajando. Por otro lado, las estimaciones de Gartner Survey apuntaban a que el 82% de los empresarios planeaban mantener la posibilidad de que sus trabajadores trabajen en remoto tras la pandemia (Wrycza & Maślankowski, 2020). Estas cifras, provocaron un gran interés académico en esta práctica debido a la importancia de esta práctica tras la pandemia (Barrero et al., 2021).

De este modo, surgió una serie de artículos que incorporaban técnicas de procesamiento natural de texto (*Sentiment Analysis*) y de *text-mining* para analizar las opiniones de los usuarios de distintas redes sociales sobre el trabajo en remoto (Dubey & Tripathi, 2020; Hacker et al., 2020; Min et al., 2021; Zhang et al., 2021; Daneshfar et al., 2022; Karl et al., 2022; Saura et al., 2022). La minería de textos en las redes sociales se refiere al proceso de obtención de información de calidad a partir de un texto publicado (Wrycza & Maślankowski, 2020). El análisis de sentimiento se emplea para conocer la opinión o connotación de una publicación de medios sociales. Puede realizarse de diferentes maneras, incluyendo enfoques *lexicon-based* o en *machine learning*, o una combinación de ambos (Dhaoui et al., 2017; Wrycza & Maślankowski, 2020). Mediante metodologías distintas, la tendencia en los resultados parece clara, la mayor parte de los tuits tenían una connotación positiva, lo cual sugiere un sentimiento positivo de los individuos hacia el teletrabajo (Daneshfar et al., 2022).

En esta línea, predominan los trabajos que incorporan datos de Twitter (veasé Tabla 1), una red social de microblogging, en la cual cada usuario puede compartir sus opiniones y pensamientos e interactuar con otros usuarios. Por este motivo, constituye una fuente de datos muy atractiva para conocer las opiniones de los individuos (Java et al., 2007). En los últimos años, estos datos han emergido como una base muy interesante para distintos

campos de estudio, desde la movilidad urbana (Osorio-Arjona et al., 2021), el bienestar (Schwartz et al., 2013) o las ciencias de la salud (Paul & Dredze, 2011). La naturaleza de las interacciones entre los usuarios de Twitter y el uso de la aplicación configuran un entorno proclive para el análisis de sentimiento mediante técnicas de *Machine Learning* (Kumar & Jaiswal, 2020; Wrycza & Maślankowski, 2020).

Dubei & Tripathi (2020) analizan 100.000 tweets publicados entre el 15 de marzo y el 15 de abril de 2020, en pleno brote de la epidemia del COVID-19. Analizan las connotaciones de cada uno de ellos mediante NRC Emotion Lexicon (Mohammad & Turney, 2013). De este modo, pueden clasificar los tuits en positivos y negativos, y categorizarlos en 8 emociones: miedo, sorpresa, confianza, disfrute, anticipación, odio, decepción y tristeza. Los resultados muestran que el 73,10 % de los tuits son positivos, frente a un 26,10% negativos. Min et al. (2021) analizan 1.56 millones de tuits en EEUU durante 4 meses, desde el 1 de marzo al 1 de julio de 2020. Para ello aplican una técnica conocida como el Discontinuous Growth Model (DGM), que utilizan para observar cambios en las trayectorias de las opiniones sobre el teletrabajo. Estos autores utilizan un modelo de *Deep Learning*, conocida como BERT (*Bidirectional Encoder Representations from Transformers*), que permiten identificar las emociones de los tuits en torno a seis emociones básicas establecidas por Ekman (1992). En promedio, observan que las connotaciones de los tuits son ligeramente positivas, con un ligero descenso de la positividad hacia el fin de semana.

Daneshfar et al., (2022), elaboran un marco teórico de variables mediadoras y moderadoras entre el teletrabajo y sus resultados desde una perspectiva multidisciplinar. Al mismo tiempo, analizan 151.175 tuits publicados entre abril y octubre de 2020 mediante el paquete de Python TextBlob. Observan que la mayoría de los tuits son objetivos y positivos. Saura et al. (2022), a partir de 205.204 tuits publicados entre abril y agosto de 2021, analizan las opiniones sobre los distintos temas relacionados con el teletrabajo. Mediante el modelo LDA y el paquete de Python, concluyen que son 11 los temas más relevantes en el teletrabajo para los individuos. Tres de ellos (salud virtual, privacidad y estrés) adquieren connotaciones negativas, 4 adquieren connotaciones positivas (conciliación laboral, menor estrés, futuro y compromiso) y 3 adquieren una connotación neutral (Nuevas tecnologías, sostenibilidad y los problemas derivados del uso de la tecnología).

3. Datos

Uno de los retos principales a la hora de trabajar con datos de Twitter es el de confeccionar una muestra adecuada para el estudio (Osorio-Arjona et al., 2021). El reto principal es establecer el marco temporal adecuado. Siguiendo a (Osorio-Arjona et al., 2021), establecemos un intervalo temporal de dos meses. De esta manera, evitamos un enfoque de largo plazo que afecte a la homogeneidad de la muestra². En segundo lugar, seleccionamos que tipo de tuits compongan nuestra muestra. Utilizamos aquellos tuits que contienen al menos una de las tres siguientes palabras: teletrabajar, teletrabajo y

² En el ámbito de la movilidad han trabajado con enfoques de largo plazo, para resolver el problema de homogeneidad de la muestra eliminan ciertos días de la semana que presenten comportamientos dispares (Lansley & Longley, 2016)

teletrabajando. Palabras comúnmente empleadas en castellano para referirse a la práctica del trabajo en remoto. Este punto supone un enfoque diferenciador sobre la literatura que aplica técnicas de procesamiento de lenguaje natural, ya que es el primer, al menos hasta dónde conocemos, análisis en castellano (Saura et al., 2022). Descargamos los tuits aplicando la técnica de Web-Scrapping, que nos permite obtener los tuits públicos que contengan las palabras seleccionadas (Hernandez-Suarez et al., 2018). Obtenidos los tuits y la información asociada al mismo³, guardamos esta información en una base de datos NoSQL, MongoDB compass.

Para mejorar la calidad de nuestra muestra aplicaremos filtros utilizando la librería de Python Pandas (McKinney, 2012). En primer lugar, eliminamos tuits duplicados con la finalidad de mitigar la presencia de cuentas *bot* (Stieglitz et al., 2017). En segundo lugar, eliminamos aquellos tuits que contengan enlaces URL (Saura et al., 2022). Por otro lado, procesamos la fecha de los tuits, para saber qué día de la semana se publica cada tuit. De este modo, esperaríamos que durante la semana el número de tuits relacionados con el teletrabajo aumentase, disminuyendo durante el fin de semana.

4. Metodología

Obtenida y depurada la muestra, aplicamos un nuevo filtro que elimine los nombres de usuario de tal manera que anonimice la muestra y prepare el texto para un mejor procesamiento del lenguaje. De esta manera, dispondríamos de una muestra preparada para analizar las connotaciones de los tuits. Para ello, nos servimos un modelo descargado de *Hugging Face*⁴ (<https://huggingface.co/cardiffnlp/twitter-xlm-roberta-base-sentiment>) basado en un enfoque Optimizado y robusto para la técnica BERT⁵, conocido como roBERTa (Liu et al., 2019). Estos modelos mejoran los enfoques utilizados previamente en el procesamiento de lenguaje natural, conocidos como BERT (Devlin et al., 2018). Esto es debido a que mejora el entrenamiento de los modelos igualando o superando el rendimiento de estos (Liu et al., 2019). En este Trabajo, utilizamos el modelo multilingüe XLM-T (Barbieri et al., 2021).

Tanto los modelos BERT como los roBERTa son modelos *Deep Learning* pre-entrenados con grandes conjuntos de datos para realizar distintas tareas de procesamiento de lenguaje natural (Barbieri et al., 2021). De esta manera, los modelos aprenden representaciones lingüísticas universales, evitando el entrenamiento desde cero. Los modelos pre-entrenados de primera generación se entrenan con el objetivo de mejorar la técnica de aprendizaje conocida como *Word embedding*, a través de la cual se asigna un número real a cada palabra para que la inteligencia artificial procese el texto. La última o segunda generación de modelos pre-entrenados se entrena para aprender *Word embedding* con el contexto.

³ Usuario, fecha, localización del usuario, seguidores, seguidos, likes, retuits, descripción del perfil, etc...

⁴ Hugging Face, Inc. es una empresa de EEUU que desarrolla herramientas para la creación de aplicaciones de *machine learning*. Es conocida por la biblioteca *Transformers*, creada para aplicaciones de procesamiento del lenguaje natural, y su plataforma, que permite a los usuarios compartir modelos y conjuntos de datos de aprendizaje automático.

⁵ BERT, Representación de Codificador Bidireccional de Transformadores, es un método basado en redes neuronales para el pre-entrenamiento en el procesamiento del lenguaje natural desarrollado por Google

El modelo empleado, XLM-T, específico y entrenado para analizar tuits, permite el procesamiento de texto en 8 lenguajes distintos, entre ellos el español. Como podemos observar en Barbieri et al. (2021), este modelo ha sido confeccionado y afinado a través de una muestra de 198 millones de tuits en distintos idiomas. Estos autores, observan que los idiomas más frecuentes en su muestra son el inglés, portugués y el español, en este orden. Por tanto, configura una herramienta muy atractiva para procesar los tuits de nuestra muestra. Una vez aplicado el modelo obtendremos los resultados en valores reales. Aplicando la función *Softmax* convertimos los resultados en probabilidades. De esta manera, obtendremos la probabilidad de 0 a 1 de que el tuit analizado tenga una probabilidad positiva, negativa o neutra. Clasificaremos el tuit según el mayor valor obtenido para la probabilidad de las tres connotaciones posibles.

Seguidamente, aplicamos el modelo *Latent Dirichlet Allocation* (LDA). Este modelo estadístico identifica los temas relevantes en un documento de texto. Para ello, asume que cada documento de texto está compuesto por un determinado número de temas, y cada tema por una serie de palabras. De esta forma, mediante las distribuciones de probabilidad de cada palabra, estas se asignan a distintos tópicos o temas y así identificamos los tópicos principales del documento (Blei et al., 2003). Es importante mencionar, que este tipo de modelos requieren de un entrenamiento previo al análisis. Esto es debido a que en el proceso de entrenamiento el modelo estima los parámetros necesarios para el análisis de los documentos posteriores (Blei et al., 2003). Por este motivo, debemos obtener una muestra que sirva de entrenamiento, cuanto más similar sea la muestra de entrenamiento a la muestra de análisis mejor calibrado estará el modelo (Blei et al., 2003).

Para obtener la muestra de entrenamiento relacionada con el tema de la investigación, dividimos nuestra muestra en dos. Nuestra muestra de entrenamiento está compuesta por el 70% de los tuits de la muestra, el 30% restante compone la muestra de análisis. Realizamos esta separación de manera aleatoria. De este modo, podemos entrenar el modelo para la correcta estimación de los parámetros y tratar de inferir la temática de los tuits publicados en relación con el trabajo en remoto. La muestra de entrenamiento la componen 9090 tuits. La muestra de análisis 3896 tuits. Antes de la implementación del modelo, procesamos el texto⁶ a analizar:

1. Eliminamos caracteres raros
2. Eliminamos palabras con un solo carácter
3. Sustituimos los espacios en blanco
4. Convertimos el texto en minúsculas
5. Eliminamos palabras vacías⁷ y dígitos.

Para implementar este modelo recurrimos a la librería de Python Gensim (Rehurek & Sojka, 2011). En primer lugar, creamos un diccionario a través de la muestra de entrenamiento. La creación del diccionario sirve como representación de las palabras que aparecen en la muestra y de base para la construcción del corpus. El corpus es la representación vectorial de la muestra y es el elemento encargado de entrenar el modelo.

⁶ Algunos autores indican que el texto debe ser “Stemmizado”, es decir, las palabras deben ser reducidas a la raíz. Si bien es cierto que esto ayuda al rendimiento del modelo, no lo aplicamos para evitar pérdidas de información en las palabras.

⁷ Preposiciones, conjunciones artículos pronombres, etc.

De este modo, cada vector se asocia a un tuit de la muestra. Una vez entrenado el modelo con el corpus, podemos analizar la muestra de análisis e inferir los temas recurrentes.

5. Resultados

Para observar estos resultados en cifras observamos la Tabla 2, que recoge el número de veces que aparece una serie de palabras extraídas de las 500 más frecuentes en la muestra. Estos términos, podrían sugerir las distintas temáticas relevantes relativas al teletrabajo. Podemos observar que los términos más repetidos que podrían relacionarse con la conciliación laboral. Estos términos aparecen un total de 4001 ocasiones en la muestra. Otros términos frecuentes podrían vincularse a temas como los problemas técnicos, la ciudad/movilidad urbana, la salud (mental), la pandemia o el sector público.

En la Tabla 4 podemos observar los estadísticos descriptivos para las variables que disponemos en la muestra. Estas son: seguidores, seguidos, “me gusta”, “retuits”, la probabilidad media asociada a cada connotación (positiva, neutral y negativa) y los tuits positivos, negativos y neutros. Observamos gran variabilidad en el número de seguidores y seguidos de los usuarios que componen la muestra, con valores de la desviación típica superiores a los de la media. Lo cual sugiere presencia de usuarios atípicos que representen instituciones, medios de comunicación o personajes públicos. Observamos el mismo patrón respecto a los “me gusta” y “retuits” de los tuits que componen la muestra. Respecto a la clasificación de los tuits, observamos que el modelo a categorizado el 21,2% de los tuits con una connotación positiva. El 43,5% de los tuits analizados han sido clasificados con una connotación negativa y los tuits con categorizados con tono neutro representan el 35,3% de la muestra. De esta manera, observamos que en la muestra predominan los tuits con connotaciones negativas. Este aspecto se ve reforzado por la probabilidad media que presenta cada tipo de connotación en la muestra.

En la Figura 2, podemos observar un gráfico de columnas apiladas que presenta el número de tuits publicados cada día de la semana y la descomposición de acuerdo con su connotación. Como cabría esperar, se han publicado menos tuits durante los fines de semana. Respecto al tipo de tuit publicado, proporcionalmente, aparecen más tuits negativos el sábado (47,44% de los tuits son negativos) y el viernes (45,16%). Respecto a los tuits positivos y neutrales la proporción se mantiene constante. La Figura 3 muestra el número de tuits y su clasificación según connotación por horas. Comprobamos que la mayoría de los tuits se han publicado entre las 11 y 14 horas, estando el número de tuits negativos por encima del resto durante la mayoría del día. La Figura 4, la proporción de tuits según su clasificación a lo largo del marco temporal establecido. De nuevo, los tuits negativos presentan una mayor proporción durante la mayor parte del intervalo. Los tuits positivos, se encuentran claramente por debajo.

La Figura 4 representa en serie temporal la trayectoria de las emociones expresadas en los tuits de teletrabajo a lo largo del marco temporal. Se puede observar como persiste una mayor proporción de tuits negativos con algún solapamiento de tuits neutrales. Respecto a la evolución de los tuits positivos, la proporción se mantiene por debajo de los niveles que marcan las emociones neutras o negativas. Gráficamente, los datos sugieren cierta estabilidad en las tres series.

Respecto al modelo LDA, obtenemos 20 tópicos que representan agrupaciones de palabras que aparecen conjuntamente con una probabilidad determinada. Podemos observar las palabras que asignan a los distintos tópicos en las Figuras 5-8. En la Tabla 4, observamos los resultados numéricos para el modelo LDA. En la primera columna observamos las palabras asociadas a cada tópico y en la segunda columna las probabilidades asociadas a cada palabra. De esta manera, interpretamos que la palabra “teletrabajo” es un 8,4% más probable que aparezca en el Tópico 1, un 5,2% en el Tópico 2, un 5,7% en el Tópico 3 y un 8,2% en el Tópico 4. Analizando la coherencia de las palabras que aparecen en cada tópico podemos sugerir distintas temáticas de los tuits. El ejemplo más evidente es el Tópico 4, en el cual observamos concurrencia de palabras como: “Internet”, “servicio” o “atención”. Palabras que podrían estar asociadas en tuits referidos a cuestiones relacionadas a la tecnología y las telecomunicaciones. Podemos comprobar en la Tabla 4 como la palabra “Internet” y “Servicio” presentan una probabilidad de 14,4% y 8,4%, respectivamente, de pertenecer al Tópico 4. Las palabras asociadas al Tópico 2 sugieren la existencia de un grupo de tuits relacionados con la pandemia de Covid-19. La palabra “Covid” y “Sanidad” presentan un 4,2% y 1,2% mayor probabilidad de pertenecer a este tópico.

6. Conclusión

En este Trabajo se han analizado datos de Twitter con el objetivo de aproximarnos a la percepción pública sobre el teletrabajo. Con este objetivo, hemos utilizado una muestra de tuits relacionados con esta práctica y hemos aplicado técnicas de inteligencia artificial, concretamente, procesamiento de lenguaje natural. En primer lugar, hemos aplicado un análisis de sentimiento sobre los tuits a partir del modelo XML-T. Este modelo basado en roBERTa, es una técnica de *Deep Learning* que nos permite clasificar los tuits según su connotación positiva, neutra o negativa. En segundo lugar, aplicamos un modelo LDA a partir del paquete de Gensim en Python. Este tipo de modelos, permiten identificar tópicos frecuentes en documentos de textos mediante técnicas de aprendizaje automático o *Machine Learning*.

Los resultados señalan que el 43,5% de los tuits analizados presentan una connotación negativa, el 35,5% una connotación neutra y el 21,1% positiva. De este modo, observamos como los tuits negativos sobre el teletrabajo son más frecuentes en nuestra muestra. Este aspecto marca una diferencia clara con otros artículos que analizan las connotaciones de los tuits sobre teletrabajo durante los meses inmediatos al comienzo de la pandemia. Respecto a los resultados del modelo LDA, estos sugieren la presencia de dos temas recurrentes en nuestra muestra, cuestiones relacionadas con los sistemas de telecomunicación que posibilitan el teletrabajo y tuits en relación con la pandemia del coronavirus.

En definitiva, este trabajo ha analizado a través de inteligencia artificial la percepción pública del trabajo en remoto de los usuarios hispanohablantes. Las limitaciones principales de esta investigación son dos: la posible presencia de bots en la muestra y el tamaño de la muestra para la implementación del modelo de aprendizaje automático LDA. Los resultados de este trabajo son reveladores pues logramos identificar la percepción de

los individuos a partir de su comportamiento en las redes sociales. Los resultados sugieren el dominio de la connotación negativa en los tuits relativos al teletrabajo.

7. Referencias

- Andrade, C., Gillen, M., Molina, J.A. and Wilmarth, M.J. (2022). The social and economic impact of Covid-19 on family functioning and well-being: Where do we go from here? *Journal of Family and Economic Issues*, 43, 205-212.
- Baker, M. (2020). Gartner survey reveals 82% of company leaders plan to allow employees to work remotely some of the time. *Gartner Survey Reveals*, 82.
- Barbieri, F., Anke, L. E., & Camacho-Collados, J. (2021). *XLM-T: Multilingual Language Models in Twitter for Sentiment Analysis and Beyond*. <http://arxiv.org/abs/2104.12250>
- Barrero, J. M., Bloom, N., & Davis, S. J. (2021). *Why working from home will stick*. National Bureau of Economic Research.
- Blei, D. M., Ng, A. Y., & Jordan, M. I. (2003). Latent dirichlet allocation. *Journal of machine Learning research*, 3(Jan), 993-1022.
- Bloom, N., Liang, J., Roberts, J., & Ying, Z. J. (2015). Does working from home work? Evidence from a chinese experiment. *Quarterly Journal of Economics*, 130(1), 165–218. <https://doi.org/10.1093/qje/qju032>
- Charalampous, M., Grant, C. A., Tramontano, C., & Michailidis, E. (2019). Systematically reviewing remote e-workers' well-being at work: a multidimensional approach. *European Journal of Work and Organizational Psychology*, 28(1), 51–73. <https://doi.org/10.1080/1359432X.2018.1541886>
- Daneshfar, Z., Asokan-Ajitha, A., Sharma, P., & Malik, A. (2022). Work-from-home (WFH) during COVID-19 pandemic – A netnographic investigation using Twitter data. *Information Technology and People*. <https://doi.org/10.1108/ITP-01-2021-0020>
- Devlin, J., Chang, M.-W., Lee, K., & Toutanova, K. (2018). Bert: Pre-training of deep bidirectional transformers for language understanding. *ArXiv Preprint ArXiv:1810.04805*.
- Dhaoui, C., Webster, C. M., & Tan, L. P. (2017). Social media sentiment analysis: lexicon versus machine learning. *Journal of Consumer Marketing*.
- Dubey, A. D., & Tripathi, S. (2020). Analysing the sentiments towards work-from-home experience during COVID-19 pandemic. In *Journal of Innovation Management* (Vol. 8, Issue 1, pp. 13–19). Universidade do Porto - Faculdade de Engenharia. https://doi.org/10.24840/2183-0606_008.001_0003
- Einav, L., & Levin, J. (2014). Economics in the age of big data. *Science*, 346(6210). <https://doi.org/10.1126/science.1243089>
- Ekman, P. (1992). *Are there basic emotions?*
- Giménez, J.I., Molina, J.A. and Ortega, R. (2012). Self-employed mothers and the work-family conflict. *Applied Economics*, 44, 2133-2148.
- Giménez-Nadal, J.I., Molina, J.A. and Velilla, J. (2020). Work time and well-being for workers at home: evidence from the American Time Use Survey. *International Journal of Manpower*, 41(2), 184-206.

- Golden, T. D., & Gajendran, R. S. (2019). Unpacking the Role of a Telecommuter's Job in Their Performance: Examining Job Complexity, Problem Solving, Interdependence, and Social Support. *Journal of Business and Psychology*, 34(1), 55–69. <https://doi.org/10.1007/s10869-018-9530-4>
- Golden, T. D., Veiga, J. F., & Dino, R. N. (2008). The Impact of Professional Isolation on Teleworker Job Performance and Turnover Intentions: Does Time Spent Teleworking, Interacting Face-to-Face, or Having Access to Communication-Enhancing Technology Matter? *Journal of Applied Psychology*, 93(6), 1412–1421. <https://doi.org/10.1037/a0012722>
- Hacker, J., vom Brocke, J., Handali, J., Otto, M., & Schneider, J. (2020). Virtually in this together—how web-conferencing systems enabled a new virtual togetherness during the COVID-19 crisis. *European Journal of Information Systems*, 29(5), 563–584. <https://doi.org/10.1080/0960085X.2020.1814680>
- Hernandez-Suarez, A., Sanchez-Perez, G., Toscano-Medina, K., Martinez-Hernandez, V., Sanchez, V., & Perez-Meana, H. (2018). *A Web Scraping Methodology for Bypassing Twitter API Restrictions*. 1–7. <http://arxiv.org/abs/1803.09875>
- Java, A., Song, X., Finin, T., & Tseng, B. (2007). *Why We Twitter: Understanding Microblogging Usage and Communities*. <http://www.pownce.com>
- Javadian, R. (2007). Social work responses to earthquake disasters: A social work intervention in Bam, Iran. *International Social Work*, 50(3), 334–346.
- Karl, K. A., Peluchette, J. v., & Aghakhani, N. (2022). Virtual Work Meetings During the COVID-19 Pandemic: The Good, Bad, and Ugly. *Small Group Research*, 53(3), 343–365. <https://doi.org/10.1177/10464964211015286>
- Kumar, A., & Jaiswal, A. (2020). Systematic literature review of sentiment analysis on Twitter using soft computing techniques. *Concurrency and Computation: Practice and Experience*, 32(1), e5107.
- Lansley, G., & Longley, P. A. (2016). The geography of Twitter topics in London. *Computers, Environment and Urban Systems*, 58, 85–96. <https://doi.org/10.1016/j.compenvurbsys.2016.04.002>
- Liu, Y., Ott, M., Goyal, N., Du, J., Joshi, M., Chen, D., Levy, O., Lewis, M., Zettlemoyer, L., & Stoyanov, V. (2019). *RoBERTa: A Robustly Optimized BERT Pretraining Approach*. <http://arxiv.org/abs/1907.11692>
- McKinney, W. (2012). *Python for data analysis: Data wrangling with Pandas, NumPy, and IPython*. “O'Reilly Media, Inc.”
- Min, H., Peng, Y., Shoss, M., & Yang, B. (2021). Using machine learning to investigate the public's emotional responses to work from home during the COVID-19 pandemic. *Journal of Applied Psychology*, 106(2), 214.
- Mohammad, S. M., & Turney, P. D. (2013). Crowdsourcing a word–emotion association lexicon. *Computational Intelligence*, 29(3), 436–465.

- Molina, J.A. (2021). The Work-Family Conflict: Evidence from the recent decade and lines of future research. *Journal of Family and Economic Issues*, 42, 4-10.
- Mouratidis, K., & Papagiannakis, A. (2021). COVID-19, internet, and mobility: The rise of telework, telehealth, e-learning, and e-shopping. *Sustainable Cities and Society*, 74. <https://doi.org/10.1016/j.scs.2021.103182>
- Mouratidis, K., Peters, S., & van Wee, B. (2021). Transportation technologies, sharing economy, and teleactivities: Implications for built environment and travel. *Transportation Research Part D: Transport and Environment*, 92. <https://doi.org/10.1016/j.trd.2021.102716>
- Olson, J. S., Covi, L., Rocco, E., Miller, W. J., & Allie, P. (1998). A Room of Your Own: What would it take to help remote groups work as well as collocated groups? *CHI 98 Conference Summary on Human Factors in Computing Systems*, 279–280.
- Osorio-Arjona, J., Horak, J., Svoboda, R., & García-Ruíz, Y. (2021). Social media semantic perceptions on Madrid Metro system: Using Twitter data to link complaints to space. *Sustainable Cities and Society*, 64. <https://doi.org/10.1016/j.scs.2020.102530>
- Ozbilen, B., Wang, K., & Akar, G. (2021). Revisiting the impacts of virtual mobility on travel behavior: An exploration of daily travel time expenditures. *Transportation Research Part A: Policy and Practice*, 145, 49–62. <https://doi.org/10.1016/j.tra.2021.01.002>
- Paul, M., & Dredze, M. (2011). You are what you tweet: Analyzing twitter for public health. *Proceedings of the International AAAI Conference on Web and Social Media*, 5(1), 265–272.
- Rehurek, R., & Sojka, P. (2011). Gensim–python framework for vector space modelling. NLP Centre, Faculty of Informatics, Masaryk University, Brno, Czech Republic, 3(2).
- Rinker, T. (2019). Lexicons for Text Analysis. *Package ‘Lexicon.’*
- Saura, J. R., Ribeiro-Soriano, D., & Zegarra Saldaña, P. (2022). Exploring the challenges of remote work on Twitter users’ sentiments: From digital technology development to a post-pandemic era. *Journal of Business Research*, 142, 242–254. <https://doi.org/10.1016/j.jbusres.2021.12.052>
- Schwartz, H., Eichstaedt, J., Kern, M., Dziurzynski, L., Lucas, R., Agrawal, M., Park, G., Lakshminanth, S., Jha, S., & Seligman, M. (2013). Characterizing geographic variation in well-being using tweets. *Proceedings of the International AAAI Conference on Web and Social Media*, 7(1), 583–591.
- Stieglitz, S., Brachten, F., Ross, B., & Jung, A.-K. (2017). Do social bots dream of electric sheep? A categorisation of social media bot accounts. *ArXiv Preprint ArXiv:1710.04044*.
- Wrycza, S., & Maślankowski, J. (2020). Social Media Users’ Opinions on Remote Work during the COVID-19 Pandemic. Thematic and Sentiment Analysis. *Information Systems Management*, 37(4), 288–297. <https://doi.org/10.1080/10580530.2020.1820631>
- Zhang, C., Yu, M. C., & Marin, S. (2021). Exploring public sentiment on enforced remote work during COVID-19. *Journal of Applied Psychology*, 106(6), 797–810. <https://doi.org/10.1037/apl0000933>

Tabla 1.**Revisión de la literatura**

Autor(es)	N. de tuits	Periodo	Metodología	Resultados principales
Dubey and Tripathi (2020)	100.000	15/3/2020-15/04/2020	NRC Emotion Lexicon	El 73% de los tuits presentan una connotación positiva
Wrycza and Máslankowski (2020)	523.000	01/02/2020 - 10/08/2020	Naive-Bayes	La proporción de tuits positivos aumenta de un 50%, antes de la pandemia, a un 62,2% durante la pandemia.
Zhang et al. (2021)	1 million	30/03/2020-05/07/2020	Lexicon R package	Los tuits reflejan actitudes positivas hacia el teletrabajo, con leves caídas durante el fin de semana
Min et al., (2021)	1.56 million	01/03/2020 - 01/07/2020	BERT, DGM (Direct growth models)	Las connotaciones de los tuits son ligeramente positivas, con un ligero descenso de la positividad hacia el fin de semana
Daneshfar et al., (2022)	151,175	07/2020–10/2020	TextBlob Python Package	Los resultados muestran que la mayoría de los tuits durante la pandemia son positivos y objetivos.
Saura et al., (2022)	205.204	04/04/2021-06/08/2021	TextBlob Python Package and Latent Dirichlet Allocation	Identifican 11 temas, de los cuales 3 son negativos (Salud virtual, Preocupación por la privacidad y Estrés), 4 positivos (Equilibrio trabajo-vida privada, Menos estrés, Futuro y Compromiso) y 3 neutros (Nuevas tecnologías, Sostenibilidad y Tecnología y compromiso), y 3 neutros (nuevas tecnologías, sostenibilidad y Tecnología).

Nota: Esta tabla incorpora el número de tuits utilizados por cada investigación, el intervalo temporal analizado, el método para realizar procesamiento de lenguaje natural y los resultados principales.

Tabla 2

Lista de palabras y temas propuestos

Tema	Descripción	Términos	Número de veces que aparece
Conciliación laboral	Tuits que podrían estar relacionados con la conciliación laboral y familiar	Vacaciones, descanso, hijos, flexibilidad, familia, dormir, madre, hijo, familias, conciliar, padres, familiar	4001
Movilidad urbana/ciudad	Tuits que podrían hacer referencia a la vida en la ciudad y la movilidad dentro de ella	Madrid, centro, ciudad(es), transporte, calle, tráfico, coche, metro, distancia,, zona(s), lejos, trasladar	3484
Salud, pandemia y salud (mental)	Tuits que podrían hacer referencia a cuestiones relacionadas con la salud	Pandemia, covid, salud, feliz, descanso, dormir, sanitaria	1045
Problemas técnicos	Tuits que podrían relacionado con los problemas técnicos para teletrabajar	Internet, @soportetecnico, teléfono, ordenador, online ,conexión	940
Sector público, gobierno y política	Tuits que podrían relacionados con el funcionamiento del sector público, gobierno y la política	Ley, público/a (s), funcionarios, gobierno, estatales, administración,	619

Nota: La Tabla 2 representa las 500 palabras más frecuentes en nuestra muestra y los posibles temas que podrían representar. Anonimizamos las cuentas de soporte técnico de las compañías telefónicas para preservar el anonimato.

Tabla 3.**Ejemplo de clasificación de tuits de la muestra**

Tuit	Clasificación	Probabilidad asociada
"@user Que suerte tienes!! Es la situación ideal a parte del teletrabajo que es y sigue siendo una maravilla"	Positivo	0.954
"Teletrabajo! Lo adoro."	Positivo	0.949
"@user Que bonito es teletrabajar "	Positivo	0.947
"@user @user Que asco el teletrabajo"	Negativo	0.967
"En @user se está regulando -tan despacio- 2 días de teletrabajo. Recibir un correo de tu jefe, informándote de que esos dos días no deben ser concebidos como días libres adicionales, me da tanta vergüenza ajena como rabia."	Negativo	0.963
"@user Exacto, los sindicatos y su maldita precarización. Basta con ver cómo rompieron, incluso, el teletrabajo, para seguir anclados en 1810 Asco"	Negativo	0.963
"@user ¿Teletrabajando o presencial?."	Neutral	0.928
"@user teletrabajo via meet"	Neutral	0.926
"En situación de #HomeOffice #WorkFromHome #Teletrabajo ¿Qué tipo de vestimenta usan?"	Neutral	0.921


Nota: Esta Tabla presenta los tuits de la muestra con las probabilidades más altas asociadas a cada tipo de connotación. Los nombres de usuario han sido anonimizados para mantener el anonimato de los usuarios

Tabla 4.
Estadísticos descriptivos

VARIABLES	(1) mean	(2) sd	(3) max	(4) min
Followers	2,287.745	17,643.669	1233142.000	0.000
Friends	915.811	1,592.738	44,878.000	0.000
Likes	5.894	117.299	7,544.000	0.000
Negative	0.411	0.342	0.967	0.008
Neutral	0.359	0.241	0.935	0.021
Positive	0.230	0.271	0.954	0.008
RT	0.829	20.663	1,480.000	0.000
Positive Tweets	0.212	0.409	1.000	0.000
Negative Tweets	0.435	0.496	1.000	0.000
Neutral Tweets	0.353	0.478	1.000	0.000


Nota: Estadísticos descriptivos para las variables de la muestra de 12,986 tuits. Disponemos información de los seguidores, seguidos (Friends), probabilidad de tuits positivos, negativos y neutros, número de retuits (RT), número de "me gusta" que tiene el tuit, y la categoría (connotación) de cada tuit.

Figura 2. Gráfico de columnas apiladas. Tuits clasificados por día de la semana.




Nota: Número de tuits publicados por día de la semana y su clasificación según adquieran una connotación positiva, negativa o neutra.

Figura 3. Gráfico de series temporales. Tuits clasificados por horas.



Nota: Número total de tuits publicados en cada hora que compone los días de la muestra. Clasificación según connotación.

Figura 4. Gráfico de series temporales. Proporción de tuits según connotación durante el intervalo temporal



Nota: Proporción de tuits en serie temporal por cada tipo de connotación. La serie abarca el periodo comprendido entre el 30 de septiembre hasta el 1 de diciembre.

Tabla 4**Resultados modelo LDA**

Tópico 1		Tópico 2		Tópico 3		Tópico 4	
Palabra	Probabilidad	Palabra	Probabilidad	Palabra	Probabilidad	Palabra	Probabilidad
Teletrabajo	8,40%	Teletrabajo	5,20%	Puedes	7%	Internet	14,40%
Mientras	6,20%	Covid	4,70%	Teletrabajo	5,70%	Servicio	8,40%
Gusta	4,20%	Ojalá	4,20%	Posibilidad	3,30%	Teletrabajo	8,20%
Zona	1,70%	Quedarse	3,20%	Medida	2,50%	Necesito	6,50%
Familia	1,70%	Sanidad	1,20%	Posible	2,30%	Atención	2,20%


Nota: Esta Tabla contiene resultados del modelo LDA. Observamos las palabras que pertenecen a cada tópico y la probabilidad asociada de que cada palabra aparezca en ese tópico.

Figura 5. Palabras más frecuentes en el Tópico 1




Nota: Gráfico elaborado con el paquete de Python WordCloud, para su elaboración hemos procesado el texto de tal manera que hemos eliminado conjunciones, artículos, preposiciones, palabras vacías y cifras.

Figura 6. Palabras más frecuentes en el Tópico 2



Nota: Gráfico elaborado con el paquete de Python WordCloud, para su elaboración hemos procesado el texto de tal manera que hemos eliminado conjunciones, artículos, preposiciones, palabras vacías y cifras.

Figura 7. Palabras más frecuentes en el tópico 1



Nota: Gráfico elaborado con el paquete de Python WordCloud, para su elaboración hemos procesado el texto de tal manera que hemos eliminado conjunciones, artículos, preposiciones, palabras vacías y cifras.

Figura 8. Palabras más frecuentes en el tópico 1



Nota: Gráfico elaborado con el paquete de Python WordCloud, para su elaboración hemos procesado el texto de tal manera que hemos eliminado conjunciones, artículos, preposiciones, palabras vacías y cifras.