

Tipo de documento: Tesis de maestría

Escuela de Negocios. Master in Management + Analytics

Desentrañando los hilos de la incivilidad del cliente: Un análisis multivariable de las respuestas en Twitter y sus implicaciones para la calidad del servicio

Autoría: Casali, Sebastián

Año: 2024

¿Cómo citar este trabajo?

Casali, S. (2024) "Desentrañando los hilos de la incivilidad del cliente: Un análisis multivariable de las respuestas en Twitter y sus implicaciones para la calidad del servicio". [*Tesis de maestría. Universidad Torcuato Di Tella*]. Repositorio Digital Universidad Torcuato Di Tella

<https://repositorio.utdt.edu/handle/20.500.13098/12885>

El presente documento se encuentra alojado en el Repositorio Digital de la Universidad Torcuato Di Tella bajo una licencia Creative Commons Atribución-No Comercial-Compartir Igual 4.0 Argentina (CC BY-NC-SA 4.0 AR)

Dirección: <https://repositorio.utdt.edu>



UNIVERSIDAD
TORCUATO DI TELLA

MASTER IN MANAGEMENT + ANALYTICS

*DESENTRAÑANDO LOS HILOS DE LA
INCIVILIDAD DEL CLIENTE:*

*UN ANÁLISIS MULTIVARIABLE DE LAS RESPUESTAS EN TWITTER
Y SUS IMPLICACIONES PARA LA CALIDAD DEL SERVICIO*

TESIS

Sebastian Casali

Mayo 2024

Tutor: Elena Fumagalli & Giovanni Visentin

Resumen

Los empleados de primera línea (FLEs) enfrentan un número creciente de clientes que actúan de manera grosera hacia ellos, incluyendo abuso verbal y gestos agresivos que van más allá de las normas sociales de decencia (Skarlicki et al., 2008; Zhu et al., 2019). Debido a su capacidad para facilitar conexiones directas y frecuentemente anónimas, las redes sociales han empeorado esta situación al aumentar la probabilidad de incivilidad (Béal et al., 2023; Fombelle et al., 2020). De hecho, este problema ahora afecta a más del 70% de los trabajadores de servicios tanto en encuentros cara a cara como digitales (Cortina et al., 2001; Sliter et al., 2010). Ilustrando el reconocimiento global de este problema, la señalización en aeropuertos de todo el mundo condena explícitamente el abuso verbal dirigido a los empleados, llamando la atención sobre la naturaleza generalizada del problema (Figura 1). A pesar de su amplitud y reconocimiento, las empresas frecuentemente no tienen políticas adecuadas para proteger a los trabajadores contra la grosería, lo cual se ha relacionado con una calidad inferior del servicio al cliente, cansancio emocional de los empleados y disminución de la satisfacción laboral de los mismos (Arnold & Walsh, 2015; Kern & Grandey, 2009; Sliter et al., 2012).

Dada la importancia de este tema para las empresas de todo el mundo, nos propusimos explorar un posible factor ambiental que podría estar impulsando inconscientemente la grosería de los clientes. En particular, iniciamos un enfoque exhaustivo de recolección de datos para investigar la conexión entre la temperatura y la grosería del cliente dirigida a los empleados de primera línea. Identificamos aspectos particulares de interés para nuestra investigación, como la geolocalización como proxy de la temperatura, utilizando datos secundarios de Twitter/X. Nuestro conjunto de datos incluía más de 110,000 tuits dirigidos a 64 empresas en 19 países diferentes. Estas empresas incluían sectores de viajes y alojamiento, dos sectores frecuentemente asociados con un mal servicio al cliente. Utilizando un modelo de lenguaje grande (LLM), usamos una definición preexistente de lo que constituye la grosería del cliente para entrenar un algoritmo que nos permitiera codificar estos tuits según su grado de grosería. Combinando información de temperatura del conjunto de datos ERA5 con las ubicaciones de los tuits, se permitió un análisis más profundo de la relación entre temperaturas extremas y mensajes groseros enviados por clientes en línea.

Construimos un modelo de datos de panel integral que incorpora efectos fijos de país y tiempo, para llevar a cabo un análisis de la correlación entre temperaturas extremas y la incidencia de mensajes groseros de clientes en línea. Nuestros resultados proporcionan evidencia convincente de que las temperaturas extremas están estrechamente vinculadas a variaciones en la incivilidad del cliente. Específicamente, encontramos que las temperaturas extremadamente altas aumentan significativamente la grosería, mientras que las condiciones extremadamente frías también contribuyen a una mayor incivilidad, aunque en menor medida. Estos hallazgos son consistentes con investigaciones previas sobre agresión fuera de línea, apoyando nuestra hipótesis de que las condiciones ambientales extremas pueden aumentar la incivilidad del consumidor en línea (Miles-Novelo & Anderson, 2019; Plante et al., 2017).

Nuestra investigación no solo arroja luz sobre los factores que impulsan el comportamiento grosero de los clientes, sino que también ofrece implicaciones prácticas para las empresas que buscan gestionar tales interacciones. Al entender la influencia de la temperatura en el comportamiento del cliente, las empresas pueden desarrollar programas de capacitación personalizados para los empleados de primera línea (FLEs), equipándolos con las herramientas necesarias para manejar la grosería durante condiciones climáticas extremas. La

implementación de sistemas de monitoreo de temperatura también puede ayudar a mitigar las interacciones negativas con los clientes.

Como resultado, nuestra investigación se suma al creciente cuerpo de conocimientos sobre la grosería del cliente al demostrar la utilidad de los modelos de lenguaje grandes (LLMs) en el análisis de patrones de grosería, identificando la temperatura como un desencadenante clave. Al ofrecer conocimientos sobre los mecanismos subyacentes que impulsan el comportamiento del cliente, proporcionamos a las empresas las herramientas para mejorar las relaciones con los clientes, fomentar interacciones positivas y apoyar el bienestar de los empleados en un mundo cada vez más digital. De cara al futuro, nuestra investigación puede considerarse un primer paso. Las empresas podrían utilizar nuestro enfoque para investigar otros factores, además de la temperatura, que se correlacionan con la grosería. Posteriormente, pueden diseñar y probar sus propias intervenciones específicas para intentar mitigar este fenómeno.

Índice

1. Introduction.....	7
1.1. Motivation.....	7
1.2. Incivildad del Cliente.....	8
1.3. Incivildad del Cliente en Redes Sociales.....	10
1.4. Empleados de Primera Líneas	12
1.5. Implicaciones Gerenciales.....	13
1.6. Objetivo.....	14
1.7. Metodología.....	15
2. Data	16
2.1. Tweets	16
2.2. ERA5	20
3. Analisis Exploratorio.....	22
3.1. Tweets	22
4. Variable Independiente: Categoría de Temperatura	28
4.1. Generación de la variable independiente	32
5. Variable de Incivildad del Cliente.....	33
5.1. Generación de la Variable Dependiente	33
5.2. Incivildad del Cliente: Análisis Exploratorio	38
6. Pruebas de Hipótesis y Resultados.....	40
6.1. Análisis y Estimaciones del Modelo	41
6.2. Modelos de Regresión.....	42
6.3. Verificaciones de Robustez	44
6.4. ANOVA de un factor y Correlaciones.....	46
6.5. Modelos de Regresión de Datos de Panel con Efectos Fijos.....	48
6.6. Análisis Transnacional de la Incivildad del Cliente: Claro	52
7. Conclusiones.....	54
7.1. Limitaciones de los Datos.....	56
7.2. Direcciones Futuras de Investigación.....	57
Referencias.....	59
Appendix A. Variables del Conjunto de Datos	61
Appendix B. Entrenamiento de ChatGPT	62
Appendix C. Figuras Adicionales	65

Appendix D. ERA5 Temperature Extraction	67
Appendix E. Large Language Model	73
Appendix F. Validación del LLM	88
Appendix G. Tabla de Regresión OLS	92
Appendix H. Figuras Adicionales del Análisis Transnacional.....	95
Appendix I. Uso de Herramientas de Inteligencia Artificial	96

Indice de Tablas

Tabla 1. Extracción de Octoparse.....	18
Tabla 2. Datos de Muestra	28
Tabla 3. Definiciones Existentes de Incivismo.....	33
Tabla 4. Customer Incivility Classification Accuracy and Tweets Classified by Incivility Level....	35
Tabla 5. Importancia de las Diferencias en la Media de Incivilidad del Cliente entre Categorías de Temperatura	44
Tabla 6. Errores Estándar Agrupados.....	44
Tabla 7. ANOVA de Incivilidad del Cliente.....	47
Tabla 8. Tabla de Correlación	48
Tabla 9. Modelos de Regresión de Datos de Panel con Efectos Fijos sobre las Temperaturas Extremas y la Incivilidad del Cliente en Línea	50
Tabla 10. ANOVA de Incivilidad del Cliente Grupo Claro	53
Tabla A1. Variables del Conjunto de Datos	61
Tabla F1. Estadísticas por Clase.....	89
Tabla G1. Tabla de Regresión OLS.....	92
Tabla H1. Tukey HSD Claro Cross Country Analysis.....	90

Indice de Figuras

Figura 1. Señal de Cortesía de Air France.....	9
Figura 2. Promoción de la Amabilidad en el Aeropuerto de Milán Linate	9
Figura 3. Visualización de Temperatura de ERA5.....	22
Figura 4. Países del Conjunto de Datos	23
Figura 5. Participación por País	24
Figura 6. Conteo de Tweets por Empresa	24
Figura 7. Top 10 Empresas por Porcentaje de Tweets	25
Figura 8. Porcentaje Promedio de Tweets por Industria	26
Figura 9. Porcentajes de Tweets Totales por Hora e Industria	27
Figura 10. Diagramas de caja de temperatura por país	30
Figura 11. Densidad de Categorías de Temperatura.....	31
Figura 12. Distribución de la Incivilidad del Cliente	38
Figura 13. Densidad de Incivilidad del Cliente por Industria.....	39
Figura 14. Distribución de Incivilidad del Cliente por Categoría de Temperatura	41
Figura 15. Heterogeneidad entre Países	45
Figura 16. Heterogeneidad a lo largo de los Meses	46
Figura 17. Distribución de la Incivilidad del Cliente para el Grupo Claro.....	52
Figura 18. Prueba Tukey HSD Grupo Claro.....	53
Figura C1. Composición de la Muestra por Empresa	65
Figura C2. Composición de la Muestra por Industria	66
Figura D1. Distribución de Temperatura según Octoparse.....	71
Figura F1. Matrix de Confusion	88

Indice de Ecuaciones

Ecuación 1. Regresión de Mínimos Cuadrados Ordinarios	42
Ecuación 2. Prueba de Bonferroni.....	43
Ecuación 3. ANOVA de Incivilidad del Cliente	46
Ecuación 4. Correlación de Pearson	47
Ecuación 5. Modelos de Regresión Panel	49
Ecuación 6. ANOVA de Incivilidad del Cliente Grupo Claro.....	52

1. Introducción

1.1. Motivación

La incivildad de los clientes es un problema importante para las organizaciones de todo el mundo. Las estadísticas muestran que la descortesía dirigida hacia los empleados de primera línea (FLEs) es alarmantemente común. Investigaciones recientes, como las enfatizadas por la profesora de gestión de la Universidad de Georgetown Christine Porath, indican que aproximadamente el 76% de los empleados han experimentado abusos por parte de los consumidores en el transcurso de un mes. Dado que los clientes desagradables pueden causar que los FLEs se sientan más estresados, tengan una menor satisfacción laboral y brinden servicios de peor calidad, es imperativo que las empresas aborden esta preocupante tendencia.

Debido al anonimato y la deshumanización frecuentemente asociados con los encuentros en línea, el problema de los clientes incivilizados se agrava en la era digital actual. Como señala Bacile et al. (2018), "las plataformas de redes sociales, como Twitter, brindan a los clientes una sensación de empoderamiento y anonimato, lo que puede resultar en un comportamiento más agresivo y desinhibido hacia las empresas y sus empleados". Este aspecto en línea de la incivildad entre los clientes complica los esfuerzos de las empresas para mantener buenas relaciones con los clientes y proteger el bienestar de sus empleados de primera línea.

Aunque la incivildad de los clientes se está reconociendo cada vez más como un problema grave, todavía existe una brecha significativa en la investigación sobre sus causas y soluciones prácticas propuestas. Pocos estudios han investigado cómo los factores ambientales afectan la dinámica de la incivildad, a pesar de que investigaciones anteriores han examinado una variedad de factores, incluidas predisposiciones individuales y fallos en el servicio, que contribuyen a la incivildad de los clientes. Esta brecha en la investigación destaca la necesidad de estudios empíricos que investiguen nuevas estrategias para reducir los efectos negativos de la incivildad de los clientes en el personal de primera línea, además de identificar los determinantes importantes de este comportamiento.

Nuestra investigación pretende cerrar esta brecha utilizando métodos computacionales sofisticados, particularmente Modelos de Lenguaje Grandes (LLMs), para crear un algoritmo que pueda identificar la incivildad en las comunicaciones textuales entre los clientes y los representantes de servicio al cliente. Nuestro objetivo es utilizar el aprendizaje automático para automatizar el proceso de detección y evaluación del comportamiento incivil en las interacciones en línea con los clientes. Esto proporcionará a las empresas una herramienta invaluable para manejar de manera más efectiva la incivildad de los clientes.

Además, nuestro estudio examina la temperatura extrema, un componente ambiental que no ha recibido mucha atención en la literatura. Buscamos investigar el impacto de la temperatura en la incivildad de los clientes en línea, basándonos en investigaciones crecientes que asocian las temperaturas extremas con un aumento de la animosidad y la violencia. Queremos proporcionar nuevos conocimientos sobre los mecanismos subyacentes de la incivildad del cliente aclarando la compleja relación entre los factores ambientales y el comportamiento del cliente a través de un examen exhaustivo de los intercambios en Twitter y sus datos diarios de temperatura asociados.

Considerando todo esto, nuestro trabajo llena una importante brecha en la investigación sobre la incivilidad del consumidor e introduce nuevos enfoques para su gestión y análisis, añadiendo al cuerpo de conocimiento sobre el tema. Nuestros hallazgos proporcionan nuevos conocimientos sobre la relación entre la temperatura y la incivilidad del cliente en línea. Al sentar las bases para el desarrollo de estrategias que protejan al personal de primera línea y fomenten interacciones positivas con los clientes, nuestros resultados incitan a los investigadores a construir sobre lo que encontramos.

1.2. Incivilidad del Cliente

Un problema persistente para los trabajadores de servicios en sus encuentros diarios es la incivilidad del cliente, que es una violación de los valores sociales, incluyendo la decencia y la civilidad (Kern y Grandey, 2009; Wilson y Holmvall, 2013). Estudios en los Estados Unidos han demostrado que más del 70% de los trabajadores de la industria de servicios reportan haber tratado con clientes groseros, lo que demuestra cuán común es este comportamiento (Cortina et al., 2001; Sliter et al., 2010). Los efectos negativos que este fenómeno tiene en los resultados empresariales son preocupantes debido al aumento del estrés y la disminución del bienestar que causa a los empleados de servicio (Sliter et al., 2010, 2012; Walker et al., 2014).

Para reducir las consecuencias negativas de los clientes groseros, las empresas deben ser conscientes de cómo responde su personal, lo que requiere la creación y aplicación de soluciones eficientes (Cortina y Magley, 2009). La incivilidad del cliente se define como "comportamiento desviado de baja intensidad" (Sliter et al., 2010, p. 468), que se distingue de tipos más evidentes de mala conducta, como la agresividad física. Esto incluye la grosería y la falta de respeto. Curiosamente, los estudios han demostrado que un componente clave de la incivilidad en el lugar de trabajo es este tipo más común pero más leve de mala conducta del cliente (Porath y Pearson, 2009; Wilson y Holmvall, 2013).

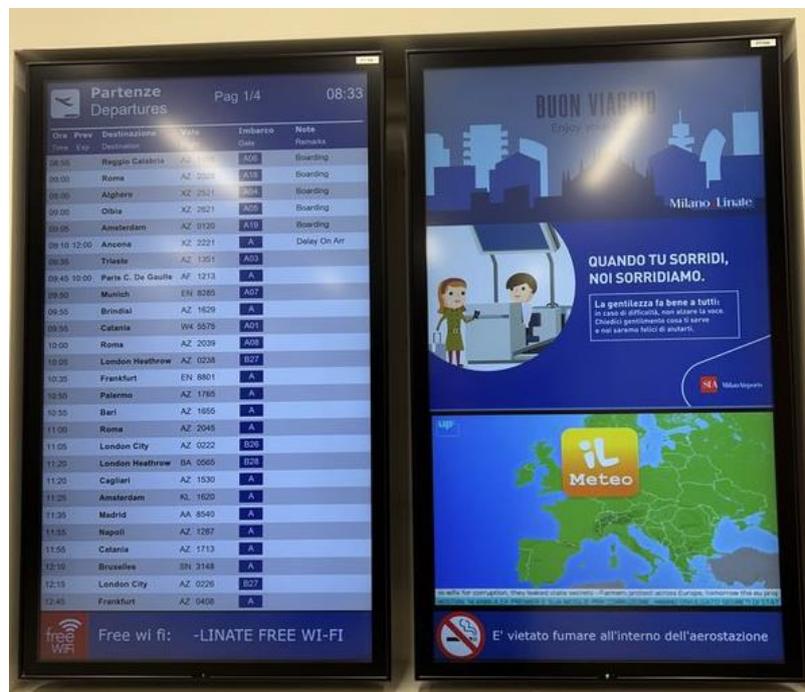
La creciente prevalencia de la incivilidad del cliente en las redes sociales añade una capa de complejidad a este fenómeno, ya que el anonimato en línea amplifica su manifestación (Fombelle et al., 2020). Una encuesta reciente reveló que el 73% de los observadores han presenciado incivilidad en las redes sociales, lo que genera preocupaciones sobre su gestión por parte de las empresas (Pew Research Center, 2014). Ejemplos notables incluyen el incidente de United Airlines en 2017, donde un video de un pasajero siendo forzosamente removido se volvió viral y provocó una enorme reacción en las redes sociales (informado por BBC News, 2017); y la controversia del arresto en Starbucks en 2018, que resultó en acusaciones de perfil racial y una indignación generalizada (informado por New York Times, 2018). Entender cómo deben las organizaciones navegar y abordar la incivilidad en las plataformas de redes sociales se convierte en una vía de investigación imperativa (Bacile, 2020; Bacile et al., 2018; Fombelle et al., 2020).

En respuesta al aumento de la incivilidad del cliente, muchas empresas han tomado medidas para fomentar el comportamiento cortés y mejorar las interacciones entre clientes y personal. Por ejemplo, Air France ha mostrado señales en los aeropuertos instando a los pasajeros a centrarse en la cortesía (Figura 1), destacando el compromiso de la aerolínea de proporcionar el mejor servicio posible mientras desalienta el comportamiento inapropiado. De manera similar, el Aeropuerto de Milán Linate muestra mensajes que promueven la amabilidad y el respeto hacia el personal (Figura 2).

Figura 1: Señal de Cortesía de Air France



Figura 2: Promoción de la Amabilidad en el Aeropuerto de Milán Linate



Aunque el comportamiento descuidado de los clientes puede no tener siempre la intención de causar daño a los proveedores de servicios, se ha demostrado que las repetidas instancias de incivilidad y falta de respeto tienen un impacto perjudicial en el bienestar y la productividad de los trabajadores (Han et al., 2016; Kern y Grandey, 2009). Crucialmente, los trabajadores podrían responder con rudeza hacia otros clientes, subrayando los posibles efectos en cascada de la incivilidad de los clientes en entornos de servicio (van Jaarsveld et al., 2010; Walker et al., 2014).

Según Sliter et al. (2012) y Walker et al. (2014), la incivilidad de los clientes tiene la capacidad de desencadenar una espiral negativa que resulta en relaciones con los clientes tensas y fallos en el servicio, destacando su importancia en la dinámica del lugar de trabajo. Las respuestas constructivas de los empleados de primera línea, como recuperaciones de servicio eficientes y asistencia personalizada, pueden ser intervenciones vitales para reducir los efectos negativos de los clientes groseros y mantener interacciones de servicio de alta calidad (Porath y Pearson, 2009; Groth y Grandey, 2012; Sliter et al., 2010; van Jaarsveld et al., 2010).

Mientras que el comportamiento anómalo de los empleados es frecuentemente el foco de la literatura más amplia sobre incivilidad en el lugar de trabajo, este estudio es único en que se concentra en el mal comportamiento de los clientes, que a menudo se pasa por alto (Zhu et al., 2019). Según Walker et al. (2014), el personal que percibe un trato hostil, grosero o descortés por parte de los consumidores es considerado víctima de la incivilidad del cliente. A su vez, se ha demostrado que la incivilidad de los clientes tiene efectos perjudiciales en la eficacia organizacional, aunque se vea como menos grave que otros comportamientos negativos (García et al., 2019; Torres et al., 2017). El impacto de la incivilidad del cliente, ya sea en línea o en persona, es igualmente perjudicial, afectando el bienestar de los empleados y los resultados organizacionales. Los estudios sugieren que el medio de incivilidad—ya sea en línea o presencial—no altera significativamente los efectos negativos experimentados por los empleados (Park et al., 2018; Shi et al., 2020).

Tras revisar la literatura sobre la incivilidad en el lugar de trabajo, quedó claro que, a pesar de su frecuente ocurrencia en una variedad de negocios, abundan los ejemplos. Por ejemplo, en entornos minoristas, los clientes a menudo muestran impaciencia y grosería hacia el personal de servicio durante los períodos de alta demanda (Harris y Daunt, 2013). De manera similar, en las industrias de la hospitalidad, los huéspedes pueden expresar insatisfacción a través de comentarios cortantes o comportamientos despectivos hacia los servidores (Smith et al., 2016). A pesar de estas ocurrencias comunes, el impacto y los procesos detrás del comportamiento disfuncional de los consumidores durante las interacciones de servicio siguen siendo poco comprendidos (Harris y Daunt, 2013).

1.3. Incivilidad del Cliente en Redes Sociales

La dinámica de la relación entre clientes y empresas ha experimentado un cambio radical debido a la influencia omnipresente de las plataformas de redes sociales. Estas plataformas fomentan la comunidad al alentar la comunicación, la participación de los usuarios, el intercambio de contenido y la expresión de opiniones entre los usuarios (Jansen et al., 2009; Gallagher y Ransbotham, 2010; Nitins y Burgess, 2014). Entre estas plataformas, los sitios de microblogging como Twitter han emergido como canales cruciales para la interacción con el cliente, ofreciendo retroalimentación en tiempo real, vías para ideas de mejora de productos, difusión de información, promoción de buena voluntad, promoción de productos y aumento de la visibilidad de la marca (Jansen, 2009; Smith et al., 2012).

Con 1.6 mil millones de visitantes únicos mensuales en sitios web con tweets incrustados y 330 millones de usuarios activos mensuales, Twitter se ha convertido en una de las plataformas de redes sociales más utilizadas por las empresas (DMR Business Statistics, 2018). Las empresas utilizan Twitter para promover contenido de boca en boca y afectar la comunicación con los consumidores (Kozinets et al., 2010). Según estudios previos, Twitter impacta significativamente en cómo interactúan los clientes y las empresas, ya que las personas utilizan la plataforma para comunicarse directamente y expresar su descontento con otros canales (Pozza, 2014). Este impacto, sin embargo, varía entre diferentes países e industrias, ya que las diferencias culturales y de mercado influyen en cómo las empresas y los clientes utilizan Twitter para la interacción (Hennig-Thurau et al., 2015; Tsimonis & Dimitriadis, 2014). Las interacciones activas son un medio para desarrollar relaciones más profundas y significativas en el contexto de los servicios (Kumar et al., 2010).

Las redes sociales inicialmente sirvieron como un medio para la creación de redes en línea y la difusión de información. Sin embargo, rápidamente evolucionaron hacia una plataforma preferida por los clientes para compartir sus experiencias con productos y servicios (Kho,

2010). Los comentarios auténticos y sinceros de los clientes en las redes sociales son muy valorados como fuentes de información confiable, dado el considerable impacto que las reseñas en línea—tanto positivas como negativas—tienen en las audiencias en línea (Deshpande y Sarkar, 2010; Burton y Khammash, 2010). Típicamente, los clientes insatisfechos tienen más inclinación a expresar públicamente sus preocupaciones y quejas en las plataformas de redes sociales (Wei et al., 2008; Geho et al., 2010). La encuesta de Chandra (2011) destaca la importancia de los sitios de redes sociales en línea, revelando que el 30 por ciento de los consumidores, de un 98 por ciento encuestado, plantearon problemas relacionados con el servicio a través de estas plataformas. Este hallazgo sugiere una tendencia notable en el comportamiento del consumidor, aunque se necesita más investigación para determinar si existen patrones similares a nivel mundial.

Una ventaja inherente de utilizar las redes sociales para recopilar comentarios de los clientes es el intercambio libre y amplio de comentarios de usuarios en línea, lo que lo convierte en un entorno ideal para la investigación discreta y no intrusiva del sentimiento del consumidor (Burton y Khammash, 2010; Culnan et al., 2010). Al proporcionar una alternativa a los desafíos asociados con los estudios tradicionales de calidad del servicio, como la reclutamiento de participantes, las regulaciones de investigación y las preocupaciones de sesgo, este método facilita la investigación sobre las experiencias de los clientes (Thelwall et al., 2011).

Twitter, como plataforma de microblogging, desempeña un papel crucial en la comunicación de boca en boca electrónica (e-WOM), permitiendo a los consumidores evaluar abiertamente productos y servicios y compartir sus opiniones (Zhang y Daugherty, 2009, 2010; Chu y Kim, 2011). Sin embargo, al ser un foro abierto, Twitter expone a las empresas tanto a e-WOM positivo como negativo, con los clientes más inclinados a difundir contenido negativo sobre una marca (Smith et al., 2012). El acceso instantáneo al contenido de Twitter permite a las empresas monitorear las respuestas de los clientes y tomar las medidas adecuadas para mitigar la difusión de e-WOM negativo (Chan y Guillet, 2011; Nitins y Burgess, 2014).

Dado nuestro enfoque de investigación, es crucial utilizar una plataforma donde los clientes típicamente interactúan con las empresas para expresar su insatisfacción. Las quejas en las redes sociales, que transmiten molestia, insatisfacción o críticas a una empresa, son prevalentes en varias plataformas (Olshtain & Weinbach, 1993). Aunque la referencia original de Olshtain & Weinbach (1993) no se refería a las plataformas modernas de redes sociales, sus observaciones sobre las quejas de los clientes siguen siendo relevantes hoy en día. En contextos contemporáneos, plataformas como Twitter, Facebook e Instagram son comúnmente utilizadas por los clientes para expresar sus quejas (Tereszkiewicz, 2015, 2017, 2019). Estas quejas abarcan la insatisfacción con los servicios, la denuncia de errores en la entrega de servicios y solicitudes explícitas o implícitas de asistencia y soluciones (Olshtain & Weinbach, 1987, 1993; Tereszkiewicz, 2015, 2017, 2019).

Debido al impacto transformador de las redes sociales y el internet en la comunicación, el concepto de compromiso del cliente ha ganado una atención significativa (Brodie et al., 2011; Economist Intelligence Unit, 2007; Harmeling et al., 2017; Kumar, 2013; Sashi, 2012; Schultz y Peltier, 2013; Sorensen y Adkins, 2014). A pesar de las inversiones sustanciales en marketing en redes sociales, convertir estos esfuerzos en niveles significativos de compromiso del consumidor sigue siendo un desafío (Forbes, 2020a). Con casi la mitad de la población mundial utilizando redes sociales en 2020, el compromiso en redes sociales tiene un vasto potencial para el alcance global (Forbes, 2020a).

Las características únicas de Twitter, como las restricciones de longitud de los mensajes y la interacción pública, lo convierten en una plataforma donde el compromiso del cliente puede

impactar significativamente en la reputación y el servicio al cliente de una empresa. Por lo tanto, es imperativo que las empresas respondan adecuadamente tanto a los comentarios positivos como negativos en Twitter para mantener su reputación y mejorar la satisfacción del cliente.

1.4. Empleados de Primera Línea

Los empleados de primera línea (EPL) son a menudo los primeros en tratar con los clientes, lo que los pone en riesgo de recibir comentarios negativos y conductas groseras. Los EPL enfrentan regularmente la incivildad de los clientes, que desafía las normas sociales de cortesía y respeto, a pesar de su carácter generalmente leve (Bani-Melhem et al., 2020). Los EPL pueden experimentar agotamiento y cansancio emocional como resultado de interactuar con consumidores groseros, lo que puede dificultar su capacidad para manejar los problemas de los clientes (Maslach & Jackson, 1981). Esta sección revisa la literatura que destaca una variedad de consecuencias negativas para el bienestar de los empleados de primera línea (EPL) y su capacidad para realizar su trabajo.

Los EPL enfrentan frecuentemente no solo la grosería, sino también la hostilidad, el maltrato verbal e incluso el asalto físico de clientes poco cooperativos en sectores como la hospitalidad (Han et al., 2016). Este fenómeno se observa en todo el mundo, lo que indica que tales desafíos no se limitan a ninguna región o cultura específica (Tsaour & Tang, 2012; Karatepe et al., 2019). Según la noción de trabajo emocional, estos eventos desagradables causan estrés ya que los EPL tienen que reconciliar la necesidad de proyectar una alegría constante mientras resuelven la disfunción del cliente, lo que crea tensión psicológica (Grandey, 2003). Según Al-Hawari et al. (2020) y Henkel et al. (2017), el deseo de reprimir sentimientos desagradables como la molestia conduce al cansancio emocional, la baja autoestima, el agotamiento y la depresión.

Las personas, especialmente los EPL que tratan frecuentemente con tales situaciones, experimentan una gama de emociones cuando son expuestas a la incivildad de los clientes, incluyendo tristeza, desesperación, hostilidad e irracionalidad (Liu et al., 2008). Según la hipótesis de la Conservación de Recursos, los recursos, la autoestima y la vitalidad de los empleados pueden disminuir como resultado de esta grosería (Hobfoll, 1989; Yagil, 2017). Este agotamiento podría desalentar comportamientos positivos como ayudar a los clientes a resolver problemas y dificultar acciones beneficiosas para la empresa.

En el mismo sentido, la investigación de Harris y Daunt (2013) ha demostrado repetidamente los efectos negativos que tienen los comportamientos indebidos de los clientes en el personal de primera línea, incluidos el estrés, el agotamiento, la desmotivación, la insatisfacción laboral y la baja moral. Como ha demostrado la industria de servicios, el personal de primera línea que debe mantener profesionalismo y amabilidad es más vulnerable al cansancio emocional (Mattila y Enz, 2002).

Los miembros del personal de primera línea a menudo discuten sobre el impacto del comportamiento indebido de los clientes en su dedicación al trabajo y el bienestar general de la empresa. Los encuentros frecuentes con clientes groseros u hostiles no solo desmoralizan a los empleados de primera línea, sino que también socavan su confianza y crean un estrés significativo en sus relaciones sociales y profesionales. Los efectos perjudiciales de estos encuentros pueden volverse tan profundos que algunos trabajadores de primera línea contemplan dejar sus puestos, destacando el grave peaje que el comportamiento negativo de los clientes puede tener en su bienestar general (Tereszkiewicz, 2017).

Nuestra investigación agrega valiosas ideas a la literatura existente al profundizar en las repercusiones de eventos negativos, como la incivilidad de los clientes, en los empleados de primera línea. Al examinar específicamente la incivilidad de los clientes dentro del marco más amplio del modelo de Demandas y Recursos Laborales (JD-R), ampliamos la comprensión obtenida de meta-análisis recientes sobre la incivilidad en el lugar de trabajo (Han et al., 2022).

Además, Lawrence et al. (2011) y Haver et al. (2013) enfatizan la importancia de fomentar un entorno de servicio que empodere a los trabajadores a través de la autonomía y el apoyo, subrayando la necesidad de intervenciones de capacitación adecuadas. Esto se alinea con investigaciones anteriores que destacan los beneficios de invertir en el empoderamiento y la capacitación de los empleados de primera línea, como lo destacan estudios realizados por Dagger et al. (2013), Wilder et al. (2014) y Riggle et al. (2014). Además, estudios como el de Colin et al. (2022) subrayan el impacto directo del cansancio de los empleados de primera línea en los esfuerzos de servicio orientados al cliente, destacando el papel crucial del personal de primera línea en la configuración de las interacciones con los clientes y el rendimiento organizacional.

En conclusión, nuestros hallazgos corroboran la evidencia que demuestra los efectos adversos del comportamiento grosero de los clientes en los empleados de primera línea, incluidos el agotamiento, el cansancio emocional, la disminución de la satisfacción laboral, la desmotivación e incluso la rotación (Harris y Daunt, 2013; Mattila y Enz, 2002). Dado que los empleados de primera línea sirven como el punto de contacto inicial para los clientes, sus experiencias con la grosería, la hostilidad y el abuso verbal impactan significativamente su bienestar psicológico y su rendimiento laboral. Por lo tanto, invertir en el apoyo y el bienestar del personal de primera línea es fundamental para fomentar un ambiente de trabajo saludable y mejorar los niveles de satisfacción del cliente.

1.5. Implicaciones Gerenciales

La co-creación del servicio durante el encuentro de servicio implica la interacción entre clientes y empleados de primera línea. Las tres partes —la empresa, el personal de primera línea y el cliente— son responsables del resultado final. Para crear y entregar valor en el sistema de servicio, es necesario gestionar con éxito tanto a los consumidores como al personal (Grönroos, 1996; Grönroos y Voima, 2013; Vargo y Lusch, 2004).

Los empleados de primera línea se ven severamente afectados por la mala conducta de los clientes, lo que repercute en su desempeño, bienestar y actitud (Kashif y Zarkada, 2015). Dado que el comportamiento disruptivo en redes sociales frecuentemente refleja las interacciones en persona, esta mala conducta puede manifestarse tanto en línea como fuera de línea (McLean y Osei-Frimpong, 2019; Ward y Ostrom, 2006). Esto afecta no solo el bienestar de los empleados de primera línea, sino también la reputación de la empresa y los clientes observadores. Las interacciones negativas que los empleados de primera línea tienen con clientes problemáticos pueden ser presenciadas y sentidas por los espectadores, lo que podría dañar la reputación y la profesionalidad de la empresa (Kashif et al., 2014). Además, los empleados de primera línea pueden sentirse molestos y quemados por lidiar constantemente con clientes disruptivos, lo que podría llevar a tasas de rotación más altas y disminuir la satisfacción laboral (Huang, 2010). Como resultado, este ciclo de atrición podría exacerbar el descontento de los clientes y retrasar una disminución en la calidad del servicio, ambos dañinos para la reputación de la empresa y su capacidad para competir en el mercado.

Las empresas deben tener políticas que prioricen el bienestar de sus empleados, manejen la mala conducta de los clientes de manera efectiva y creen un entorno de trabajo respetuoso y de apoyo debido a la gravedad de estas consecuencias.

El daño reputacional para el proveedor de servicios puede surgir de la co-destrucción de valor provocada por problemas de mala conducta durante los encuentros de servicio si no se abordan adecuadamente. Los clientes que reciben un servicio deficiente son más propensos a quejarse con otros, lo que perjudica la reputación de la empresa (Maxham y Netemeyer, 2003; Grégoire et al., 2009). Estos episodios aumentan los costos financieros directos e indirectos de resolver y compensar a los clientes afectados por la mala conducta del cliente a nivel organizacional (Harris y Reynolds, 2003, 2004). También se ve afectada la productividad de los empleados, lo que resulta en intenciones de renunciar y en una atrición general (Huang, 2010; Ahmed et al., 2010).

Los miembros del personal de primera línea en el sector bancario se espera que encarnen rasgos como el enfoque en el cliente, ser extremadamente profesionales, tener conocimientos y capacidad para asistir durante emergencias de clientes (Smith y Johnson, 2018; Patel y Gupta, 2019). Los empleadores deben priorizar la selección de candidatos que posean estas cualidades y proporcionar programas de capacitación para mejorar aún más sus habilidades y capacidades (Brown y Wilson, 2020). Es imperativo que los empleados sean tratados con respeto y confianza por la dirección, ya que desempeñan un papel crucial en el proceso de entrega de valor de las empresas de servicios (Smith y Johnson, 2018; Brown y Wilson, 2020).

La gerencia debe reconocer que la grosería de los clientes es un problema serio y tomar medidas proactivas para abordarlo (Lee y Jones, 2017; García y Martínez, 2018). Al educar a los empleados de primera línea sobre la importancia de la grosería de los clientes y proporcionarles las estrategias de capacitación y afrontamiento necesarias, las empresas pueden mitigar la tensión emocional y el impacto causado por clientes groseros (Wang y Chang, 2019). Los supervisores y el personal estarán mejor equipados para manejar tales situaciones si reciben capacitación sobre las causas principales de la incivilidad, los mecanismos de afrontamiento y cómo distinguir entre la agresión grave y la incivilidad menor (Lee y Jones, 2017; Wang y Chang, 2019)..

1.6. Objetivo

Aunque las causas subyacentes de este comportamiento aún son en su mayoría desconocidas, la incivilidad de los clientes representa una seria amenaza para las empresas en sectores orientados al cliente. Aunque el trabajo actual en la literatura reconoce la frecuencia de las quejas de los clientes respecto a mal funcionamiento del servicio, se necesita más investigación para determinar las causas precisas de la grosería que surge en estos intercambios. En el presente trabajo, nos enfocamos en el entorno donde ocurre la interacción, específicamente en la temperatura que experimenta el cliente al dirigirse al empleado de primera línea.

Según un estudio reciente, las temperaturas extremas se han relacionado con un aumento en los discursos de odio en línea (Stechemesser et al., 2022). Este hallazgo sugiere posibles paralelos en las interacciones cara a cara. Además, la investigación sobre la correlación entre altas temperaturas y aumento de la agresión (Miles-Novelo y Anderson, 2019; Plante et al., 2017) respalda la idea de que la temperatura podría desempeñar un papel significativo en la incivilidad de los clientes.

A la luz de la literatura disponible y de los marcos teóricos revisados en las secciones anteriores, el objetivo del presente estudio es evaluar la asociación entre la temperatura ambiente y la

incivilidad de los clientes. Basándonos en los hallazgos de estudios sobre discursos de odio en línea y agresión, formulamos la siguiente hipótesis:

Hipótesis: Las temperaturas extremas, tanto altas como bajas, están positivamente correlacionadas con la incivilidad de los clientes.

Al poner a prueba esta hipótesis, nuestro objetivo es profundizar en nuestra comprensión de los factores que influyen en la incivilidad de los clientes y contribuir tanto a la literatura académica como a las aplicaciones prácticas en la gestión del servicio al cliente..

1.7. Metodología

Comprender los factores que influyen en la incivilidad de los clientes en las interacciones de servicio es fundamental para las empresas que buscan mejorar la calidad del servicio al cliente y el bienestar de los empleados. Esta sección de metodología describe cómo utilizamos una combinación de datos de Twitter y datos climáticos para investigar la relación entre la temperatura y la grosería por parte de los clientes.

El primer paso consiste en recopilar información de Twitter. Específicamente, compilamos una colección de tweets dirigidos a diferentes organizaciones en diversas industrias, y extraemos aspectos importantes como datos de geolocalización y contenido de los tweets. La colección ERA5 también proporciona datos climáticos, que incluyen valores de temperatura correspondientes a los lugares y momentos de los tweets recopilados.

Utilizamos Modelos de Lenguaje Grande (Large Language Models, LLM) que pueden analizar y clasificar texto según criterios predefinidos para evaluar el grado de grosería de los clientes en los tweets recopilados. Al crear puntajes de incivilidad para cada tweet, estos modelos están entrenados para identificar patrones y pistas lingüísticas que sugieren un comportamiento grosero por parte de los clientes. Los LLM alcanzan una excelente precisión en la identificación de grados de grosería mediante entrenamiento recurrente y mejora, asegurando la validez de los puntajes que se producen.

Se produce un único conjunto de datos para el análisis mediante la integración del conjunto de datos de Twitter con los datos climáticos. Este conjunto de datos integrado permite una investigación exhaustiva de la correlación entre las condiciones de temperatura y la grosería de los clientes. Incluye el contenido de los tweets, datos de geolocalización y datos de temperatura. Además, se generan variables para categorías de temperatura severamente calientes y frías, clasificando las circunstancias de temperatura como extremadamente calientes o frías según umbrales predefinidos.

Después de determinar las variables y crear el conjunto de datos, se realizan pruebas para evaluar nuestra hipótesis sobre la correlación entre la grosería de los clientes y la temperatura. Se examinan las relaciones entre las categorías de temperatura y los puntajes de incivilidad de los clientes utilizando dos técnicas estadísticas: modelado de regresión y ANOVA de una vía. El modelado de regresión se utiliza para determinar la fuerza y el tipo de relación entre una variable dependiente y una o más variables independientes (Montgomery, Peck, & Vining, 2012). Por otro lado, el ANOVA de una vía se utiliza para determinar si existen diferencias estadísticamente significativas entre las medias de tres o más grupos no relacionados (Gelman, Hill, & Vehtari, 2020). Estos análisis buscan clarificar el impacto de la temperatura en el comportamiento del consumidor y proporcionar datos empíricos que respalden nuestra hipótesis.

2. Data

En esta sección, profundizamos en las complejidades de nuestro proceso de recopilación de datos, destacando dos contribuciones fundamentales a nuestro conjunto de datos: la extracción de datos de Twitter, que forma la base de nuestro modelo de Incivilidad del Cliente, y los datos climatológicos obtenidos de ERA5, que nos permitieron probar nuestra relación hipotética (consulte el Apéndice A para obtener información detallada sobre el conjunto de datos y variables).

2.1. Tweets

El estudio utilizó dos métodos para recopilar datos de Twitter. El primer método utilizó la API de Twitter, una técnica bien establecida en el análisis de datos. Este método se utiliza comúnmente en estudios similares, como el estudio de caso de Sofia Nazarena Di Buccio "Mejora en el servicio al cliente utilizando datos de Twitter y técnicas de aprendizaje automático". Para acceder a la API, se requiere una cuenta de desarrollador, que se solicita a través de un formulario en línea proporcionado por Twitter. Una vez aprobada, se generan tres credenciales: una Clave, un Secreto y un Token para establecer una conexión con la API. Los cambios recientes en la propiedad de Twitter han llevado a desarrollos notables, como la capacidad de extraer más datos a una velocidad más rápida, reduciendo la necesidad de múltiples extracciones por consulta.

Los datos utilizados en este estudio se recopilaron de Twitter, centrándose en empresas de servicios como @AmericanAir, @LATAM Airlines, @RappiArgentina y @EntelPeru. Estas empresas fueron seleccionadas porque prestan servicios a usuarios dentro de las mismas áreas geográficas, lo que permite una correlación más precisa entre la temperatura y la incivilidad del cliente. Asumimos que las interacciones con los clientes ocurren predominantemente dentro de las regiones que estas empresas sirven. Dado que Twitter ya no proporciona datos de geolocalización precisos para los tweets tras la adquisición de Elon Musk, estimamos la temperatura promedio de las áreas geográficas correspondientes a las ubicaciones de servicio principales de las empresas. Este enfoque nos permitió aproximar las condiciones ambientales a pesar de la falta de datos específicos de ubicación del usuario.

Comenzar con una colección manejable de idiomas y geografías fue una decisión estratégica, reflejada en la selección de países y empresas específicas. Las Américas, donde se habla ampliamente español y portugués, así como los países de habla inglesa como Estados Unidos y Canadá, fueron el foco original de este estudio. Esta selección tuvo como objetivo minimizar posibles complicaciones derivadas del análisis de múltiples idiomas y observar si el idioma influyó en los resultados. Investigaciones futuras pueden ampliar este alcance para incluir una gama más amplia de idiomas y regiones, añadiendo complejidad al estudio una vez validadas las hipótesis iniciales.

Los proveedores de servicios interactúan frecuentemente con clientes dentro de sus territorios operativos para abordar problemas de servicio locales y quejas de los consumidores. Los proveedores locales de telecomunicaciones y aerolíneas, por ejemplo, suelen atender a los ciudadanos de los países en los que operan y tratan regularmente con quejas e consultas de servicio de estos clientes. Según Bitner et al. (1990), los encuentros de servicio, especialmente en industrias de servicios, tienden a estar geográficamente localizados. Además, la investigación

de Lovelock y Wirtz (2016) destaca que las empresas de servicios a menudo adaptan sus operaciones y estrategias de servicio al cliente a las regiones específicas que sirven, reflejando las condiciones locales y las expectativas de los clientes.

Investigaciones anteriores han validado esta estrategia al demostrar que estrechar el alcance del estudio inicial a un número menor de variables o áreas geográficas puede simplificar el proceso y producir resultados más informativos que pueden desarrollarse aún más. Por ejemplo, Kozinets et al. (2010) mostraron cómo controlar un número limitado de variables en investigaciones preliminares puede producir descubrimientos significativos, mientras que Hennig-Thurau et al. (2015) enfatizaron la importancia de simplificar los análisis iniciales para gestionar las complejidades. Del mismo modo, Kumar et al. (2010) y Tsimonis & Dimitriadis (2014) han destacado los beneficios de un enfoque escalonado para incorporar variables adicionales en estudios longitudinales.

En resumen, elegimos deliberadamente un conjunto específico de países e idiomas para nuestro enfoque inicial como un enfoque metodológico para controlar posibles factores sociales que puedan afectar los resultados y para manejar la complejidad del análisis de sentimientos utilizando Modelos de Lenguaje Grande (LLMs). Basado en los resultados de nuestras evaluaciones preliminares, este método básico allana el camino para investigaciones futuras más extensas, que incluirán una gama más amplia de idiomas y naciones.

Debido a los cambios recientes en Twitter, la extracción de datos utilizando solo la API presentó varios desafíos. Estos incluyeron la limitación de extraer solo los tweets más recientes y la incapacidad de consultar la sección de "Respuestas" de los tweets para su contenido. Para superar estos obstáculos, empleamos la herramienta de web scraping Octoparse. Octoparse automatiza el proceso de extracción de datos sin necesidad de cuentas premium y se adhiere estrictamente a prácticas éticas de web scraping, asegurando el cumplimiento de las políticas de Twitter y otros estándares legales y éticos.

Utilizando Octoparse y estableciendo los parámetros de extracción necesarios (programando los "Trabajos"), pudimos extraer información de la sección de Respuestas de cada Tweet. Esto incluyó contenido, likes, retweets, comentarios, visualizaciones, cuentas involucradas, la fecha en que se hizo el Tweet, la hora precisa y la zona horaria en la que se emitió, y la ubicación (si es pública).

Para fines ilustrativos, la Tabla 1 muestra un segmento de la extracción de Octoparse para algunas cuentas de Twitter. Los datos abarcan elementos críticos como el nombre del usuario, el enlace al perfil, el identificador de la cuenta, la marca de tiempo del tweet, el número de comentarios, visualizaciones, contenido del tweet, retweets y likes. Cada fila representa un tweet individual junto con detalles relevantes..

Tabla 1: Extracción de Octoparse

Nombre	Cuenta	Tiempo	Comentario	Visualizaciones	Contenido	Retweets	Likes
Aaa	@beavianac	2023-09-18 11:16:31 UTC	2	181	Que odiooooo da @VoeGOLoficial serviço horrível, comprei um voo de SLZ com eles pagando um pouco mais caro por conta do horário e agora cancelaram me jogando pra VCP, sendo que é um destino totalmente diferente	1	0
Rappi Ecuador	@EcuadorRappi	2023-02-25 14:17:49 UTC	2	141	Hola, Jesus. Estamos aquí para revisarlo, por favor compártenos por DM tu correo electrónico y número de teléfono asociados a tu cuenta de Rappi. Adicional, nombre del establecimiento. Quedamos atentos.	0	0
Cristina Hernández	@chdez83	2022-07-28 20:01:32 UTC	0	0	@interjet @Interjetvac hablando a Interjet para preguntar sobre mi vuelo de regreso me dijeron que debo utilizar los mismos voucher que utilice de ida. Pero al validarlo me sale este mensaje. Por que es?? Les solicito su ayuda por favor	0	0
RappiChile	@RappiChile	2023-04-03 00:28:53 UTC	0	17	Te ofrecemos disculpas, Francieli. Por favor, revisa tu DM. Te hemos dejado un mensaje.	0	0
TIM AJUDA	@TIM_AJUDA	2023-09-09 16:07:16 UTC	0	0	Olá! Entre em contato conosco na DM do Twitter TIM_AJUDA para que possamos lhe auxiliar, ok? Estaremos esperando por você!	0	0

					@MovistarVe		
					Sres.		
					@MovistarVe		
Ciro Millan	@ciromillan	2023-04-01 20:09:13 UTC	2	55	, el día 30/03/2023 realicé el pago de mi línea pospago y a la fecha de hoy, 01/02/2023 dicha línea se encuentra INACTIVA, e intentado por distintos medios obtener atención por parte de ustedes para solventar dicha situación y ha sido en vano +	2	1
Karin	@jensikobando	2022-06-28 20:46:42 UTC	1	0	Hace más de 8 días realice una compra por mercado libre y hasta ahora nada que llega	0	0
					@ML_Colombia		
James Millholland	@JMillholland	2021-09-18 16:02:47 UTC	1	0	I have called them 4 times	0	0

Para extraer todos los datos relevantes de la sección de Respuestas en Twitter para cada cuenta, el proceso involucró iterar a través de los tweets presentados dentro del período de estudio. Esta sección solo muestra comentarios donde una persona etiqueta a la cuenta en cuestión e incluye respuestas de la empresa y anuncios.

El proceso consistió en iterar la extracción para cada cuenta a lo largo de un día completo del calendario. Este proceso prolongado fue necesario porque, debido a las nuevas políticas de Twitter, las extracciones tenían que realizarse con pausas para evitar que la plataforma bloqueara la herramienta de scraping, interpretándola como un bot. Inicialmente, se extrajeron todos los tweets mencionados, lo que resultó en un conjunto de datos de más de 300,000 tweets.

Posteriormente, se llevó a cabo un proceso de limpieza, dejando solo los tweets de otras cuentas dirigidos a la empresa (considerados comentarios de clientes), excluyendo las publicaciones y anuncios propios de la empresa. Además, se eliminaron las observaciones con datos faltantes en cualquier propiedad.

Preparación de Datos

Después de la extracción inicial y la limpieza, el siguiente paso fue la preparación de datos. Esto incluyó manejar datos faltantes y transformar variables para preparar el conjunto de datos para el análisis:

1. **Manejo de Datos Faltantes:** Se eliminaron las observaciones con datos faltantes en campos críticos (por ejemplo, contenido del tweet, marca de tiempo). Esto aseguró que todos los tweets en el conjunto de datos fueran completos y utilizables para el análisis. La eliminación de datos incompletos o duplicados fue crucial para mantener la integridad y precisión del análisis.
2. **Transformaciones de Variables:** Se aplicaron varias transformaciones al conjunto de datos para estandarizar y normalizar los datos:
 - *Transformación de Marca de Tiempo:* Todas las marcas de tiempo se convirtieron a un formato uniforme y se ajustaron a la misma zona horaria (UTC) para garantizar consistencia temporal en todos los puntos de datos.
 - *Normalización de Texto:* El contenido de los tweets se procesó para eliminar caracteres especiales, URLs y otros elementos no alfanuméricos. Además, el texto se convirtió a minúsculas para mantener consistencia en el análisis de texto.
 - *Preparación para Análisis de Sentimientos:* Los tweets se tokenizaron y se eliminaron las palabras vacías para prepararlos para el análisis de sentimientos utilizando Modelos de Lenguaje Grande (LLMs). Este paso fue fundamental para reducir el ruido y centrarse en el contenido significativo.
3. **Aproximación de Geolocalización:** Dado que no se disponía de datos precisos de geolocalización, estimamos la temperatura promedio de las áreas geográficas correspondientes a las ubicaciones de servicio principales de las empresas. Esta aproximación implicó correlacionar las áreas de servicio de las empresas con datos de temperatura regional obtenidos de fuentes meteorológicas confiables.
4. **Codificación de Variables Categóricas:** Se codificaron adecuadamente las variables categóricas (por ejemplo, idioma del usuario, tipo de tweet) para su uso en modelos de aprendizaje automático. Se aplicó codificación one-hot donde fue necesario para facilitar el entrenamiento y análisis del modelo.

Estos pasos de preparación de datos aseguraron que el conjunto de datos final fuera robusto, completo y listo para el análisis, abordando cualquier inconsistencia inicial o brecha en los datos brutos. Estos procesos fueron críticos para establecer una base sólida para las etapas posteriores de nuestra investigación.

2.2. ERA5

Otro de los componentes principales de este estudio es la data de temperatura, la cual obtuvimos del conjunto de datos ERA5 (<https://cds.climate.copernicus.eu/cdsapp#!/dataset/reanalysis-era5-single-levels?tab=form>).

El conjunto de datos ERA5, desarrollado por el Centro Europeo para Predicciones Meteorológicas a Plazo Medio (ECMWF, por sus siglas en inglés), representa un avance significativo en la reanálisis global del clima y el tiempo atmosférico. Proporciona estimaciones detalladas de parámetros atmosféricos, oceánicos y de superficie terrestre a intervalos horarios, abarcando un periodo de más de ocho décadas desde 1940 en adelante. En comparación con su predecesor, ERA-Interim, ERA5 ofrece una mayor resolución de datos, incluyendo promedios y variabilidad del conjunto, lo cual mejora las estimaciones de incertidumbre y potencia su aplicación en climatología.

Acceder a los datos de temperatura de ERA5 implica utilizar la API web de Python proporcionada por ECMWF. Aquí están los pasos típicos involucrados en este proceso:

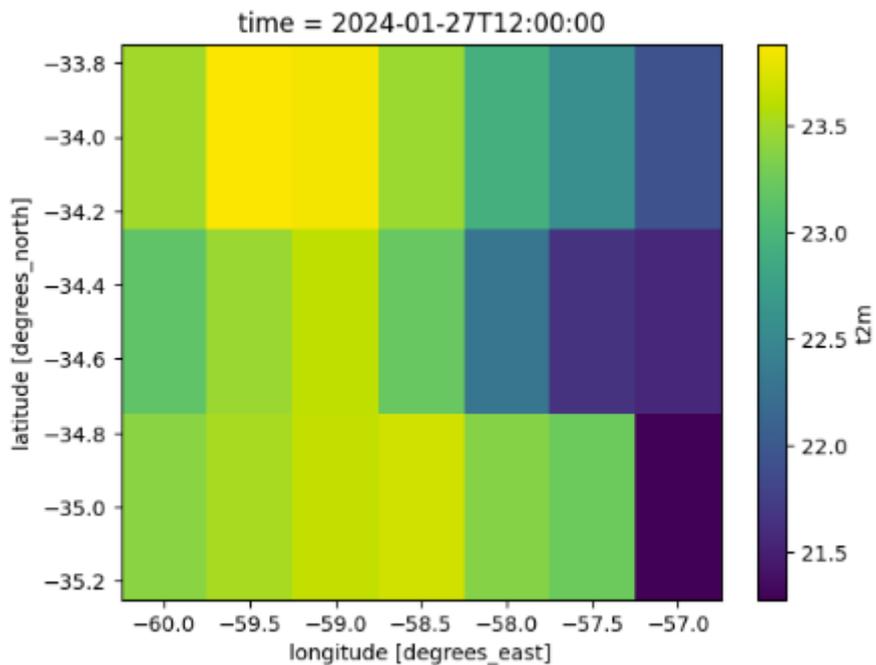
- Acceso a los Datos de ECMWF: Utilizar la API web de Python de ECMWF para conectarse al conjunto de datos ERA5.
- Descarga de Datos: Recuperar los datos de temperatura para la región geográfica y el periodo de tiempo especificados. Se deben especificar parámetros como la latitud, longitud, rango de tiempo y variables deseadas (por ejemplo, temperatura a 2 metros).
- Procesamiento de Datos: Extraer y manipular la información de temperatura de los archivos de datos descargados, que generalmente están disponibles en formatos como GRIB o netCDF.
- Análisis y Visualización: Aplicar métodos estadísticos (como estadísticas descriptivas, análisis de correlación, regresión) y técnicas de visualización (incluyendo gráficos de series temporales, mapas espaciales, gráficos de dispersión) para analizar y visualizar los datos de temperatura. Esto ayuda a descubrir información y patrones relevantes para los objetivos de investigación.
- Generación de Credenciales para Acceso a Datos de ERA5: Acceder a los datos de la base de datos ERA5 requiere obtener credenciales únicas, específicamente el ID de usuario (UID) y la clave de API, proporcionados por el Centro Europeo de Predicción Meteorológica a Plazo Medio (ECMWF). Estas credenciales permiten a los usuarios acceder al portal de datos del ECMWF, facilitando la recuperación de datos de ERA5 con fines académicos, de investigación y educativos.

Para asegurar que la información fuera adecuada para nuestra investigación, tuvimos que preprocesarla una vez que tuvimos acceso a ella. Los datos de temperatura, inicialmente proporcionados en archivos netCDF (NC), requerían un examen cuidadoso y transformación en un formato de tabla final. Este proceso implicó varias etapas de modificación de datos para garantizar la fiabilidad y consistencia de los datos. La conversión de unidades y la extracción de variables fueron dos técnicas importantes utilizadas. Específicamente, la extracción de variables implicó aislar puntos de datos relevantes del conjunto de datos más grande, como lecturas específicas de temperatura para ubicaciones y momentos particulares. La conversión de unidades fue necesaria para estandarizar los datos; por ejemplo, convirtiendo los valores de temperatura de Kelvin a grados Celsius para facilitar una interpretación más sencilla y comparación con otros conjuntos de datos.

Los datos procesados fueron luego visualizados utilizando herramientas de graficación (Figura 3), lo que nos proporcionó información sobre los patrones de temperatura y la distribución geográfica en la región específica en diferentes momentos. Estas visualizaciones de datos ofrecen una imagen clara y detallada de cómo varía la temperatura en diferentes lugares y períodos de tiempo, lo cual es fundamental para identificar tendencias y anomalías en los datos.

Para obtener información detallada sobre los pasos y técnicas de preprocesamiento de datos, consulte el Apéndice A. Este apéndice proporciona un desglose paso a paso de los métodos utilizados, incluidos los scripts específicos y las herramientas de software empleadas en los procesos de extracción, conversión y visualización de datos.

Figura 3: Visualización de Temperatura de ERA5



Después de procesar los datos de ERA5 en una tabla por ubicación, fecha y hora, pudimos integrarlos perfectamente con los datos de Twitter al emparejar estas variables. Esta integración dio como resultado un conjunto de datos de tweets que ahora incluye la variable de temperatura para cada entrada.

3. Análisis Exploratorio

En esta sección realizamos un análisis exploratorio y descriptivo de los conjuntos de datos de Twitter y ERA5. El objetivo es obtener conocimientos iniciales sobre los datos recopilados y comprender sus características. Al examinar variables clave y realizar análisis preliminares, buscamos identificar patrones, tendencias y posibles relaciones dentro de los conjuntos de datos. Estos conocimientos orientarán nuestros pasos metodológicos posteriores y nos ayudarán a definir nuestro enfoque para el análisis de datos.

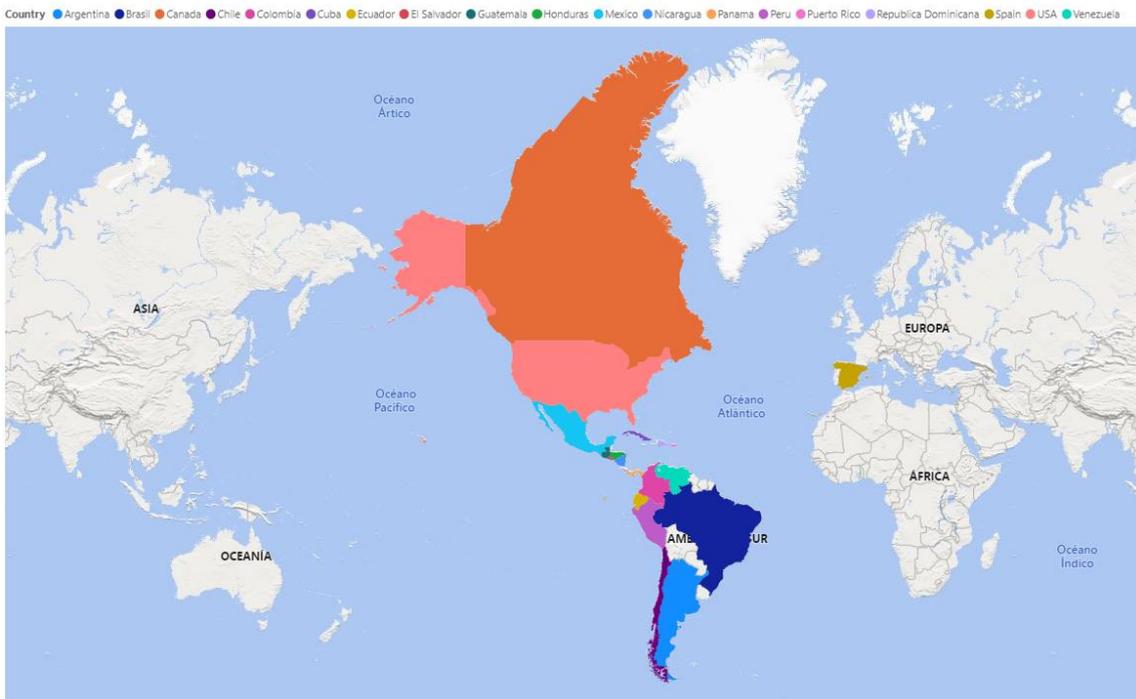
3.1. Tweets

El conjunto de datos utilizado en este estudio comprende respuestas de Twitter de diversas empresas orientadas al servicio. Cada unidad de análisis es un tweet individual obtenido de la sección de Respuestas de empresas en los sectores de aerolíneas, hoteles, telecomunicaciones y entrega, seleccionados por sus altos niveles de interacción con los clientes. Nuestro conjunto de datos es robusto, abarcando casi 300,000 tweets originados en más de 60 empresas de 15 países durante los años 2022 y 2023. La información extraída incluye detalles sobre la empresa, su país e industria, junto con perfiles de cuentas de Twitter, marcas de tiempo (formateadas como "AAAA-MM-DDTHH:MM.fffZ"), y métricas de participación como comentarios, me gusta,

visualizaciones y retweets. Además, capturamos detalles clave de la cuenta de la empresa como el año de creación, total de publicaciones y el número de seguidores.

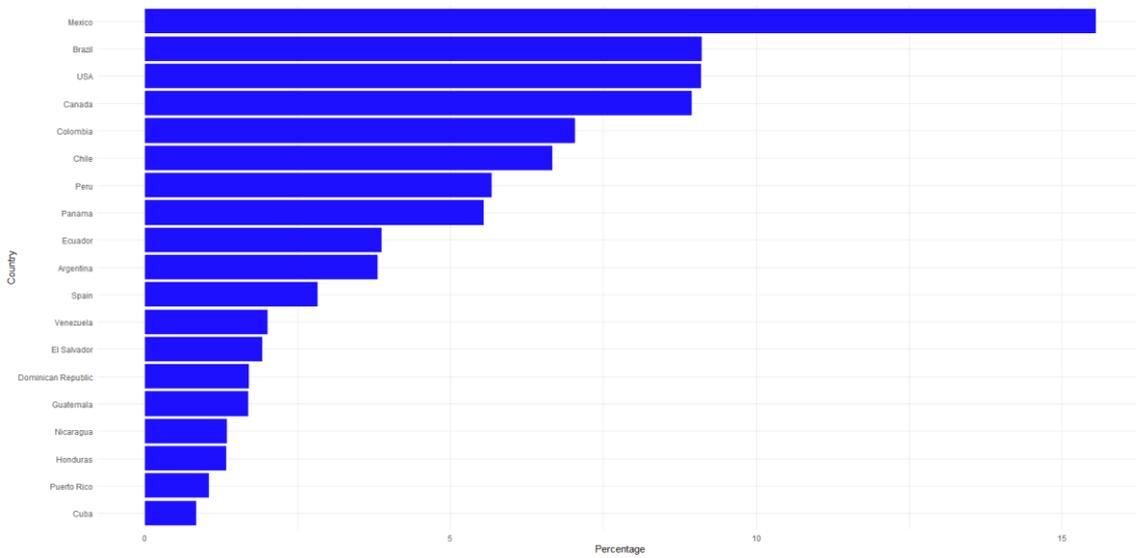
La Figura 4 destaca los países de América y España incluidos en nuestro conjunto de datos, proporcionando una visión regional de las interacciones de los clientes en Twitter dentro de la industria de servicios. Esta representación geográfica concentrada permite un examen detallado de las tendencias de participación de los clientes en estas regiones específicas, considerando posibles matices culturales y dinámicas industriales únicas en América y España..

Figura 4: Países del Conjunto de Datos



Si observamos más detalladamente por país y vemos el porcentaje de participación de cada uno dentro del conjunto de datos, podemos utilizar el siguiente gráfico circular:

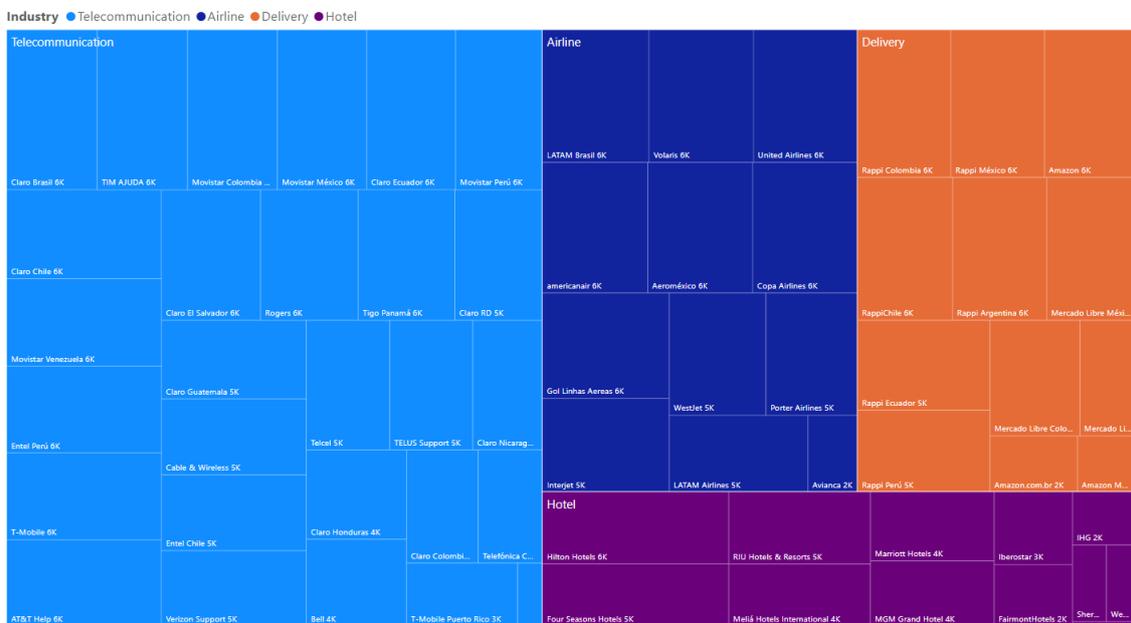
Figura 5: Participación por País



Podemos observar en el gráfico (Figura 5) que los datos no están concentrados en un solo país, sino que es un conjunto de datos bastante equilibrado en cuanto a los tweets de cada uno de ellos.

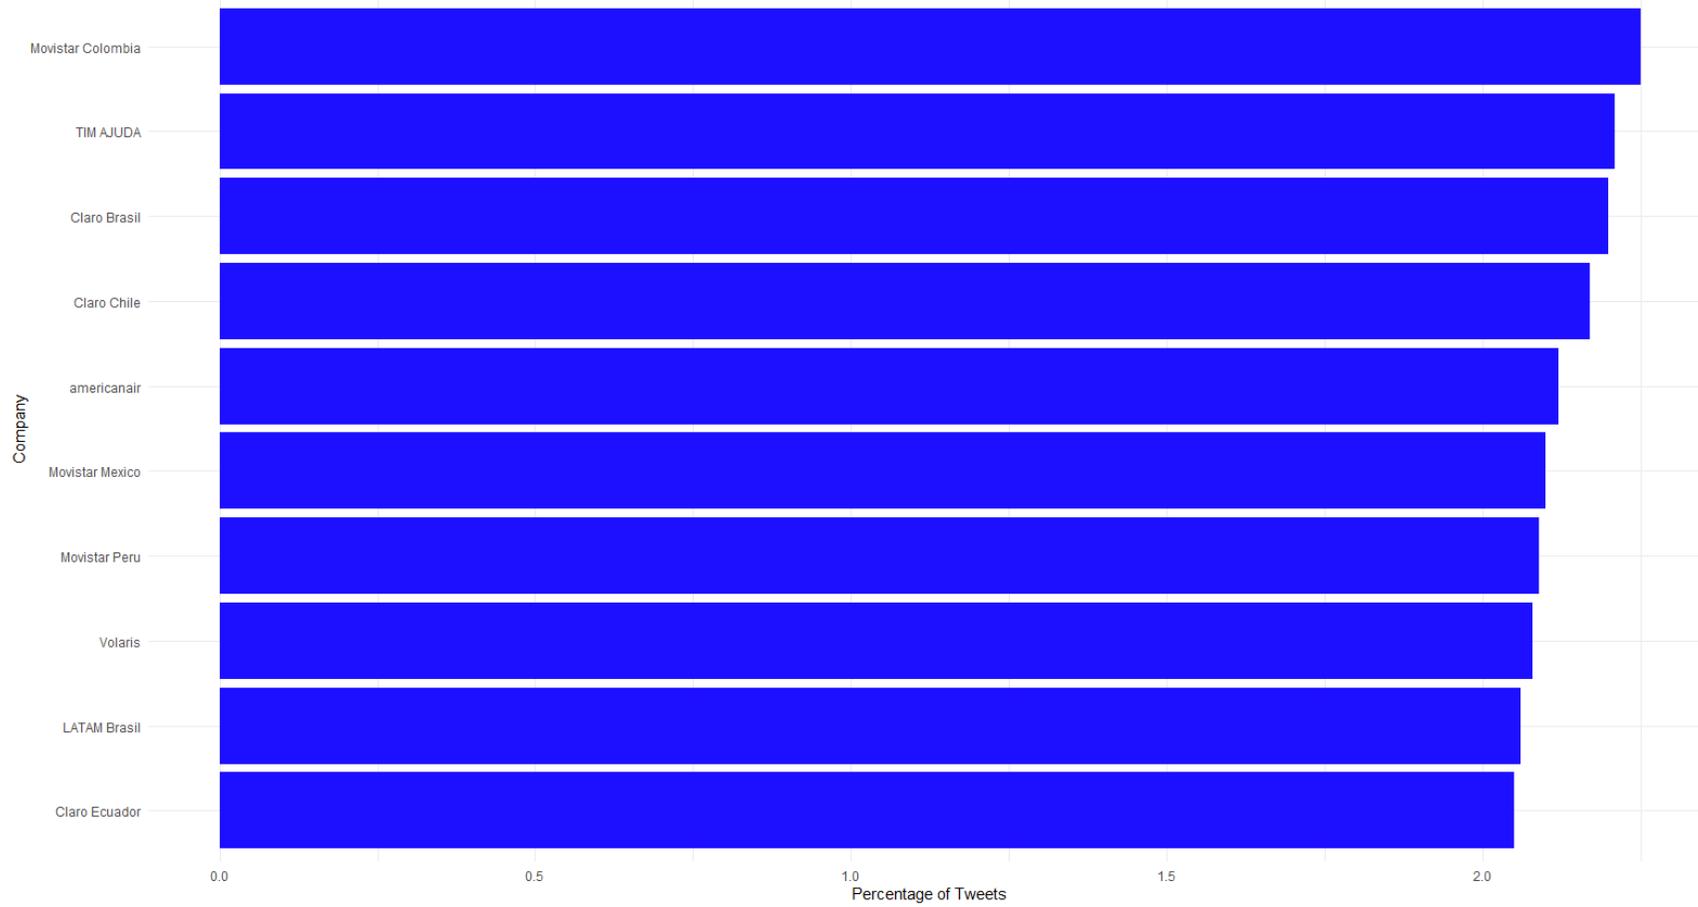
Para ofrecer una representación visual de la distribución de tweets entre diversas empresas de servicios, hemos incorporado un Treemap (Figura 6), que proporciona una imagen clara e intuitiva del recuento de tweets asociados con cada empresa en nuestro conjunto de datos.

Figure 6: Conteo de Tweets por Empresa



Es importante señalar que la distribución está bien equilibrada y no hay una sola empresa que englobe todos los datos. Esta distribución equilibrada asegura una representación completa y diversa de las interacciones de los clientes en una multitud de proveedores de servicios.

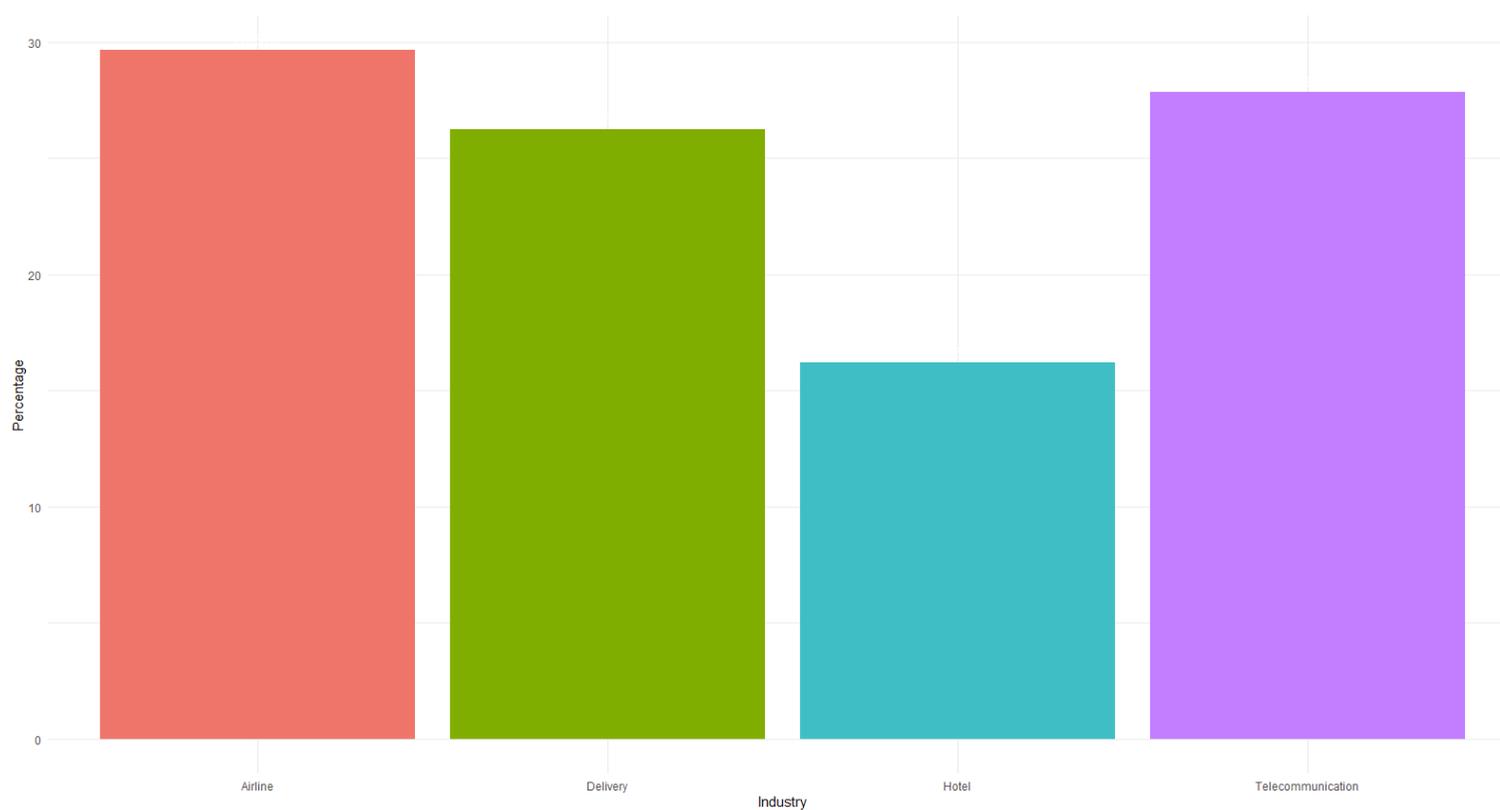
Figura 7: Top 10 Empresas por Porcentaje de Tweets



En la Figura 7, observamos que no hay una concentración significativa de tweets por parte de una sola empresa dentro de nuestro conjunto de datos, ya que el mayor contribuidor, Movistar Colombia, representa ligeramente menos del 2.5% del total del conjunto de datos. Además, las primeras posiciones en el ranking están ocupadas por empresas de telecomunicaciones, con la presencia de una aerolínea en las primeras posiciones.

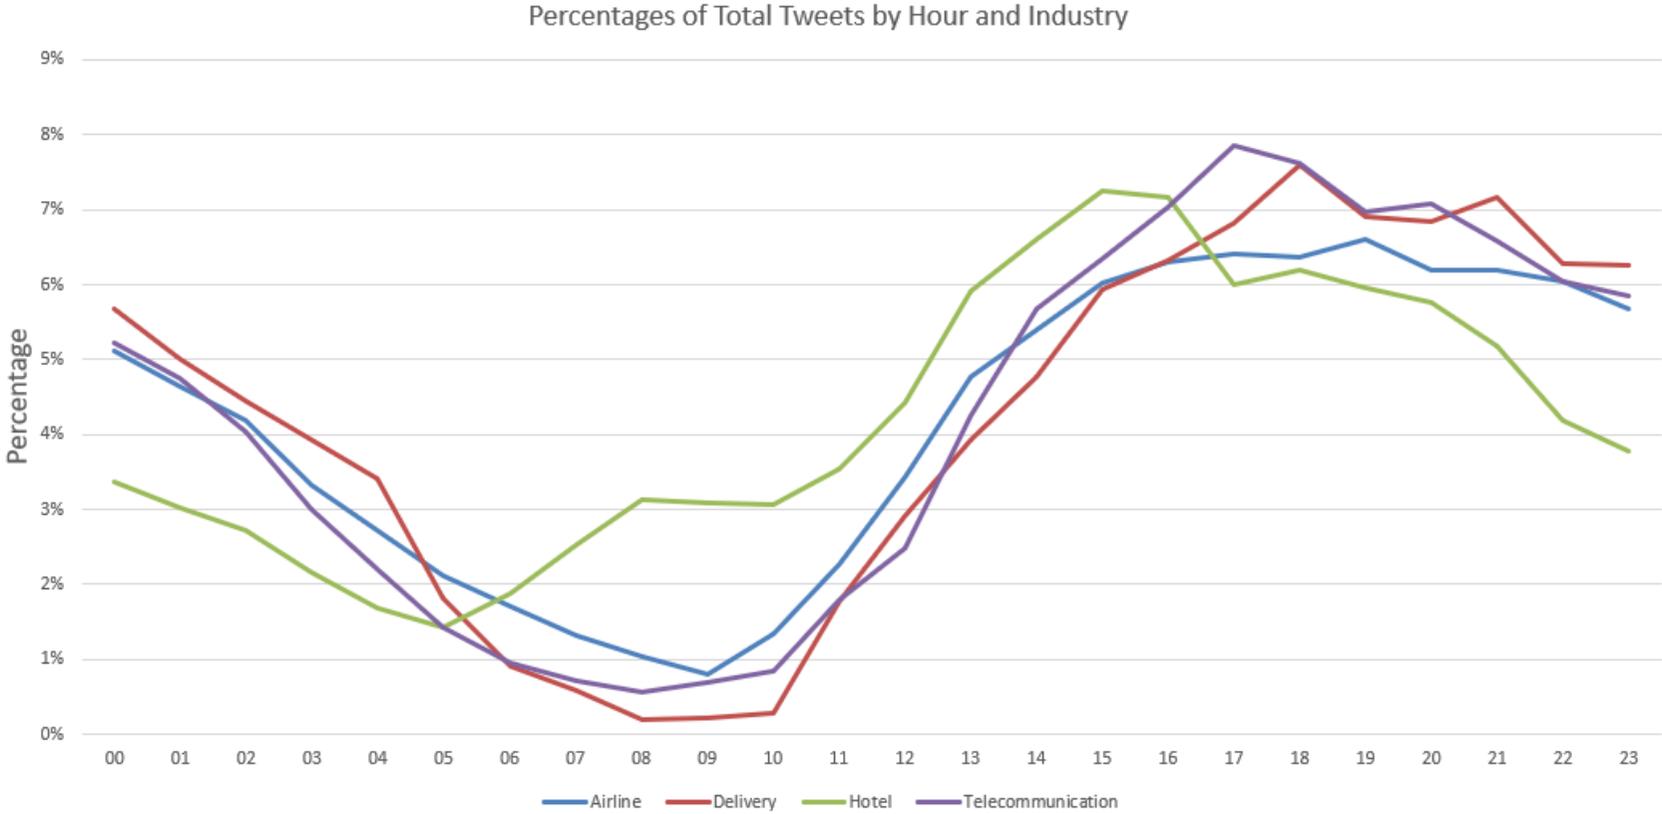
Mientras exploramos más a fondo, adentrémonos en el porcentaje promedio de tweets por industria (Figura 8) para obtener ideas sobre los niveles generales de participación en diferentes sectores:

Figura 8: Porcentaje Promedio de Tweets por Industria



Es evidente que aunque no hay una concentración significativa dentro de una industria específica, el sector de Hoteles muestra una participación más baja en comparación con otras industrias. Posteriormente, nos propusimos entender si esta diferencia podría observarse en la variable temporal. Para explorar esto, nuestro objetivo fue observar el comportamiento de los tweets a lo largo de las horas del día (Figura 9):

Figura 9: Porcentajes de Tweets Totales por Hora e Industria



El gráfico muestra que generalmente hay más actividad de usuarios entre las 2:00 y las 10:00 p.m. Sin embargo, ninguna industria experimenta una concentración de más del 7% de todos los tweets, incluso durante las horas pico. Una observación adicional significativa es que hay una diferencia de dos puntos porcentuales en el sector hotelero durante las horas de la mañana en comparación con otros momentos. Esta variación podría explicarse por la naturaleza de las operaciones hoteleras, que suelen estar vinculadas a las primeras o últimas horas del día. Las experiencias negativas y las quejas de los clientes pueden ocurrir en cualquier momento del día, y la distribución de tweets indica que la actividad y los comentarios de los usuarios son continuos en lugar de estar concentrados en ciertos momentos. Esto respalda la idea de que los incidentes negativos no ocurren en un momento específico, sino que se distribuyen a lo largo del día, reflejando las interacciones continuas entre clientes y empresas en diferentes industrias.

4. Variable Independiente: Categoría de Temperatura

La variable independiente en nuestro estudio se refiere a las categorías de temperatura, las cuales desempeñan un papel crucial en la comprensión de la influencia de los factores ambientales en la incivildad del cliente. Esta sección describe el proceso de generación y categorización de la variable de temperatura para el análisis.

Tras acceder a los datos de ERA5 como se mencionó en la sección 2.2 ERA5, los datos de temperatura se integraron sin problemas con los datos de Twitter. Mediante la coincidencia de variables de ubicación, fecha y hora, la variable de temperatura se incorporó al conjunto de datos de tweets (Tabla 2). Esta integración nos permitió analizar la relación entre la temperatura y algunas de nuestras variables clave del conjunto de datos, como país o tiempo.

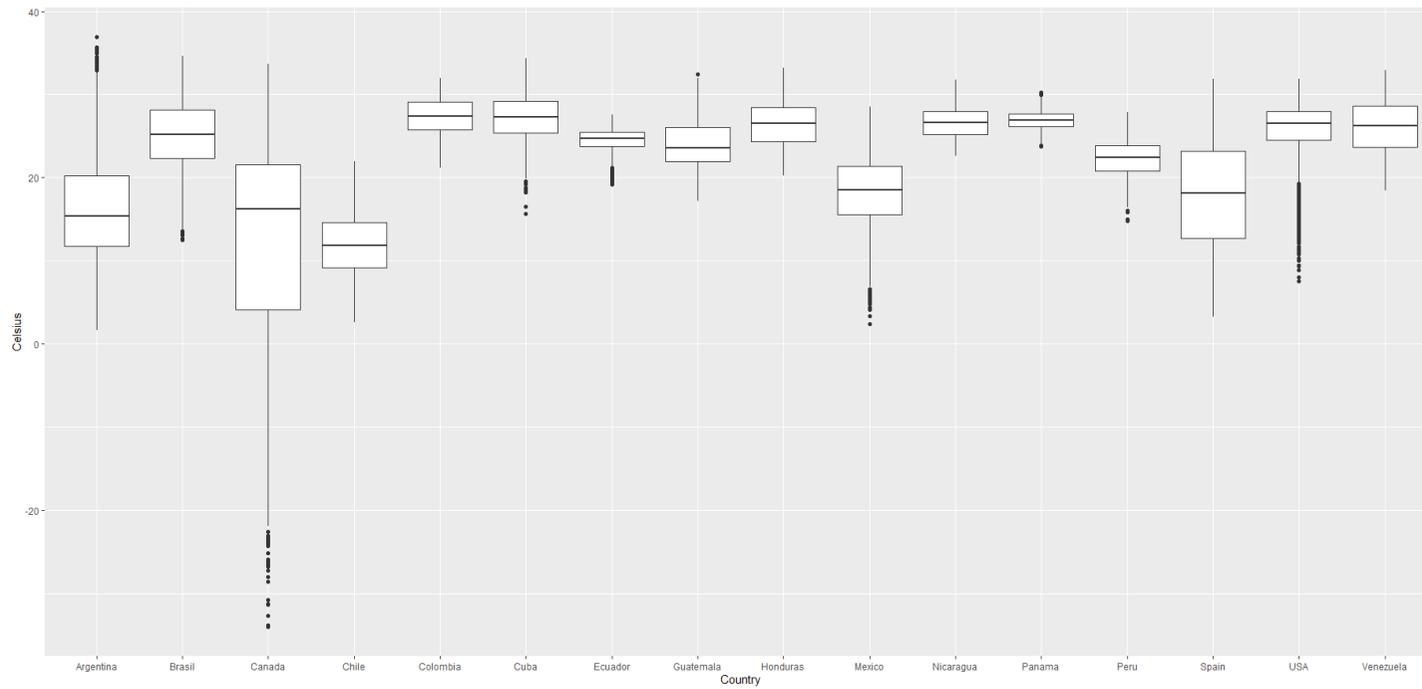
Tabla 2: Datos de muestra

ID	Empresa	País	Industria	Timestamp	Contenido del Tweet	Temperatura (Promedio diario, Celsius)	Puntuacion de Incivildad del Cliente (Predicción LLM)
1	Aeroméxico	Mexico	Airline	2023-10-02 04:53:05	Hoy en el vuelo 2697 de CDMX a Zacatecas nos quedamos aprox 2 horas parados... por favor Aeroméxico que pasa con el profesionalismo?	15.43	1

39166	Claro Brasil	Brasil	Telecommunication	2023-09-28 20:54:05	sem internet desde as 10:30, obrigada @ClaroBrasil por me fazer perder um dia inteiro de trabalho, nem preciso de dinheiro mesmo, sou milionária assim como vocês	28.38	2
95320	Entel Perú	Peru	Telecommunication	2023-10-02 14:19:37	Un mes más pagando una suscripción que nunca hice @EntelPeru después de que me dijeron que me iban a desafiliar y devolver el dinero el mes pasado.	23.31	1
78347	Claro Nicaragua	Nicaragua	Telecommunication	2022-09-26 17:15:08	los hptas de @ClaroNicaragua nunca resuelven ni verga jajsjsjsjs	27.37	3

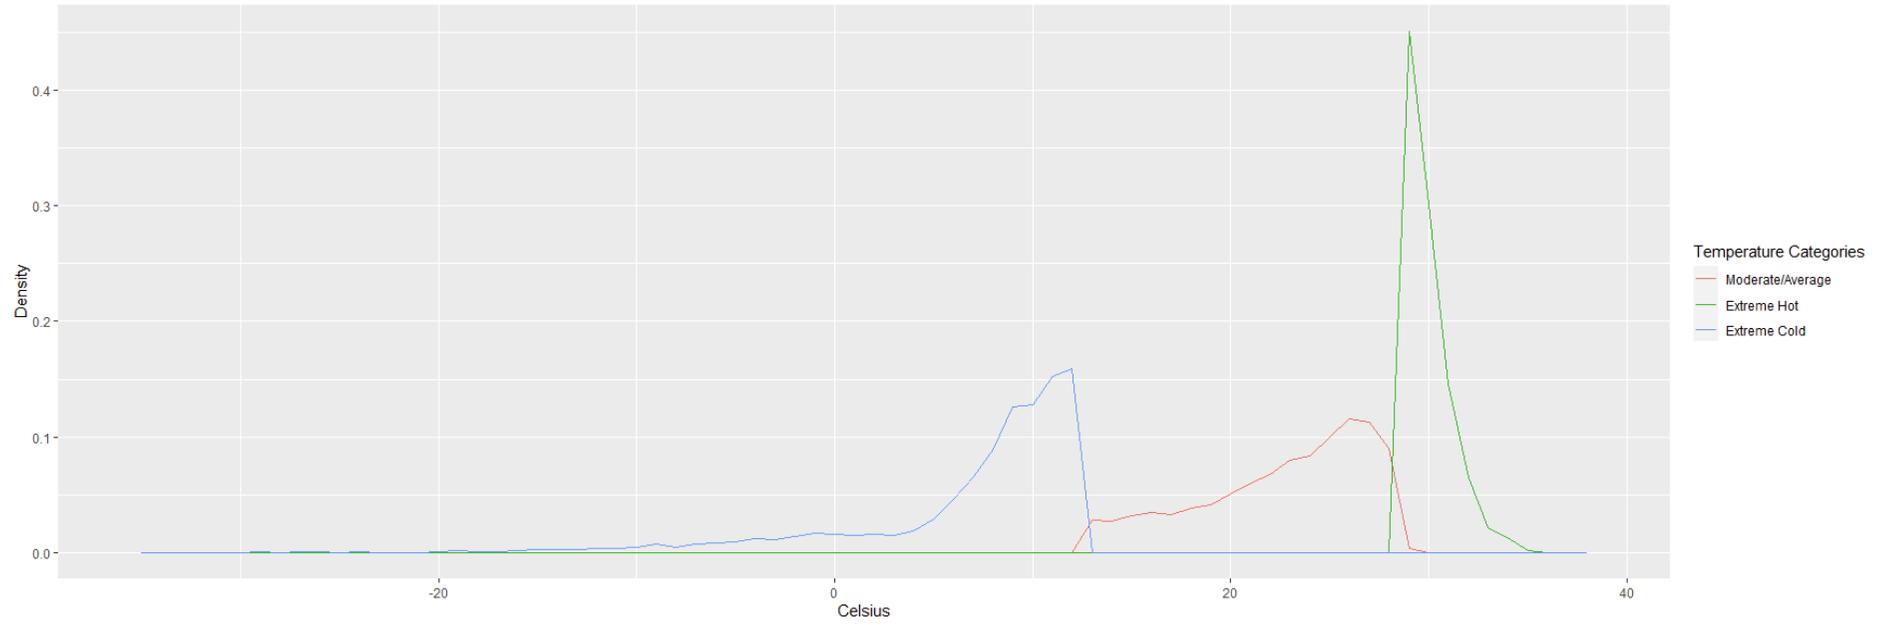
El diagrama de caja (Figura 10) revela variaciones significativas en las distribuciones de temperatura entre los países representados, proporcionando insights sobre las tendencias centrales y la variabilidad de las lecturas de temperatura.

Figura 10: Diagramas de caja de temperatura por país



Además, evaluamos la distribución de temperaturas extremas (Figura 11), centrándonos especialmente en las frías.

Figura 11: Densidad de Categorías de Temperatura



Hemos examinado la distribución de temperaturas extremas, enfocándonos particularmente en las temperaturas más frías. Mientras que las temperaturas extremadamente altas consistentemente oscilaron entre 28 y 40 grados Celsius, las temperaturas más frías mostraron un rango menos extremo, que abarca desde +10 hasta -30 grados Celsius. Dado que la mayoría de las observaciones estaban por encima de cero, especialmente considerando las ubicaciones de nuestra muestra principalmente en América Central y América Latina, sugerimos reconsiderar los cuantiles utilizados para codificar las temperaturas extremas. Utilizar umbrales más estrictos, como 0.10 y 0.90, podría ofrecer una representación más precisa de las condiciones de temperatura extrema. A pesar de que la mayoría de las observaciones están por encima de cero, mantenemos nuestra decisión de utilizar los cuantiles 0.10 y 0.90 para la codificación de temperaturas extremas para garantizar consistencia metodológica y fiabilidad. Este ajuste tiene como objetivo mantener el equilibrio y la sistematicidad al mismo tiempo que se tienen en cuenta las características climáticas únicas de las regiones de nuestra muestra.

4.1 Generación de la variable independiente

El análisis de las distribuciones de temperatura, como se ilustra en las Figuras 10 y 11, proporcionó conocimientos significativos sobre las tendencias de temperatura en muchas naciones y áreas. El análisis de diagrama de caja (Figura 10) mostró diferencias notables en las distribuciones de temperatura de los países representados, lo cual indica las diversas condiciones climáticas existentes. Además, el gráfico de densidad (Figura 11) proporcionó más información, especialmente en lo que respecta a los rangos de temperaturas más frías, al enfocarse en las temperaturas extremas.

Los resultados mencionados subrayan la importancia de documentar con precisión las fluctuaciones de temperatura para comprender su posible impacto en las interacciones de los clientes en entornos de servicio en línea. Utilizamos umbrales basados en el percentil 10 y 90 de la distribución de temperatura para categorizar eficazmente las temperaturas. Mediante este método, creamos tres categorías separadas de temperatura: "Extremadamente Caliente," "Moderada/Normal," y "Extremadamente Frío". Esta clasificación, basada en la metodología presentada por Stechemesser et al. (2022), permite una comprensión más sofisticada de las tendencias de temperatura y su posible influencia en varios factores, como la rudeza entre los clientes en línea.

En resumen, el proceso de clasificación de las temperaturas en grupos discretos según criterios percentiles ofrece nuevas perspectivas importantes sobre las tendencias de temperatura y cómo podrían afectar las interacciones de los clientes en entornos de soporte en línea. A través de la integración fluida de los datos de temperatura con nuestro conjunto de datos y la aplicación de enfoques inspirados en la investigación, nuestro objetivo es arrojar luz sobre la compleja interacción entre las condiciones ambientales y la rudeza de los clientes. Las conclusiones del análisis profundizarán nuestro conocimiento sobre cómo las fluctuaciones de temperatura afectan la actividad del consumidor en línea y proporcionarán orientación para desarrollar técnicas que mejoren las experiencias del consumidor en diversas circunstancias climáticas.

5. Variable de Incivilidad del Cliente

5.1. Generación de la Variable Dependiente

La base de nuestro estudio es la capacidad para cuantificar la rudeza del cliente, que sirve como nuestra variable dependiente. Al comenzar nuestra investigación, nos enfrentamos a un desafío metodológico significativo: la ausencia de una escala validada específicamente diseñada para medir la rudeza entre los clientes durante los encuentros de servicio en línea. Esta brecha hizo necesario desarrollar un nuevo sistema de codificación para evaluar con precisión el nivel de rudeza que los consumidores mostraban en sus interacciones con las empresas en las redes sociales.

Para abordar este desafío, nos basamos en las definiciones y criterios existentes de incivismo del consumidor documentados en investigaciones anteriores (Tabla 3). Estas definiciones proporcionaron un marco fundamental que abarca comportamientos que van desde la rudeza sutil hasta formas más evidentes de descortesía. Cada definición de la Tabla 3 aporta dimensiones distintas a nuestro sistema de codificación, garantizando una cobertura integral del incivismo del cliente en diversos contextos.

Tabla 3. *Definiciones Existentes de Incivismo*

Referencia	Definición
(Andersson and Pearson, 1999, p. 457)	“El incivismo en el lugar de trabajo es un comportamiento desviado de baja intensidad con una intención ambigua de dañar al objetivo, en violación de las normas laborales de respeto mutuo. Los comportamientos incivilizados son típicamente groseros y descorteses, mostrando una falta de consideración por los demás.”
(Béal et al., 2023, p. 8)	“El incivismo es un constructo amplio que abarca una amplia gama de comportamientos que incluyen la rudeza, la falta de cortesía, mostrar una falta de consideración por los demás, adoptar un tono condescendiente, insultar y realizar ataques verbales.”
(Coe, Kenski, and Rains 2014)	"En las redes sociales, las publicaciones inciviles suelen estar caracterizadas por insinuaciones, vulgaridad, discurso peyorativo y el uso de letras mayúsculas."
(Skarlicki et al., 2008)	“La injusticia del cliente se refiere al trato injusto o inadecuado experimentado por individuos de parte de clientes en interacciones relacionadas con el servicio. Esta forma de injusticia

	se caracteriza por comportamientos que violan normas de respeto, dignidad y equidad en las relaciones interpersonales. Indicadores clave de injusticia del cliente incluyen, pero no se limitan a, clientes que se niegan a escuchar, interrumpen, hacen demandas irrazonables, plantean discusiones irrelevantes, dudan de la capacidad del empleado, gritan, usan un lenguaje condescendiente y hablan agresivamente."
(Sliter et al., 2010, p. 468)	"... la incivilidad también ocurre con el cliente como perpetrador de la incivilidad y un empleado de la organización como objetivo. Esto es la incivilidad del cliente, o un comportamiento desviado de baja intensidad, perpetrado por alguien en un rol de cliente, con una intención ambigua de dañar a un empleado, en violación de normas sociales de respeto mutuo y cortesía."

Basándonos en investigaciones recientes en el campo, desarrollamos instrucciones de codificación que abarcaron todo el espectro de rudeza en las redes sociales, desde comentarios neutros hasta declaraciones altamente despectivas. Una vez definidas las puntuaciones de incivilidad del cliente utilizando este marco integral, utilizamos ChatGPT para evaluar y asignar consistentemente puntuaciones a los tweets. Esta utilización de ChatGPT fue fundamental debido a su capacidad para interpretar el contenido de los tweets en diferentes idiomas y regiones, aprovechando su extenso entrenamiento en datos de redes sociales. Al emular procedimientos de codificación similares a los humanos, ChatGPT facilitó el procesamiento ágil y confiable de una amplia variedad de interacciones en redes sociales.

Para clasificar eficazmente los tweets según el nivel de incivilidad del cliente, implementamos ChatGPT, un modelo de lenguaje de aprendizaje profundo conocido por su habilidad para comprender y generar texto similar al humano. Nuestra metodología incluyó varios pasos críticos:

- **Creación del conjunto de datos:** Como se detalló en secciones anteriores, curamos un conjunto de datos que consiste en tweets y datos de temperatura asociados. Este conjunto de datos sirvió como base para entrenar y validar nuestro modelo, asegurando que fuera robusto y representativo de interacciones reales en las redes sociales.
- **Generación del cuestionario humano:** Utilizando las definiciones de incivilidad del cliente descritas en la Tabla 3, desarrollamos meticulosamente un cuestionario para guiar a los evaluadores humanos en la clasificación consistente de tweets en diferentes niveles de incivilidad. Este cuestionario proporcionó criterios claros y definiciones (consulte el Apéndice B para detalles específicos del cuestionario).
- **Proceso de entrenamiento:** ChatGPT se empleó para simular la codificación humana basada en las reglas definidas en el cuestionario. Inicialmente, el modelo fue provisto con estas reglas para asegurar evaluaciones consistentes. Lotes de 30 tweets fueron luego alimentados secuencialmente a ChatGPT, el cual clasificó cada tweet según nuestros criterios establecidos. Este proceso iterativo nos permitió refinar y mejorar la precisión del modelo en ciclos de entrenamiento sucesivos.

- Evaluación y validación:** Para evaluar la precisión y el rendimiento del modelo, dividimos el conjunto de datos final proporcionado por ChatGPT en conjuntos de entrenamiento (70%) y validación (30%). Esta división permitió el refinamiento iterativo de nuestro enfoque, identificando y abordando debilidades en categorías o tipos específicos de tweets. Se emplearon métricas de evaluación como precisión, recall y puntaje F1 (consulte las métricas detalladas en el Apéndice F) para cuantificar la efectividad del modelo en la clasificación de niveles de incivildad del cliente.

Una vez obtenidos los datos simulados iniciales, procedimos a entrenar nuestro Modelo de Lenguaje Grande (ver el modelo LLM en el Apéndice E). Los Modelos de Lenguaje Grande (LLMs) son modelos avanzados de aprendizaje automático diseñados para entender y generar texto similar al humano basándose en la entrada que reciben. Estos modelos se construyen utilizando técnicas de aprendizaje profundo, específicamente aprovechando redes neuronales con muchas capas (arquitecturas profundas). Los modelos LLM más conocidos son BERT (Bidirectional Encoder Representations from Transformers) de Google y los modelos GPT (Generative Pre-trained Transformer) de OpenAI, entre otros.

Los LLMs son capaces de capturar una amplia gama de patrones lingüísticos, contexto y conocimiento, dado que han sido entrenados con enormes volúmenes de datos textuales de diversas fuentes, incluyendo libros, páginas web y artículos. El proceso de entrenamiento se divide principalmente en dos fases: pre-entrenamiento y ajuste fino. El pre-entrenamiento enseña al modelo a anticipar la siguiente palabra de una oración basándose en sus términos precedentes a lo largo de miles de millones de oraciones. En este punto, el modelo adquiere una comprensión completa del lenguaje. El ajuste fino implica entrenar el modelo en una tarea específica con datos etiquetados, lo que le permite desempeñarse bien en aplicaciones dirigidas como análisis de sentimientos, traducción o resumen (Devlin et al., 2018; Radford et al., 2019).

En nuestra investigación, clasificamos los tweets según su nivel de rudeza utilizando un LLM. Al utilizar la capacidad del modelo para comprender el contexto y las sutilezas del lenguaje humano, este método lo convierte en una herramienta efectiva para el análisis de sentimientos. El sistema de puntuación del LLM, que refleja los diferentes niveles de rudeza de los clientes registrados en el conjunto de datos, va de 0 (neutral) a 4 (muy incivil). El uso de un LLM garantiza un enfoque escalable y consistente para el análisis de grandes volúmenes de datos textuales, lo cual es fundamental para investigar la correlación entre la temperatura y el comportamiento de los clientes en las redes sociales (Vaswani et al., 2017).

Para garantizar la máxima precisión de nuestro modelo, fue imperativo un riguroso procesamiento, examen de resultados y ajustes tanto en las entradas de datos como en las variables del modelo. Este proceso iterativo de refinamiento tuvo como objetivo mejorar el rendimiento del modelo frente a diversos contenidos de tweets y variaciones contextuales..

Tabla 4. *Customer Incivility Classification Accuracy and Tweets Classified by Incivility Level*

Nivel de Incivildad	Precisión de la Clasificación (%)	Porcentaje de Tweets en la Base de Datos (%)
---------------------	-----------------------------------	--

Neutral (Nivel 0)	80%	7.70%
Levemente Incivil (Nivel 1)	47.46%	43.75%
Moderadamente Incivil (Nivel 2)	36.67%	2.95%
Altamente Incivil (Nivel 3)	50.85%	12.48%
Extremadamente Incivil (Nivel 4)	48.15%	33.12%

Para mejorar la efectividad de nuestro modelo, empleamos diversas mejoras iterativas y modificaciones en nuestro estudio. En el contexto del aprendizaje automático, el ajuste fino es crucial para adaptar un modelo preentrenado como ChatGPT a una tarea específica, como el análisis de sentimientos o, en nuestro caso, la clasificación de niveles de incivildad del cliente. Este proceso incluyó:

- **Mejoras Iterativas:** Empleamos mejoras y modificaciones iterativas tanto en nuestro conjunto de datos como en las variables del modelo basadas en los resultados de la evaluación. Este proceso iterativo tenía como objetivo mejorar la precisión de clasificación del modelo en diversos contenidos y contextos de tweets.
- **Métricas de Desempeño:** A lo largo del proceso de ajuste fino, evaluamos rigurosamente el modelo utilizando diversas métricas de desempeño para medir su eficacia en manejar la complejidad y el matiz de las interacciones en redes sociales.

Como se muestra en la Tabla 4, pudimos lograr una precisión de clasificación que oscila entre el 36% y el 80% en varios grados de rudeza con esta técnica. Para generar el puntaje de incivildad del cliente, utilizamos un modelo de lenguaje profundo (LLM) para codificarlos según su nivel de incivildad.

Tras limpiar las entradas no relacionadas con datos, los tweets que no eran respuestas de clientes y la propaganda, redujimos nuestra base de datos a 131,748 tweets de clientes que interactuaron con 64 empresas ubicadas en 19 países, abarcando 4 industrias comúnmente asociadas con fallos en el servicio, como aerolíneas u hoteles (consulte las Figuras 6; Figuras C1 y C2 del Apéndice C). Luego, de manera similar a cómo entrenaríamos a un codificador humano, instruimos a nuestro LLM sobre cómo codificar la incivildad del cliente. En ausencia de una escala validada, utilizamos las definiciones existentes de incivildad del cliente (consulte la Tabla 3) y creamos un esquema de codificación que proporciona descripciones específicas que van desde 1 = neutral hasta 5 = publicaciones extremadamente groseras en redes sociales (consulte el Apéndice B).

Para contextualizar el rendimiento de nuestro modelo, es fundamental contrastarlo con modelos de referencia. Un modelo de referencia generalmente adopta un enfoque simplista, como predecir todas las observaciones en una sola categoría. En un conjunto de datos equilibrado con cinco niveles distintos, un modelo de referencia normalmente alcanzaría una precisión máxima de alrededor del 20%. Sin embargo, nuestro modelo superó significativamente estas expectativas, demostrando su capacidad para discernir niveles matizados de incivildad en tweets con una precisión notable.

Además, es crucial considerar cómo los falsos positivos y los falsos negativos pueden afectar nuestra investigación. Dado que recibir un tweet civil mal clasificado no presenta problemas operativos, los falsos positivos, es decir, tweets clasificados erróneamente como incivil, no tendrían un efecto negativo significativo en los empleados de primera línea (FLEs) en el contexto de nuestra investigación particular. Sin embargo, los falsos negativos, es decir, tweets incivilizados clasificados erróneamente como civiles, afectarían nuestra capacidad para dividir y controlar con precisión el grado de incivildad que experimentan los FLEs. Para mantener la integridad y eficacia de nuestro sistema de categorización en el manejo de la incivildad del cliente en los contactos de servicio, es especialmente crucial minimizar los falsos negativos.

Además de la precisión, evaluamos nuestro modelo utilizando métricas de validación exhaustivas detalladas en el Apéndice F. Estas métricas incluyen precisión, recuperación (recall) y puntuación F1, que proporcionan información sobre la capacidad del modelo para identificar instancias positivas teniendo en cuenta tanto los falsos positivos como los falsos negativos. Para nuestro Modelo de Lenguaje Grande (LLM), la precisión fue de 0.4746, la recuperación fue de 0.5385 y la puntuación F1 fue de 0.5045.

Además, analizamos la matriz de confusión (consulte la Figura F1, Apéndice F) para obtener una visión detallada del rendimiento de clasificación del LLM en diferentes clases. Las estadísticas generales, que incluyen precisión, intervalo de confianza del 95%, tasa de información nula y valor kappa, ofrecen una evaluación resumida del rendimiento del LLM y su acuerdo con las etiquetas de clase reales.

Además, las estadísticas por clase proporcionan un desglose de varias métricas de rendimiento para cada clase en el conjunto de datos, ofreciendo información sobre la capacidad del LLM para distinguir entre diferentes clases (consulte la Tabla F1, Apéndice F). Los principales puntos destacados de las clases mencionadas son::

- La tabla muestra una alta especificidad en todos los niveles de incivildad, lo que indica la robusta capacidad del modelo para identificar con precisión los tweets no incivilizados.
- La sensibilidad varía entre las clases, con una sensibilidad notablemente alta observada para tweets Extremadamente Incivilizados, subrayando la eficacia del modelo para detectar casos severos de incivildad.
- Los valores predictivos positivos (PPV) muestran una precisión moderada en la clasificación de tweets en sus respectivos niveles de incivildad.
- La prevalencia de detección destaca áreas donde el modelo sobresale en la identificación precisa de todos los niveles específicos de incivildad presentes en el conjunto de datos.
- La precisión balanceada general de 0.7750 indica un rendimiento sólido en la clasificación de niveles de incivildad del cliente en diversas interacciones, sugiriendo

áreas potenciales para mejorar la sensibilidad, especialmente para clases menos prevalentes.

Finalmente, después de configurar nuestro LLM, procedimos a puntuar el resto del conjunto de datos para generar nuestra variable dependiente de Incivilidad del Cliente.

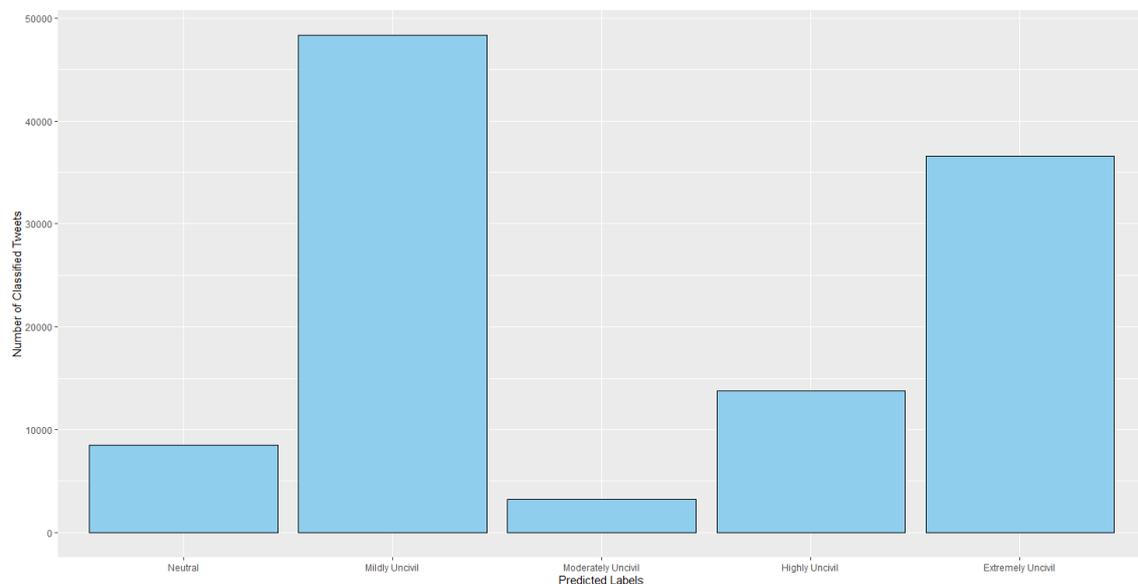
5.2. Incivilidad del Cliente: Análisis Exploratorio

La incivilidad del cliente, definida como comportamiento grosero, irrespetuoso o socialmente inaceptable hacia los empleados de servicio, es una preocupación significativa para las empresas en diversas industrias. En nuestro esfuerzo por comprender la dinámica de la incivilidad del cliente, emprendemos un análisis exploratorio para obtener información sobre su distribución, patrones y asociaciones.

Distribución de los Puntajes de Incivilidad del Cliente:

Comenzamos nuestro análisis examinando la distribución de los puntajes de incivilidad del cliente a través de un histograma (Figura 12). Esta visualización sirve como nuestra primera mirada a la prevalencia e intensidad del comportamiento incivil en las interacciones con los clientes.

Figura 12: Distribución de la Incivilidad del Cliente



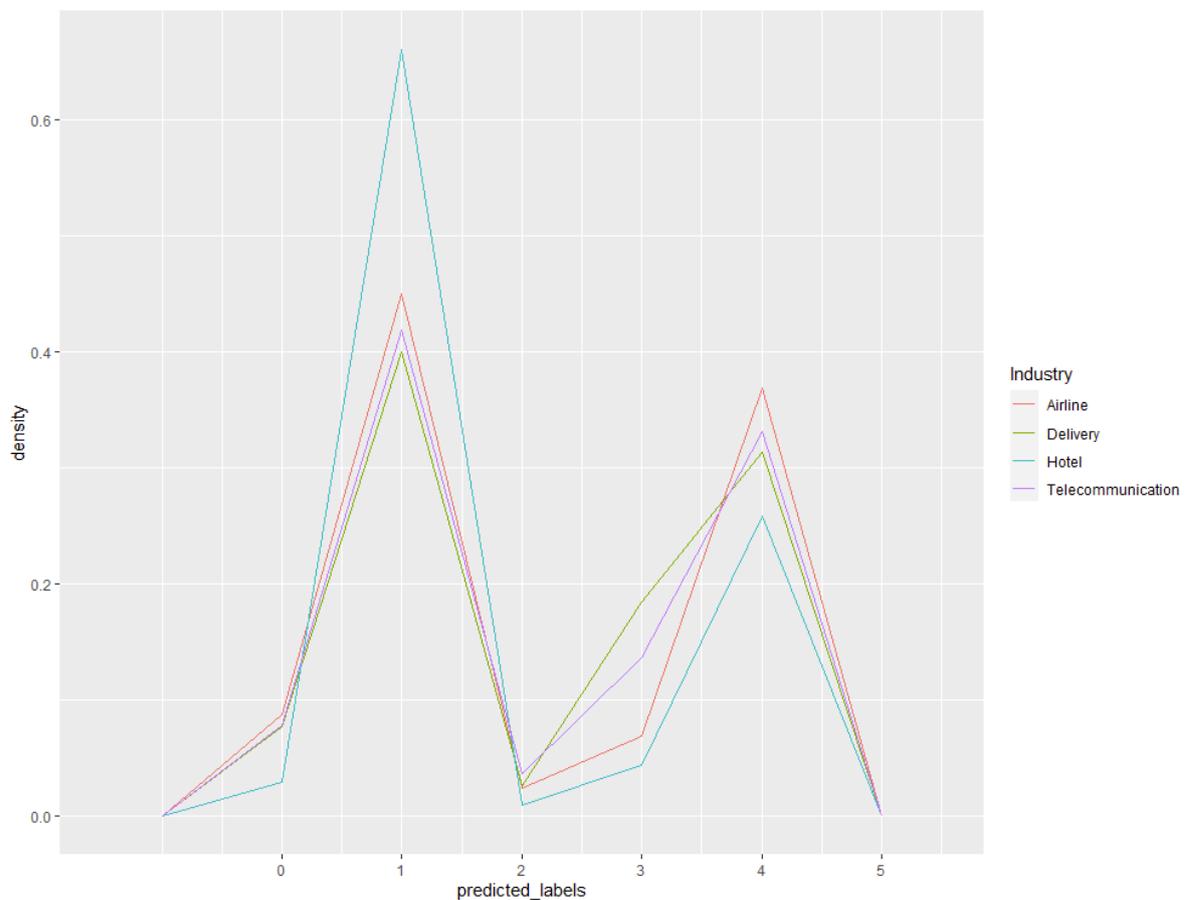
Al observar el histograma (Figura 12), destacan algunos patrones interesantes. Específicamente, la distribución parece ser bimodal, lo que sugiere que hay dos picos separados en el grado medio de rudeza. Esto implica que existen dos categorías principales de interacciones: aquellas con grados relativamente bajos de rudeza y aquellas con niveles más altos de rudeza. Comprender esta distribución es crucial para discernir posibles subconjuntos de encuentros con clientes y personalizar enfoques para satisfacer sus necesidades particulares. Es importante recordar que un "Neutral" en nuestra escala denota encuentros neutrales, no necesariamente corteses.

Además, aunque la mayoría de las interacciones muestran puntajes de incivildad relativamente bajos, hay instancias discernibles de valores extremos que representan interacciones con niveles excepcionalmente altos de incivildad. Aunque no son atípicos tradicionales, estos valores extremos podrían influir significativamente en los análisis de regresión y justificar un análisis más detenido.

Conclusiones del Análisis por Industria:

Continuando con nuestra exploración, nos adentramos en cómo varían las puntuaciones de incivildad del cliente en diferentes industrias. Al visualizar la distribución de estas puntuaciones dentro de cada sector (Figura 13), buscamos obtener perspectivas sobre las dinámicas únicas de las interacciones con clientes prevalentes en varias industrias.

Figura 13: Densidad de Incivildad del Cliente por Industria



Nuestro análisis revela variaciones notables en los niveles de incivildad del cliente entre industrias. Específicamente, la industria hotelera emerge con un nivel promedio más bajo de incivildad del cliente en comparación con otros sectores. Esta observación sugiere posibles diferencias en el comportamiento y niveles de satisfacción del cliente entre industrias, lo que motiva una investigación más profunda sobre los factores específicos de cada industria que influyen en las interacciones con los clientes.

Al examinar la influencia de la temperatura, investigamos la relación entre la incivildad del cliente y las categorías de temperatura. Utilizando diagramas de caja, exploramos cómo fluctúan

los niveles de incivildad en diferentes condiciones de temperatura, con la hipótesis de que las temperaturas extremas podrían exacerbar la incivildad del cliente.

Mediante un polígono de frecuencia, representamos la distribución de los niveles de incivildad en diferentes categorías de temperatura. Esta visualización nos permite identificar patrones o tendencias en el comportamiento del cliente respecto a las variaciones de temperatura..

Conclusiones y Recomendaciones:

Nuestro análisis exploratorio ofrece valiosas percepciones sobre la distribución, patrones y asociaciones de la incivildad del cliente. Comprender estas dinámicas es crucial para diseñar estrategias efectivas para gestionar y mitigar comportamientos incivilizados de los clientes.

Para avanzar, es esencial considerar los efectos fijos de la industria y el país en nuestros análisis para abordar posibles variables de confusión. Además, se justifica realizar más investigaciones para profundizar en los factores subyacentes que impulsan la incivildad del cliente y explorar estrategias detalladas para abordar el comportamiento incivil en diferentes contextos.

6. Pruebas de Hipótesis y Resultados

Esta sección explora la relación entre las variaciones de temperatura y la incivildad del cliente en las interacciones de servicio en línea. Al categorizar los datos de temperatura y utilizar modelos de aprendizaje profundo para evaluar las interacciones en redes sociales, investigamos cómo los factores ambientales influyen en el comportamiento del consumidor.

Para recopilar los datos necesarios, nos enfocamos en Twitter como nuestra fuente principal. Recolectamos tweets dirigidos a diversas organizaciones en diferentes industrias, asegurando un conjunto de datos diverso que incluye interacciones de servicio al cliente con empresas como Amazon y AT&T. Cada tweet incluía geolocalización y contenido, lo que nos permitió mapear el sentimiento del cliente a regiones específicas y a las condiciones ambientales correspondientes. Herramientas como Tweepy y Octoparse facilitaron la extracción de tweets que mencionaban cuentas de servicio al cliente, asegurando una cobertura integral de diversos sectores de servicio y ubicaciones geográficas.

Además de los datos de Twitter, obtuvimos datos climáticos del conjunto de datos ERA5 proporcionado por el Centro Europeo para Pronósticos Meteorológicos a Medio Plazo (ECMWF). ERA5 ofrece registros de temperatura horarios de alta resolución a nivel global, lo que nos permitió alinear con precisión las condiciones de temperatura con las marcas de tiempo y ubicaciones de los tweets. La integración de estos dos conjuntos de datos nos permitió crear un conjunto de datos cohesivo, vinculando los tweets con registros de temperatura correspondientes para examinar cómo las variaciones de temperatura se correlacionan con los niveles de incivildad del cliente.

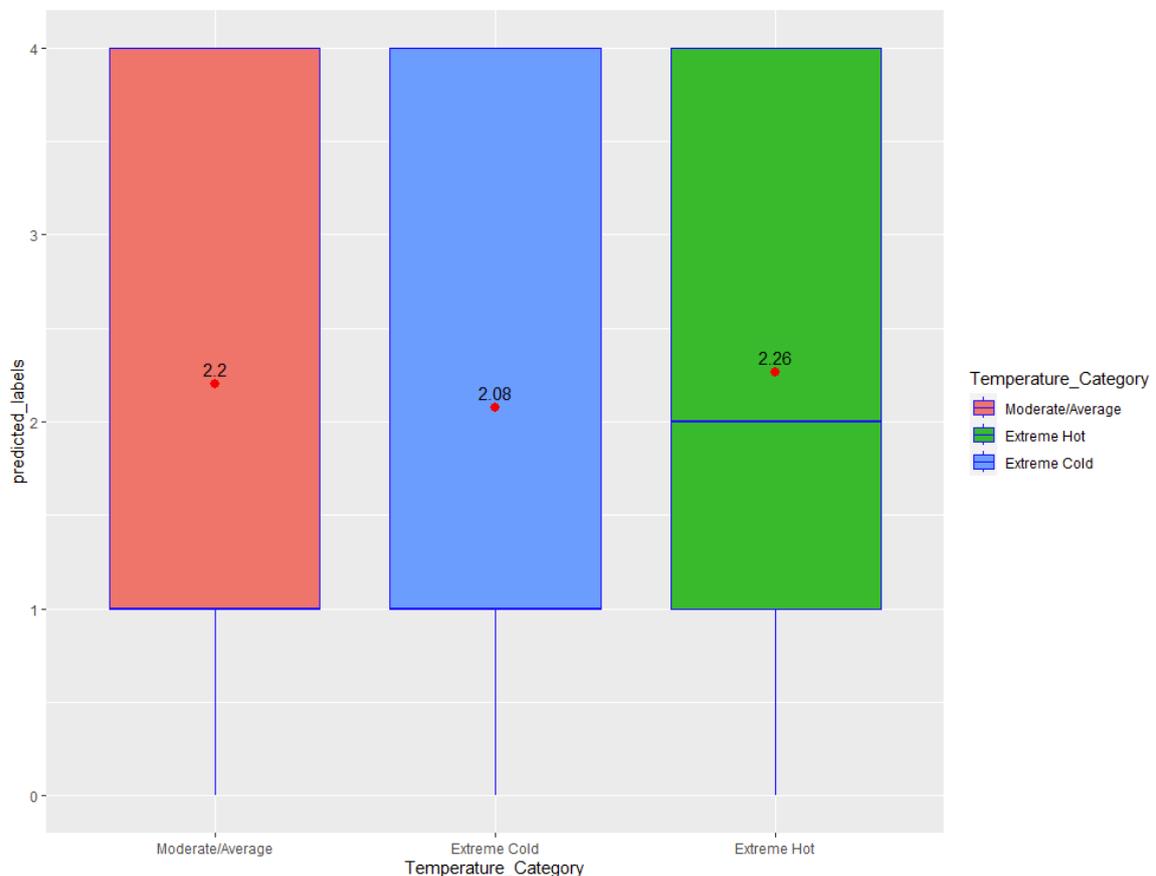
Con los datos integrados, categorizamos los datos de temperatura y los puntajes de incivildad del cliente, lo que nos permitió investigar cómo estas variables se relacionan entre sí e influyen las interacciones del consumidor en entornos de servicio en línea. Nuestro análisis comienza examinando las conexiones entre los puntajes de incivildad del cliente y las categorías de temperatura. Luego empleamos análisis de regresión para explorar la capacidad predictiva de las categorías de temperatura sobre la rudeza del cliente, ajustando para factores relevantes como empresas específicas y meses.

6.1. Análisis y Estimaciones del Modelo

Para identificar posibles relaciones entre estos factores, comenzamos nuestro estudio examinando las conexiones entre los puntajes de incivilidad del cliente y las categorías de temperatura. Luego, después de ajustar por factores pertinentes, utilizamos análisis de regresión para explorar más a fondo la capacidad predictiva de las categorías de temperatura sobre la rudeza del cliente.

A través de esta investigación, esperamos aprender más sobre cómo los factores ambientales, específicamente las variaciones de temperatura, pueden afectar el comportamiento del consumidor en las interacciones de servicio en línea. Estos hallazgos tienen implicaciones importantes para las empresas que buscan mejorar las interacciones con los clientes y mitigar los efectos negativos de la rudeza en los foros en línea.

Figura 14: Distribución de Incivilidad del Cliente por Categoría de Temperatura



Los diagramas de caja en la Figura 14 muestran la relación entre las categorías de temperatura y los niveles de incivilidad del cliente, revelando patrones perspicaces. Como se anticipaba, el nivel medio de incivilidad del cliente tiende a aumentar con temperaturas más altas, coincidiendo con nuestras expectativas.

- Los cuadros para todas las categorías de temperatura, incluidas las moderadas/medias y las extremadamente calurosas, en su mayoría abarcan desde 1 hasta 4, indicando un rango de niveles de incivilidad del cliente en diferentes condiciones de temperatura.

- Es notable que las temperaturas extremadamente calurosas muestran un nivel medio de incivilidad del cliente más alto, centrado alrededor de 3, en comparación con las temperaturas moderadas/medias, donde el nivel medio de incivilidad del cliente está más cerca de 1.

Estas observaciones iniciales sugieren una asociación cualitativa entre la temperatura y la incivilidad del cliente, resaltando la posible influencia del calor extremo en las interacciones en línea.

6.2. Modelos de Regresión

Para explorar la relación entre las variaciones de temperatura y la incivilidad del cliente en las interacciones en línea, utilizamos regresión de mínimos cuadrados ordinarios (OLS, por sus siglas en inglés) (ver Ecuación 1). Este enfoque estima cómo los cambios en la temperatura, categorizados en diferentes niveles de extremidad, influyen en los puntajes predichos de incivilidad del cliente. Además, controlamos por empresas específicas y meses para aislar el impacto de la temperatura en el comportamiento del cliente.

Ecuación 1: Regresión de Mínimos Cuadrados Ordinarios

$$\begin{aligned}
 &\text{Customer Incivility LLM Predicted Score} \\
 &= \beta_0 + \beta_1 \text{temperature} \\
 &+ \beta_2 \text{Interaction_Temperature_Category_Extreme_Hot} \\
 &+ \beta_3 \text{Interaction_Temperature_Category_Extreme_Cold} \\
 &+ \beta_4 \text{Temperature_Category} + \sum_{i=1}^n \beta_i \text{factor}(\text{Company}_i) \\
 &+ \sum_{j=2}^{12} \beta_j \text{factor}(\text{Month}_j) + \epsilon
 \end{aligned}$$

Donde:

- **Customer Incivility LLM Predicted Score:** Representa la puntuación predicha de incivilidad del cliente basada en el modelo de regresión.
- **Temperature, Interaction_Temperature_Category_Extreme_Hot, Interaction_Temperature_Category_Extreme_Cold, and Temperature_Category:** Variables explicativas relacionadas con las condiciones de temperatura.
- **Factor(Company) and Factor(Month):** Denotan variables dummy que representan empresas individuales y meses, respectivamente.
- β_n : Representa los coeficientes estimados que indican el tamaño del efecto de cada variable en la "Puntuación Predicha de Incivilidad del Cliente LLM".
- ϵ : Denota el término de error, capturando la varianza no explicada en la variable dependiente.

Este modelo nos permitió examinar cómo las categorías de temperatura, junto con otros factores pertinentes como la empresa y el mes, influyen en los niveles de incivilidad del cliente en las interacciones de servicio en línea.

Los resultados de la regresión (ver detalles en el Apéndice G) indican varios hallazgos significativos:

- Las temperaturas más altas (**temperature**) y el calor extremo (**Interaction_Temperature_Category_Extreme_Hot**) están asociados positivamente con los puntajes de incivilidad del cliente.
- El frío extremo (**Interaction_Temperature_Category_Extreme_Cold**) muestra una asociación negativa con los puntajes de incivilidad.
- Ciertas categorías de temperatura (**Temperature_Category**) exhiben efectos variables en los niveles de incivilidad.

La inclusión de variables dummy para empresas individuales y meses revela diferencias notables en los puntajes de incivilidad del cliente entre diversas entidades y períodos de tiempo. Por ejemplo, empresas como Amazon y AT&T Help muestran impactos significativos en los puntajes de incivilidad en comparación con las categorías de referencia.

Los coeficientes en el Apéndice G representan los efectos estimados de cada variable en los puntajes de incivilidad del cliente, junto con sus errores estándar, valores t y valores p asociados. Notablemente, coeficientes más altos indican asociaciones más fuertes con la incivilidad del cliente.

En general, este análisis de regresión proporciona insights sobre cómo los factores ambientales, especialmente las variaciones de temperatura, y variables contextuales influyen en el comportamiento del consumidor en entornos de servicio en línea. Estos hallazgos subrayan la compleja interacción entre elementos ambientales e interacciones del cliente, ofreciendo implicaciones valiosas para la gestión de experiencias de cliente en línea y la mitigación de los efectos negativos de la incivilidad..

Las comparaciones por pares pueden ser representadas por la siguiente ecuación:

Ecuación 2: Prueba de Bonferroni

$$t - value = \frac{\bar{X}_1 - \bar{X}_2}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}}$$

Donde:

- \bar{X}_1 y \bar{X}_2 son las medias de los puntajes de incivilidad del cliente para dos categorías diferentes de temperatura.
- s_1^2 y s_2^2 son las varianzas de los puntajes de incivilidad del cliente para las respectivas categorías de temperatura.
- n_1 y n_2 son los tamaños de muestra para las respectivas categorías de temperatura.

Tabla 5: Importancia de las Diferencias en la Media de Incivilidad del Cliente entre Categorías de Temperatura

	Moderado/Promedio	Extremadamente Caliente
Extreme Hot	<0.0000000000000002	-
Extreme Cold	<0.0000000000000002	<0.0000000000000002

P value adjustment method: bonferroni

Para abordar la heterocedasticidad y la correlación serial, empleamos errores estándar robustos. La tabla de correlación presentada (Tabla 5) ofrece evidencia convincente de un efecto significativo de las temperaturas extremas en la incivilidad del cliente. El test de correlación de Pearson realizado en la Tabla 8 proporciona evidencia convincente de una correlación significativa entre las temperaturas extremas y la incivilidad del cliente, destacando la existencia de una relación hipotetizada antes de realizar el análisis de regresión.

6.3. Verificaciones de Robustez

Para asegurar la solidez de nuestros hallazgos, realizamos varios análisis adicionales, incluyendo el uso de errores estándar agrupados. Esta técnica tiene en cuenta posibles correlaciones dentro de los grupos que podrían influir en los errores estándar de nuestras estimaciones.

Tabla 6: Errores Estándar Agrupados

	Estimate	Srd. Error	t-value	Pr(> t)
Min.	-2.311624	0.002953	-9.1011	0.00000
1st Qu.	-0.059237	0.041187	-1.2510	0.06235
Median	-0.019167	0.046266	-0.4011	0.21876
Mean	-0.132342	0.056765	0.1530	0.33520
3rd Qu.	0.007578	0.051628	0.8197	0.55601

Max.

0.313799

0.253993

9.3743

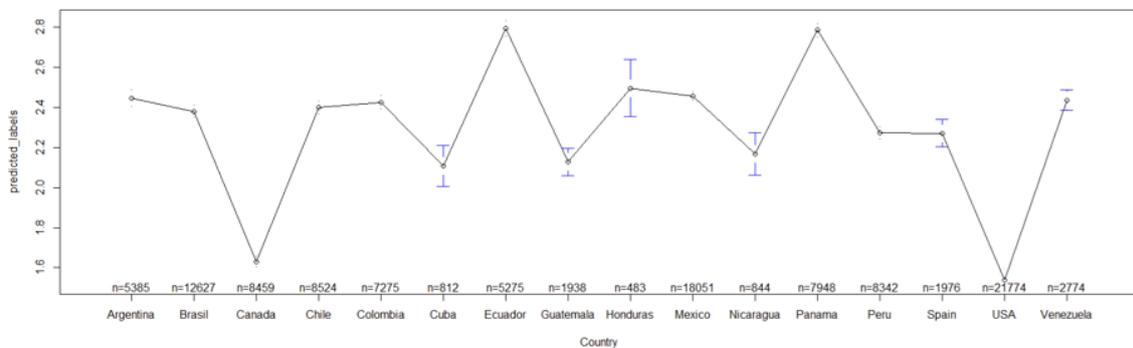
0.90825

Los errores estándar agrupados sugieren que nuestras estimaciones de modelo son robustas frente a posibles correlaciones dentro de los grupos de observaciones. Esta verificación de robustez respalda aún más la validez de nuestros hallazgos de regresión.

Para comprender mejor las dinámicas complejas de la incivilidad del cliente, examinamos las variaciones que existen entre países y meses. Este análisis tiene como objetivo identificar patrones que podrían influir potencialmente en nuestro modelo de regresión.

Un análisis detallado de la Variable Dependiente en diferentes países (Figura 15) revela una distribución compleja de puntajes promedio de incivilidad:

Figura 15: Heterogeneidad entre Países

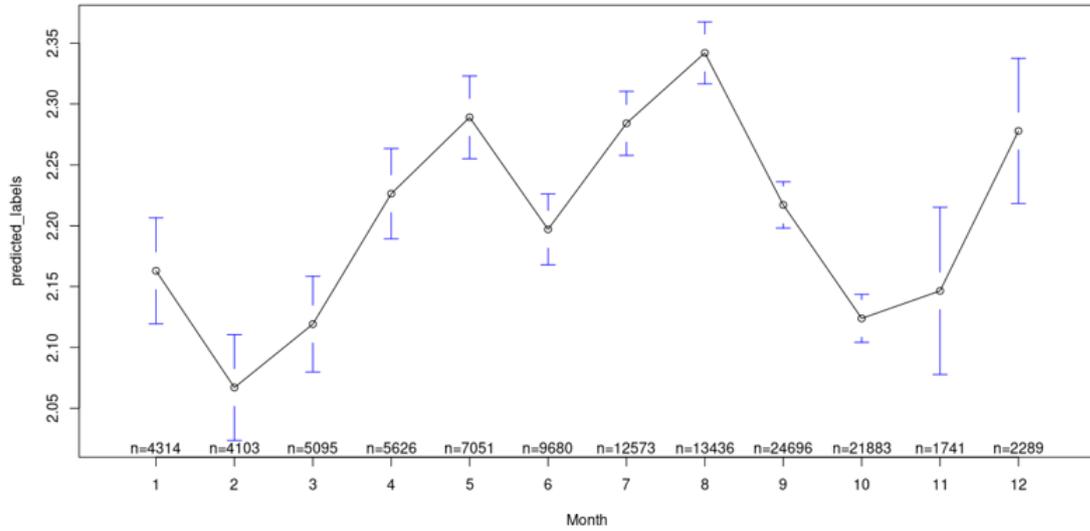


Mientras existen variaciones modestas, que van desde 1.6 (Canadá y Estados Unidos) hasta 2.8 (Ecuador y Panamá), con varios países convergiendo alrededor de la marca de 2.4 (incluyendo Argentina, Brasil, Chile, Colombia, Cuba, Guatemala, Perú y España), no surgen discrepancias profundas. Esta observación matizada subraya un hilo consistente de incivilidad del cliente que permea el panorama global, sugiriendo una similitud armónica en la dinámica de las interacciones con los clientes.

Transición a una lente temporal, analizamos meticulosamente la distribución de los puntajes promedio de incivilidad a lo largo de los meses.

También analizamos la distribución de los puntajes promedio de incivilidad a lo largo de los meses (Figura 16):

Figura 16: Heterogeneidad a lo largo de los Meses



En la Figura 16, observamos un patrón claro caracterizado por regularidad temporal y dinámicas estacionales. Agosto emerge como el pico máximo, con el puntaje promedio más alto de 2.35, seguido de cerca por mayo, julio y diciembre, cada uno registrando un puntaje promedio de 2.30. Por el contrario, los meses de abril, junio y septiembre muestran puntajes promedio ligeramente menores de 2.22, mientras que enero, octubre y noviembre se agrupan alrededor de 1.15. Notablemente, marzo concluye con un puntaje promedio de aproximadamente 2.11. Este análisis temporal revela un patrón rítmico a lo largo de los meses, sin fluctuaciones significativas en los puntajes promedio de incivilidad a lo largo del ciclo anual.

En resumen, estas comprobaciones de robustez y análisis adicionales destacan la fiabilidad y consistencia de nuestros hallazgos, subrayando el impacto significativo de las variaciones de temperatura en la incivilidad del cliente en interacciones en línea, al tiempo que se tienen en cuenta posibles heterogeneidades entre países y meses.

6.4. ANOVA de un factor y Correlaciones

Realizamos un ANOVA de un factor para evaluar las diferencias en la incivilidad en línea de los clientes a través de tres categorías de temperatura. El modelo ANOVA se representa como:

Ecuación 3: ANOVA de Incivilidad del Cliente

$$Y_{ij} = \mu + \tau_i + \epsilon_{ij}$$

Donde:

- Y_{ij} representa el puntaje de incivilidad para la j -ésima observación en la i -ésima categoría de temperatura.
- μ es el puntaje promedio general de incivilidad.
- τ_i es el efecto de la i -ésima categoría de temperature.

- ϵ_{ij} es el término de error aleatorio.

Tabla 7: ANOVA de Incivilidad del Cliente

	Df	Sum Sq	Mean Sq	F Value	p-Value
Temperature Category	2	828	414.0	187.7	<2e-16 ***
Residuals	112484	248138	2.2		

Signif. codes:

0 ‘‘ 0.001 ‘‘ 0.01 ‘‘ 0.05 ‘.’ 0.1‘

Los resultados indican diferencias significativas en los niveles de incivilidad entre las categorías de temperatura, con un valor de F de 187.7 y un valor de p menor a 2e-16. Las comparaciones por pares confirmaron diferencias significativas en las tres categorías de temperatura (todos los valores de $p < 0.01$). Esto sugiere que la temperatura influye significativamente en el nivel de incivilidad experimentado por los clientes.

Calculamos términos de interacción entre la temperatura promedio en la ubicación del tweet y las variables ficticias de temperatura extrema. Se observaron correlaciones positivas entre estos términos de interacción y el grado de incivilidad del cliente.

El coeficiente de correlación de Pearson r_{xy} se calcula utilizando la siguiente fórmula::

Ecuación 4: Correlación de Pearson

$$r_{xy} = \frac{\sum(X - \bar{X})(Y - \bar{Y})}{\sqrt{\sum(X - \bar{X})^2 \sum(Y - \bar{Y})^2}}$$

Where:

- r_{xy} is the Pearson correlation coefficient between variables X and Y/
- X : represents the average temperature at the location of the tweet/
- Y represents the incivility score assigned to each tweet.
- \bar{X} and \bar{Y} are the mean values of X and Y respectively.

Tabla 8: Tabla de Correlación

	1	2	3
1. Temperature			
2. Customer Incivility	.04***		
3. Inter. Extreme Temperature Hot	.40***	.04***	
4. Inter. Extreme Temperature Cold	.77***	.06***	.10***

Note. This table presents Pearson correlation coefficients with pairwise deletion. * $p < .05$, ** $p < .01$, *** $p < .001$

Estos hallazgos subrayan nuestra hipótesis de que las temperaturas extremas se correlacionan con un aumento de la incivilidad del cliente en línea. La tabla adjunta realiza pruebas t para explorar las disparidades en los niveles de incivilidad entre las tres categorías de temperatura, ofreciendo comparaciones detalladas entre estos grupos. Este análisis complementa el ANOVA exhaustivo presentado en la Tabla 7, que evalúa las diferencias generales en la incivilidad a través de todas las categorías de temperatura. En conjunto, estos conocimientos profundizan nuestra comprensión de cómo las variaciones ambientales influyen en las interacciones de los clientes en línea.

6.5. Modelos de Regresión de Datos de Panel con Efectos Fijos

Después de estimar cuidadosamente el modelo de regresión y abordar posibles problemas de heterocedasticidad y correlación serial mediante errores estándar robustos agrupados a nivel de empresa (Abadie et al., 2023), nuestra atención se centró en interpretar los modelos presentados en la Tabla 8. Es notable que la interacción entre la temperatura y las categorías de temperatura extrema muestra un efecto sustancial y significativo en ambas instancias de temperaturas extremadamente altas y bajas. Este hallazgo crucial subraya la asociación entre condiciones extremas de temperatura y niveles elevados de incivilidad predicha por los clientes, reforzando la importancia de la temperatura en la configuración de las interacciones en línea.

La multicolinealidad se refiere a una situación en el análisis de regresión donde las variables independientes están altamente correlacionadas, lo que dificulta aislar el efecto individual de cada variable sobre la variable dependiente. Esto puede conducir a estimaciones poco confiables e inestables de los coeficientes de regresión, distorsionando potencialmente los resultados del análisis. Dado que nuestro modelo implica el uso de un término de interacción entre nuestra variable de temperatura (numérica) y la variable dummy de temperatura_extrema (categórica), nos preocupaba que este término de interacción pudiera ser altamente multicolineal con otras

variables en el modelo. La multicolinealidad podría ser un problema porque sesgaría los errores estándar de nuestras estimaciones, haciendo que los coeficientes parezcan más grandes (y posiblemente significativos) de lo que realmente son. Para abordar esta preocupación, realizamos un examen exhaustivo de la multicolinealidad en nuestros modelos de regresión.

Analizamos los factores de inflación de la varianza (VIF) para las variables independientes, centrándonos especialmente en los términos de interacción entre las variables de temperatura y las variables dummy de temperatura extrema. Nuestro análisis mostró que los valores de VIF estaban por debajo del umbral comúnmente aceptado, lo que indica que la multicolinealidad no estaba en un nivel que sesgaría nuestros resultados. La buena noticia es que nuestros valores de error estándar son bajos y los intervalos de confianza son estrechos, lo que significa que podemos estar seguros de que la multicolinealidad no está afectando nuestros resultados. Nuestro análisis es sólido y confiable. Además, los errores estándar robustos fueron lo suficientemente bajos y los intervalos de confianza fueron estrechos, reforzando la fiabilidad de nuestras estimaciones.

Al confirmar la ausencia de multicolinealidad problemática, aseguramos que los efectos estimados de la temperatura y sus interacciones con las condiciones extremas de temperatura en la incivilidad del cliente sean válidos y robustos.

En la Tabla 9, presentamos los Modelos de Regresión de Datos de Panel con Efectos Fijos, mostrando la relación entre las temperaturas extremas y la incivilidad del cliente en línea. Estos modelos integran efectos de país y mes como covariables fijas, capturando la heterogeneidad observada entre países y meses. Con la inclusión de estas influencias matizadas, nuestro modelo de regresión emerge como integral y refleja la intrincada interacción de factores que configuran los niveles de incivilidad del cliente en el dominio en línea.

Específicamente, el término de interacción para temperaturas extremadamente altas mostró un impacto positivo sustancial en la incivilidad ($\beta = 0.35$, $t(112411) = 30.3$, $p < 0.01$, IC del 95% [0.33, 0.37]), indicando un aumento en la incivilidad bajo condiciones extremadamente calurosas. De manera similar, las temperaturas extremadamente frías tuvieron un efecto positivo más pequeño pero significativo en la incivilidad ($\beta = 0.02$, $t(112411) = 7.82$, $p < 0.01$, IC del 95% [0.01, 0.02]).

El modelo de regresión de datos de panel con efectos fijos se puede representar con la siguiente ecuación::

Ecuación 5: Modelos de Regresión Panel

$$y_{it} = \alpha + \beta_1 Temperature_{it} + \beta_2(Temperature_{it} \times ExtremeHotDummy_{it}) + \beta_3(Temperature_{it} \times ExtremeColdDummy_{it}) + \beta_4 ExtremeHotDummy_{it} + \beta_5 ExtremeColdDummy_{it} + \delta_i + \gamma_t + \epsilon_{it}$$

Donde:

- y_{it} : Puntuación de incivilidad del cliente (Puntuación Predicha LLM) para el tweet i en el tiempo t .
- $Temperature_{it}$: Temperatura promedio en la ubicación del tweek i en el tiempo t .
- $ExtremeHotDummy_{it}$: Variable dummy que indica condiciones extremadamente calurosas para el tweet i en el tiempo t .
- $ExtremeColdDummy_{it}$: Variable dummy que indica condiciones extremadamente frías para el tweet i en el tiempo t .

- δ_i : Efectos fijos para el país.
- γ_t : Efectos fijos para el mes (Incluido en el Modelo 2).
- ϵ_{it} : Término de error.

Tabla 9: Modelos de Regresión de Datos de Panel con Efectos Fijos sobre las Temperaturas Extremas y la Incivilidad del Cliente en Línea

<i>Dependent variable:</i>		
Customer Incivility LLM Predicted Score		
	(1)	(2)
temperature	0.001 (0.003)	0.002 (0.003)
temperature*ExtremeHotDummy	0.355*** (0.033)	0.355*** (0.033)
temperature*ExtremeColdDummy	0.025*** (0.004)	0.024*** (0.005)
ExtremeHotDummy	-2.582*** (0.254)	-2.595*** (0.254)
ExtremeColdDummy	0.270*** (0.057)	0.256*** (0.059)
Country Fixed Effects	Y	Y
Month Fixed Effects	N	Y
Observations	112,487	112,487
R ²	0.014	0.015
Adjusted R ²	0.013	0.014
F Statistic	318.493*** (df = 5; 112422)	104.523*** (df = 16; 112411)

Note:

* p<0.1; ** p<0.05; *** p<0.01

Los coeficientes de los factores de interacción entre las variables ficticias de temperatura extrema y la temperatura proporcionan información sobre cómo las temperaturas extremas afectan el grado de rudeza mostrado por los clientes. Los coeficientes positivos indican que las temperaturas severas empeoran la rudeza del consumidor.

En el análisis de regresión, el término de interacción para las temperaturas extremadamente calurosas mostró un impacto positivo sustancial en la incivilidad, con un coeficiente (β) de 0.35. Esto significa que bajo condiciones extremadamente calurosas, hay un aumento significativo en la incivilidad. Específicamente, para un aumento unitario en el término de interacción que involucra temperaturas extremadamente calurosas, la incivilidad aumenta en 0.35 unidades. Para interpretarlo en términos económicos, debemos considerar que la incivilidad tiene costos asociados, como mencionamos en nuestra revisión de literatura (por ejemplo, aumento del absentismo de los empleados, gastos médicos, pérdida de productividad). En este caso, un aumento de 0.35 por unidad de temperatura extrema calurosa indica un impacto económico significativo. Por ejemplo, si los costos asociados con la incivilidad son, digamos, \$1,000, entonces las temperaturas extremadamente calurosas podrían explicar una parte de este costo equivalente a \$350, debido al coeficiente 0.35. Esto indica una proporción significativa de los costos. También significa que, al evitar efectivamente que la incivilidad de los clientes afecte a los empleados, nuestro análisis podría ofrecer ahorros de \$350 en costos relacionados.

Además, al considerar la heterogeneidad observada entre diferentes países y meses (Figuras 15 y 16), la adición de los Efectos Fijos del Mes y del País (Tabla 9) fortalece la validez y robustez de nuestros modelos de regresión. La significancia estadística general del modelo y la bondad de ajuste se caracterizan aún más por las observaciones, los valores de R-cuadrado y las estadísticas F. Los niveles de significancia indicados por asteriscos (* $p < 0.1$, ** $p < 0.05$, *** $p < 0.01$) resaltan la importancia estadística de los coeficientes, proporcionando perspectivas sobre la fuerza y la dirección de las relaciones examinadas en el análisis de regresión.

Hemos concluido que nuestro estudio sobre la conexión entre las fluctuaciones de temperatura y la rudeza de los clientes durante los intercambios de servicio en línea ha generado información nueva importante. Hemos demostrado correlaciones fuertes entre los elementos ambientales y el comportamiento del consumidor mediante un enfoque metódico que incluye la categorización de datos de temperatura, análisis profundo del aprendizaje en las interacciones en redes sociales y pruebas rigurosas de hipótesis mediante modelos de regresión. Para asegurar la robustez de nuestros hallazgos, realizamos un examen exhaustivo de la multicolinealidad, confirmando que no sesga nuestras estimaciones y que nuestros resultados son confiables.

Nuestros resultados indican que mientras que el frío extremo tiene el impacto opuesto, mayores temperaturas, especialmente el calor intenso, se correlacionan favorablemente con un aumento en la rudeza del consumidor. Además, los factores sutiles que influyen en las interacciones del consumidor se destacan mediante nuestros análisis que tienen en cuenta los efectos corporativos y mensuales. Estos hallazgos ofrecen implicaciones útiles para mejorar la prestación de servicios y manejar los contactos con clientes en una variedad de contextos ambientales, además de profundizar en nuestra comprensión de la dinámica del comportamiento del cliente en línea.

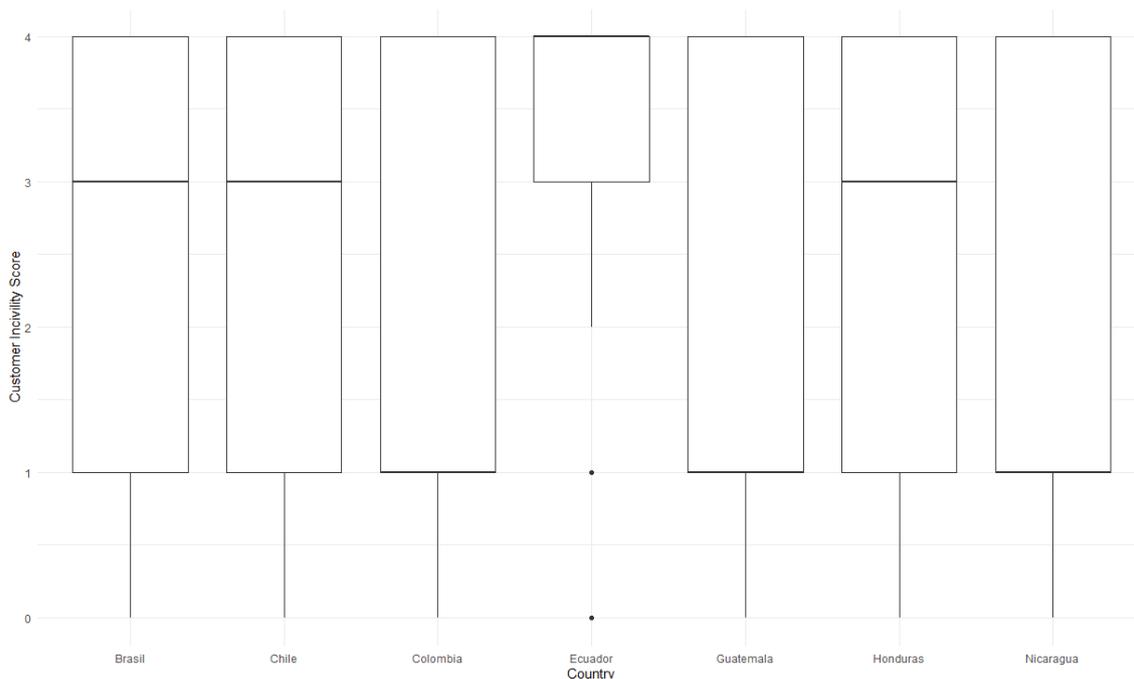
6.6 Análisis Transnacional de la Incivilidad del Cliente: Claro

Esta sección explora las variaciones en los puntajes de incivilidad del cliente para el grupo Claro en diferentes países después de analizar la influencia de la temperatura en la incivilidad. Con operaciones en varios países, incluyendo Brasil, Chile, Colombia, Ecuador, Guatemala, Honduras y Nicaragua, Claro ofrece una oportunidad única para investigar si y cómo la rudeza hacia los clientes difiere según el contexto cultural y geográfico. Esta investigación puede proporcionar información perspicaz que se puede utilizar para crear estrategias personalizadas para gestionar eficientemente las interacciones con los clientes.

Debido a que Claro está presente en varios países en nuestro conjunto de datos, podemos examinar las variaciones regionales en los puntajes de incivilidad del cliente. Este enfoque ayuda a determinar si las variaciones geográficas y culturales tienen una influencia significativa en el comportamiento del consumidor. Es importante recordar que este estudio es simplificado y que las diferencias en la rudeza del cliente entre naciones también pueden estar influenciadas por otros factores como el nivel socioeconómico y la calidad de los servicios proporcionados.

Para visualizar la distribución de los puntajes de incivilidad del cliente en los países donde opera Claro, primero trazamos diagramas de caja para cada país.

Figura 17: Distribución de la Incivilidad del Cliente para el Grupo Claro



Estos diagramas de caja ilustran la dispersión y tendencia central de los puntajes de incivilidad del cliente en cada país, destacando la variabilidad entre diferentes regiones.

Para probar estadísticamente las diferencias significativas en los puntajes de incivilidad del cliente entre los países, realizamos un ANOVA de una vía. El modelo ANOVA utilizado es el siguiente:

Ecuación 6: ANOVA de Incivilidad del Cliente Grupo Claro

$$\text{predicted_labels} = \beta_0 + \beta_1 \text{Country} + \varepsilon$$

Where:

- **predicted_labels** representa el puntaje de incivilidad del cliente.
- **Country** es una variable categórica que indica el país.
- ε es el término de error.

Los resultados del ANOVA (Tabla 10) indican diferencias significativas en los puntajes de incivilidad del cliente entre los siete países ($F(6, 12925) = 99.57, p < 2e-16$). El resumen detallado se presenta a continuación:

Tabla 10: ANOVA de Incivilidad del Cliente Grupo Claro

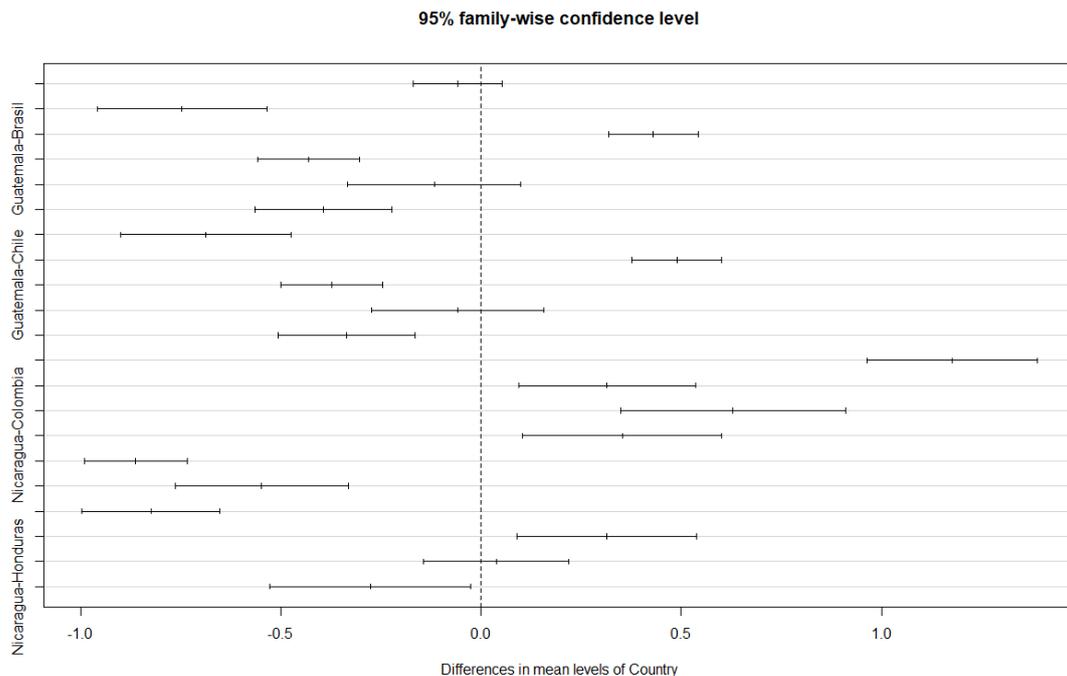
	Df	Sum Sq	Mean Sq	F Value	p-Value
Country	6	1318	219.72	99.57	<2e-16 ***
Residuals	12925	28521	2.21		

Signif. codes: 0 ‘’ 0.001 ‘‘ 0.01 ‘‘ 0.05 ‘.’ 0.1 ‘

Dado los resultados significativos del ANOVA, realizamos una prueba Tukey HSD para realizar comparaciones por pares entre países e identificar pares específicos con diferencias significativas en los puntajes de incivilidad del cliente.

La prueba Tukey HSD es un análisis post-hoc que ajusta para comparaciones múltiples, proporcionando una prueba más rigurosa para detectar diferencias entre medias.

Figura 18: Prueba Tukey HSD Grupo Claro



El test Tukey HSD revela diferencias significativas en los puntajes de incivildad del cliente entre varios países (Consulte la tabla H1 en el Apéndice H para obtener resultados más detallados). Por ejemplo, Colombia y Ecuador muestran diferencias marcadas en comparación con Brasil. Estos hallazgos sugieren que los factores culturales y regionales influyen significativamente en el comportamiento de los clientes.

Los resultados del ANOVA indican diferencias significativas en los puntajes de incivildad del cliente entre los países donde opera Claro. Específicamente:

- Colombia muestra puntajes de incivildad significativamente más altos en comparación con Brasil, Chile y otros países.
- Ecuador tiene puntajes de incivildad del cliente significativamente más bajos que varios otros países.
- Guatemala y Nicaragua también exhiben diferencias notables en comparación con Brasil y Chile.

Basándonos en estos hallazgos, proponemos las siguientes recomendaciones para el grupo Claro:

- **Capacitación Personalizada en Servicio al Cliente:** Para reducir la rudeza de los clientes, implementar programas nacionales de capacitación en servicio al cliente que tengan en cuenta las variaciones culturales. Por ejemplo, los programas de capacitación en Colombia podrían enfatizar más en tácticas de desescalada que en otros temas.
- **Estrategias de Compromiso con el Cliente Localizadas:** Crear planes de marketing y compromiso que se adapten a los requisitos y preferencias únicas de los consumidores de cada país. Las campañas en Ecuador, por ejemplo, pueden aprovechar los puntajes más bajos de incivildad para mejorar la reputación de la marca.
- **Monitoreo y Retroalimentación Regular:** Establecer un método para rastrear casos de rudeza de los clientes de manera regular y proporcionar retroalimentación para ajustar las estrategias según sea necesario. Esto puede apoyar la satisfacción del cliente y responder rápidamente a nuevos problemas.

Estas recomendaciones tienen como objetivo mejorar la satisfacción del cliente y reducir la incivildad, mejorando en última instancia la experiencia general del cliente en diferentes mercados.

Además de ofrecer sugerencias útiles para el grupo Claro, este análisis transnacional ofrece una mayor comprensión de las tendencias de incivildad del consumidor. En futuros estudios, más empresas y áreas geográficas podrían incluirse en este análisis para mejorar el conocimiento y los enfoques para manejar clientes groseros.

Claro puede desarrollar medidas más efectivas y personalizadas para mejorar la satisfacción del cliente y disminuir las experiencias negativas en todas sus diversas regiones, reconociendo y abordando las variaciones culturales y geográficas en la incivildad del cliente.

7. Conclusiones

Nuestra investigación explora las dinámicas complejas de la rudeza por parte de los clientes durante los encuentros de servicio, especialmente en comunidades en línea como Twitter. Reconocemos que el comportamiento grosero hacia los empleados de primera línea (EPL) está

umentando, lo que representa grandes obstáculos para las empresas que intentan mantener los estándares de servicio y proteger el bienestar de los trabajadores. Investigamos el impacto de las temperaturas extremas como posibles desencadenantes de la incivildad del consumidor, basándonos en ideas de estudios actuales y literatura existente. Nuestro objetivo fue arrojar luz sobre estos fenómenos complejos y proporcionar respuestas prácticas a las empresas.

Iniciamos un enfoque integral de recopilación de datos para iniciar nuestro análisis, utilizando conversaciones de Twitter en diversas empresas, países y meses. Nuestro conjunto de datos incluyó más de 110,000 tweets dirigidos a 64 empresas en 19 países diferentes, proporcionando una muestra diversa y representativa de las comunicaciones con los consumidores. Estos tweets fueron meticulosamente codificados utilizando un Modelo de Lenguaje Grande (LLM) según su grado de rudeza, utilizando terminología establecida para establecer un esquema de puntuación que va desde 0 (neutral) hasta 4 (extremadamente incivil).

Después de perfeccionar nuestro modelo de clasificación mediante mejoras iterativas y lograr una precisión de clasificación que oscilaba entre el 36% y el 80%, integramos datos de temperatura del conjunto de datos ERA5 con ubicaciones y marcas de tiempo de los tweets. Esta integración nos permitió examinar la relación entre la temperatura y la incivildad del cliente en línea de manera matizada, considerando tanto condiciones extremadamente calurosas como frías.

Según nuestros datos, que analizamos mediante técnicas estadísticas descriptivas e inferenciales, hay variaciones notables en la rudeza del cliente entre los grupos de temperatura, siendo las temperaturas extremadamente altas las que muestran una fuerte correlación positiva con los niveles de incivildad. El frío extremo también tuvo un impacto positivo más pequeño pero significativo en la rudeza, lo que sugiere una relación compleja entre las temperaturas extremas y el comportamiento del consumidor en línea. Estos resultados subrayan el posible impacto de las condiciones ambientales en las interacciones sociales y validan nuestra hipótesis de que las temperaturas extremas están vinculadas a un aumento en la rudeza entre los clientes en línea.

En el futuro, nuestra agenda de investigación se centrará en varios objetivos importantes que ampliarán nuestro entendimiento y guiarán tratamientos útiles. Para aumentar el alcance geográfico y la diversidad de nuestro análisis, pretendemos agregar más países europeos y asiáticos a nuestro conjunto de datos. Además, nuestro objetivo es evaluar la confiabilidad interrater de nuestro modelo LLM con codificadores humanos para garantizar la corrección y la robustez de nuestro procedimiento de clasificación. Además de los métodos convencionales centrados en la enseñanza de los EPL en comunicación e inteligencia emocional, también tenemos la intención de realizar estudios para probar la causalidad e investigar intervenciones que utilicen modificaciones contextuales para "enfriar" los encuentros.

Finalmente, al identificar la temperatura como un posible desencadenante y utilizar enfoques computacionales avanzados para evaluar las tendencias de incivildad en las interacciones en línea, nuestro estudio contribuye al creciente cuerpo de investigación sobre la incivildad del cliente. Esperamos capacitar a las organizaciones para mejorar la calidad del servicio, fomentar interacciones positivas con los clientes y promover el bienestar de los empleados en un mundo cada vez más digital, al proporcionar insights sobre los mecanismos subyacentes que impulsan el comportamiento del cliente y ofrecer soluciones creativas para manejar la incivildad.

Es crucial considerar las implicaciones prácticas de nuestro estudio para las empresas y organizaciones que operan en industrias orientadas al servicio, más allá de nuestros objetivos y

hallazgos de investigación. Nuestra investigación subraya la importancia de tener en cuenta factores ambientales, como las temperaturas extremas, al abordar la rudeza del cliente. Por ejemplo, durante períodos de calor extremo, es posible que los clientes sean más propensos a la frustración e impaciencia, lo que conduce a un aumento en los casos de rudeza hacia los empleados de primera línea. Un insight accionable que se deriva de nuestros hallazgos es la necesidad imperativa de que las empresas desarrollen programas de capacitación adaptados destinados a equipar a los empleados de primera línea con las habilidades necesarias para navegar la incivildad, especialmente durante condiciones climáticas extremas. Estos programas podrían incluir escenarios simulados donde los empleados practiquen manejar interacciones difíciles con clientes en diversas condiciones climáticas.

Además, la adopción de sistemas de monitoreo de temperatura y la implementación de regulaciones que permitan a los empleados tomar descansos durante períodos de calor intenso podrían ayudar a mitigar la probabilidad de interacciones desfavorables con los clientes. Por ejemplo, las empresas podrían instalar dispositivos de monitoreo de temperatura en áreas de servicio al cliente e implementar políticas que permitan a los empleados tomar breves descansos para refrescarse durante el clima extremadamente caluroso. Además, las organizaciones pueden explorar la posibilidad de utilizar bots para proteger a los empleados de la incivildad del cliente hasta que la situación se enfríe, permitiéndoles luego interactuar con un representante humano. Por ejemplo, los chatbots automatizados podrían estar programados para detectar signos de frustración creciente por parte del cliente e intervenir ofreciendo soluciones o desactivando la situación antes de transferir la conversación a un agente humano. Al adoptar medidas proactivas como estas para abordar el impacto de la temperatura en el comportamiento del consumidor, las empresas pueden mejorar la calidad del servicio, fomentar interacciones positivas con los clientes y proteger el bienestar de los empleados.

Si bien nuestro estudio arroja luz sobre las dinámicas complejas de la incivildad del cliente en las interacciones de servicio en línea, especialmente en el contexto de plataformas como Twitter, es importante reconocer las limitaciones y oportunidades para investigaciones futuras..

7.1. Limitaciones de los Datos

La principal limitación de datos para nuestra investigación es la disponibilidad de fuentes de datos. Dado que principalmente utilizamos datos de un sitio web disponible públicamente, nuestra investigación se limitó a las interacciones en Twitter. El acceso a canales adicionales, como correos electrónicos y mensajes directos de Instagram, Twitter u otras plataformas de redes sociales, podría proporcionar una imagen más completa de las interacciones en línea con los clientes. Además, nuestra investigación se limitó al acceso gratuito, lo que resultó en compromisos significativos de tiempo para la recopilación y extracción de datos, mientras que Twitter ofrece una gran cantidad de datos con membresías pagas. Los investigadores podrían adquirir datos más rápidamente y incorporar más datos en proyectos futuros si tienen acceso a fuentes de datos premium.

Otra limitación se refiere al alcance geográfico de nuestra investigación. Al centrarnos principalmente en España y las Américas, nos vimos influenciados por sus idiomas y costumbres compartidas. Sin embargo, ampliar nuestro estudio para abarcar un conjunto más amplio de países podría mejorar la aplicabilidad de nuestros hallazgos. La incorporación de datos de regiones con variaciones de temperatura más pronunciadas podría proporcionar ideas valiosas sobre cómo la temperatura afecta el comportamiento en línea de los clientes. Además, al

ampliar el alcance geográfico, podríamos captar una gama más diversa de contextos ambientales y culturales, enriqueciendo así futuros esfuerzos de investigación. Con la llegada de los Modelos de Lenguaje Grande (LLMs, por sus siglas en inglés), los investigadores ahora tienen la capacidad de procesar datos de prácticamente cualquier país, facilitando la exploración de regiones geográficas más diversas en estudios posteriores.

7.2. Direcciones Futuras de Investigación

La investigación futura podría seguir varios caminos diferentes para desarrollar los hallazgos de este estudio y contribuir al corpus de conocimiento y aplicaciones del mundo real. Principalmente, es necesario realizar investigaciones adicionales para determinar los orígenes del comportamiento impoluto de los clientes, explorando factores fuera de la temperatura que puedan impactar las comunicaciones virtuales entre usuarios. Nuestro trabajo proporciona un ejemplo metodológico de cómo se pueden detectar las tendencias de rudeza en una variedad de escenarios de comunicación utilizando análisis de texto y Modelos de Lenguaje Grande (LLMs). Un uso prometedor de esta tecnología es emplear algoritmos de aprendizaje automático para desplegar chatbots o agentes de IA para manejar clientes poco amistosos en encuentros en tiempo real. Al identificar los comportamientos precisos que califican como incivilidad, las empresas pueden tomar medidas proactivas para controlar las interacciones con los clientes y proteger al personal de primera línea del lenguaje despectivo.

En adelante, es imperativo ampliar nuestra investigación para incluir otros elementos contextuales que influyen en la incivilidad del cliente además de la temperatura. Para proporcionar un conocimiento más completo de las dinámicas de incivilidad, la investigación futura debería investigar factores como la hora del día, las características demográficas de los clientes y los detalles del contacto con el servicio. La investigación con un diseño longitudinal puede ofrecer ideas importantes sobre cómo cambian los patrones de incivilidad del consumidor con el tiempo y cómo las iniciativas organizativas afectan estos patrones. Además, los estudios que se concentren en la creación y evaluación de planes de intervención adaptados a elementos contextuales distintos de la temperatura pueden ampliar nuestra comprensión y ayudar en la creación de planes eficientes de gestión de la incivilidad del cliente. Las iniciativas de investigación futuras podrían ofrecer ideas útiles para ayudar a las empresas a desarrollar grandes interacciones con los clientes y un entorno de trabajo favorable para el personal de primera línea mediante la adopción de un enfoque holístico para comprender el comportamiento del consumidor.

Finalmente, la investigación futura debería explorar intervenciones diseñadas para mitigar la incivilidad del cliente aprovechando cambios contextuales para "enfriar" los encuentros. Estas intervenciones pueden complementar técnicas más tradicionales centradas en la capacitación de los empleados de primera línea en comunicación e inteligencia emocional. Las intervenciones abarcan tanto estrategias conscientes, como la capacitación formal para empleados de servicio de primera línea (FSE), como enfoques inconscientes, como ofrecer una bebida fría a los clientes para templar interacciones caldeadas.

Una intervención puede ser probada a través de experimentos controlados o estudios de campo, donde se implementen diferentes estrategias y se evalúen sus efectos en el comportamiento del cliente y el bienestar del empleado. Por ejemplo, basándose en la literatura sobre el comportamiento del consumidor en la cognición integrada, ofrecer una bebida caliente a las personas ha demostrado evocar asociaciones metafóricas con la calidez y aumentar el

comportamiento prosocial. De manera similar, ofrecer una bebida fría puede inducir asociaciones psicológicas con la frescura, influenciando potencialmente el comportamiento del cliente durante las interacciones de servicio.

Nuestra investigación futura tiene como objetivo explorar la eficacia de tales intervenciones basadas en nuestros hallazgos. Al implementar técnicas tanto conscientes como inconscientes, buscamos determinar su impacto en la satisfacción del cliente y el bienestar del empleado en roles orientados al cliente. A través de pruebas y análisis rigurosos, podemos identificar estrategias efectivas para fomentar encuentros de servicio positivos y mejorar el rendimiento organizativo en general..

Referencias

1. Béal, M., Grégoire, Y., & Carrillat, F. A. (2023). Let's Laugh About It! Using Humor to Address Complainers' Online Incivility. *Journal of Interactive Marketing*, 58(1), 34–51. <https://doi.org/10.1177/10949968221129268>
2. Baylis, P. (2020). Temperature and temperament: evidence from Twitter. *Journal of Public Economics*, 184, 104161.
3. Bolton, R. N., & Drew, J. H. (1991). A multistage model of customers' assessments of service quality and value. *Journal of Consumer Research*, 17, 375–384. <https://doi.org/10.1086/208564>
4. Bani-Melhem, S., et al. (2022). Customer Incivility and Customer Problem-Solving Behaviour in Frontline Employees: Testing a Moderated Mediation Model. *Total Quality Management & Business Excellence*, 33(3-4), 278–296.
5. Di Buccio, S. (2023). Mejora En La Atención Al Cliente Usando Datos de Twitter y Técnicas de Aprendizaje Automático. Universidad Torcuato Di Tella.
6. Iglesias, V. (2009). The Attribution of Service Failures: Effects on Consumer Satisfaction. *The Service Industries Journal*, 29(2), 127–141.
7. Kashif, M., & Zarkada, A. (2015). Value Co-Destruction Between Customers and Frontline Employees: A Social System Perspective. *International Journal of Bank Marketing*, 33(6), 672–691.
8. Kim, T. T., et al. (2012). Frontline Service Employees' Customer-Related Social Stressors, Emotional Exhaustion, and Service Recovery Performance: Customer Orientation as a Moderator. *Service Business*, 6(4), 503–526.
9. Lin, W.-C., Lu, T.-E., & Peng, M.-Y. (2021). Service Failure Recovery on Customer Recovery Satisfaction for Airline Industry: The Moderator of Brand Authenticity and Perceived Authenticity. *Managerial and Decision Economics*, 42(5), 1079–1088.
10. Lorenz, M. P., Johnson, C. M., & Barakat, L. L. (2017). An Exploration of Frequent Service Failures in the Brazilian Airline Industry. *Latin American Business Review*, 18(1), 19–45.
11. Masorgo, N., Mir, S., & Rossiter Hofer, A. (2022). Expectations Vs Experience: Managing the Adverse Effects of Service Failures on Customer Satisfaction in the Airline Industry. *Transportation Journal*, 61(3), 231–262.
12. Misopoulos, F., et al. (2014). Uncovering Customer Service Experiences with Twitter: The Case of Airline Industry. *Management Decision*, 52(4), 705–723.
13. Rathje, S., et al. (2023). GPT is an effective tool for multilingual psychological text analysis [Preprint]. *PsyArXiv*. <https://doi.org/10.31234/osf.io/sekf5>
14. Sashi, C. M., Brynildsen, G., & Bilgihan, A. (2019). Social Media, Customer Engagement and Advocacy: An Empirical Investigation Using Twitter Data for Quick Service Restaurants. *International Journal of Contemporary Hospitality Management*, 31(3), 1247–1272.
15. Stechemesser, A., Levermann, A., & Wenz, L. (2022). Temperature impacts on hate speech online: Evidence from 4 billion geolocated tweets from the USA. *The Lancet Planetary Health*, 6(9), e714–e725. [https://doi.org/10.1016/S2542-5196\(22\)00173-5](https://doi.org/10.1016/S2542-5196(22)00173-5)

16. Tereszkieicz, A. (2021). Rejecting Consumer Complaints in Customer Encounters on Twitter - the Case of English and Polish Brand Communication. *Journal of Politeness Research: Language, Behaviour, Culture*, 17(2), 189–231.
17. Zhu, J. N. Y., Lam, L. W., & Lai, J. Y. M. (2019). Returning Good for Evil: A Study of Customer Incivility and Extra-Role Customer Service. *International Journal of Hospitality Management*, 81, 65–72.
18. de Oliveira Santini, F., et al. (2021). Customer Engagement in Social Media: A Framework and Meta-Analysis. *Journal of the Academy of Marketing Science*, 48(6).
19. Hansen, J., Sato, M., & Ruedy, R. (2012). Perception of climate change. *Proceedings of the National Academy of Sciences*, 109(37), E2415–E2423. <https://doi.org/10.1073/pnas.1205276109>
20. Zhu, R., & Zhang, J. (2010). Impact of online consumer reviews on sales: The moderating role of product and consumer characteristics. *Journal of Marketing*, 74(2), 133–148. <https://doi.org/10.1509/jmkg.74.2.133>
21. Grewal, L. (2019). Impact of customer incivility on employee performance: The mediating role of emotional exhaustion. *Journal of Organizational Behavior*, 40(5), 533–546. <https://doi.org/10.1002/job.2399>
22. Groth, M. (2005). Customers as good soldiers: Examining citizenship behaviors in internet service deliveries. *Journal of Management*, 31(1), 7–27. <https://doi.org/10.1177/0149206304271393>
23. Wang, Y. D., et al. (2020). Modeling online customer behavior in social media: A review and research agenda. *Information & Management*, 57(2), 103165. <https://doi.org/10.1016/j.im.2019.103165>
24. Yang, Z., Cai, S., & Zhou, Z. (2021). Investigating the effect of service failure severity on customer engagement behaviors: The roles of psychological ownership and customer incivility. *Journal of Retailing and Consumer Services*, 59, 102379. <https://doi.org/10.1016/j.jretconser.2020.102379>
25. Jang, S. S., & Namkung, Y. (2009). Perceived quality, emotions, and behavioral intentions: Application of an extended Mehrabian–Russell model to restaurants. *Journal of Business Research*, 62(4), 451–460. <https://doi.org/10.1016/j.jbusres.2008.01.049>

Appendix A. Variables del Conjunto de Datos

Tabla A1: Variables del Conjunto de Datos

Nro	Variable	Descripcion de la Variable
1	Company	Nombre de la empresa.
2	Country	Pais donde se encuentra la empresa.
3	Industry	Industria a la que pertenece la empresa.
4	Name	Nombre asociado con la cuenta de Twitter.
5	Profile	Enlace URL al perfil de Twitter.
6	Account	Nombre del usuario de la cuenta de Twitter.
7	Time	Fecha y hora del tui ten formato POSIXct.
8	Comments	Numero de comentarios en el tweet.
9	Visualizations	Numero de visualizations del tweet.
10	Content	Contexto textual del tweet.
11	Retweets	Numero de Retweets del Tweet.
12	Likes	Numero de likes del Tweet.
13	TotalEngagement	Compromiso total, suma de comentarios, retuits y “me gusta”.
14	MostFrequentName	Nombre mas frecuente asociado con la cuenta de twitter.
15	CompanyTweet	Indicador Binario (1 o 0) si el tweet es de la empresa o no.
16	Timezone	Zona horaria del Tweet.
17	TimeDifference	Diferencia horaria con respect a UTC.
18	Year	Añodel tweet.
19	Month	Mes del tweet.
20	Day	Día del mes del tweet.
21	LocalTime	Hora local del tweet.
22	DayOfWeek	Día de la semana (numérico) del tweet.
23	Posts	Número de publicaciones en Twitter por la cuenta.
24	Followers	Número de seguidores de la cuenta.
25	CreationofAccount	Mes y año en que se creó la cuenta de Twitter.
26	YearOfCreation	Año en que se creó la cuenta de Twitter.
27	temperature	Promedio de grados Celsius para la región donde se encuentra la observación, para su tiempo, día, mes y año específicos. Fuente: base de datos ERA5.
28	predicted_labels	Puntuación de Incivildad del Cliente del modelo LLM, con valores entre 1 y 5.

Appendix B. Entrenamiento de ChatGPT

Basado en la definición integral proporcionada, se puede desarrollar una escala de incivildad del cliente adaptada para interacciones en redes sociales que categorice las publicaciones en cinco niveles distintos, desde neutral hasta extremadamente incivil. Esta escala ayudará a los codificadores a evaluar sistemáticamente las publicaciones de los clientes según su intensidad de incivildad y su posible impacto en los empleados.

Nivel 1: Neutral

Características: Publicaciones que son informativas, corteses o expresan preocupaciones sin emociones negativas ni falta de respeto.

Checklist:

- La publicación contiene consultas o comentarios sin lenguaje negativo.
- El tono es respetuoso, sin signos de frustración o enojo.
- Se adhiere a las normas de respeto y cortesía mutuos.

Ejemplos:

- "¿Alguien puede ayudarme con mi problema de cuenta, por favor?"
- "Gracias por su pronta respuesta. Espero la resolución."
- "Estoy teniendo problemas con mi servicio; agradecería cualquier ayuda."

Nivel 2: Ligeramente Incivil

Características: Ligeras expresiones de insatisfacción o impaciencia, desviación mínima de la comunicación respetuosa.

Checklist:

- Expresiones leves de frustración o decepción.
- Uso sutil de sarcasmo o lenguaje pasivo-agresivo.
- La crítica sigue siendo constructiva, sin ataques personales.

Ejemplos:

- "Un poco decepcionado con la demora, esperaba algo mejor."
- "Parece que mi solicitud se perdió nuevamente. Sorpresa, sorpresa."
- "Espero que esta vez realmente resuelvan mi problema."

Nivel 3: Moderadamente Incivil

Características: Las publicaciones muestran rudeza clara, impaciencia notable o insultos leves hacia el servicio o los empleados.

Checklist:

- Quejas directas con un tono rudo o condescendiente.
- Uso de lenguaje negativo para expresar insatisfacción.
- Comienzo de una desviación significativa del discurso respetuoso.

Ejemplos:

- "¿Es realmente tan difícil obtener un buen servicio aquí?"
- "Otra respuesta inútil. ¿Acaso entrenan a su personal?"
- "Tanto por 'soporte rápido'. Qué broma."

Nivel 4: Altamente Incivil

Características: Críticas agresivas, uso de lenguaje duro o insultos y clara falta de respeto hacia la dignidad del empleado.

Checklist:

- Empleo de lenguaje ofensivo o ataques personales.
- Expresiones de enojo u hostilidad hacia los empleados o la empresa.
- Violación significativa de las normas de respeto y cortesía.

Ejemplos:

- "Absolutamente incompetentes. ¿Qué tan difícil puede ser resolver un problema?"
- "Peor servicio al cliente de todos. Deberían estar avergonzados."
- "Esta empresa es un desastre. Ayuda completamente inútil cada vez."

Nivel 5: Extremadamente Incivil

Características: Publicaciones que incluyen ataques verbales severos, uso extenso de vulgaridades, amenazas o discurso de odio.

Checklist:

- Ataques personales severos, uso de lenguaje vulgar contra individuos.
- Amenazas o lenguaje altamente agresivo que indica hostilidad intensa.
- Uso de letras mayúsculas para transmitir gritos o extrema frustración.

Examples:

- "¡Son todos unos idiotas! ¡Peor experiencia de mi vida!"
- "¡Espero que quiebren por este servicio patético. ¡Se lo merecen!"
- "¡Esto es una completa basura! Nunca más usaré este servicio de porquería. ¡Están advertidos!"

Instrucciones para Codificadores:

- ✓ **Comprensión Contextual:** Siempre considere el contexto de la publicación, incluidas las interacciones precedentes, para evaluar con precisión su nivel de incivilidad.
- ✓ **Atención a los Detalles:** Preste mucha atención al tono, lenguaje e intención detrás de las palabras utilizadas en las publicaciones de los clientes.
- ✓ **Evaluación de Impacto:** Evalúe cómo el lenguaje y el tono utilizados podrían afectar el bienestar emocional y la percepción de los empleados directamente mencionados o dirigidos.
- ✓ **Mantenimiento de la Consistencia:** Use la lista de verificación y los ejemplos como puntos de referencia para una evaluación consistente en diferentes publicaciones. En caso de duda, discútalo con un compañero o supervisor para mayor claridad.
- ✓ **Documentación:** Mantenga notas detalladas sobre frases o elementos específicos que contribuyeron a la calificación de incivilidad para su revisión y calibración.

Esta escala y sus directrices proporcionan un enfoque estructurado para que los codificadores clasifiquen la civilidad de las publicaciones de los clientes hacia los empleados, asegurando evaluaciones precisas, consistentes y objetivas.

Appendix C. Figuras Adicionales

Figura C1: Composición de la Muestra por Empresa

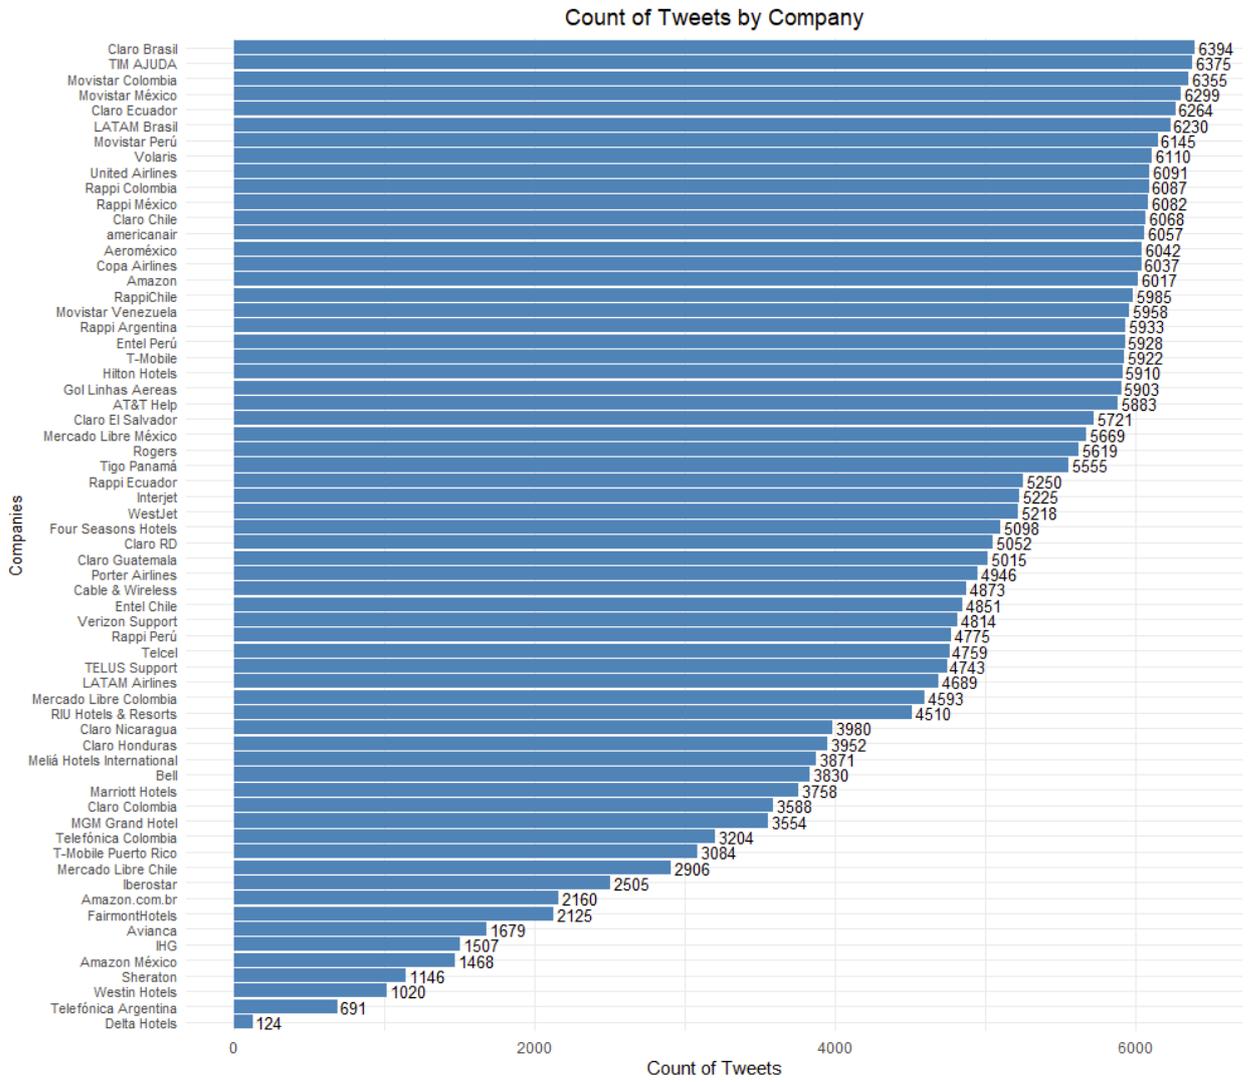
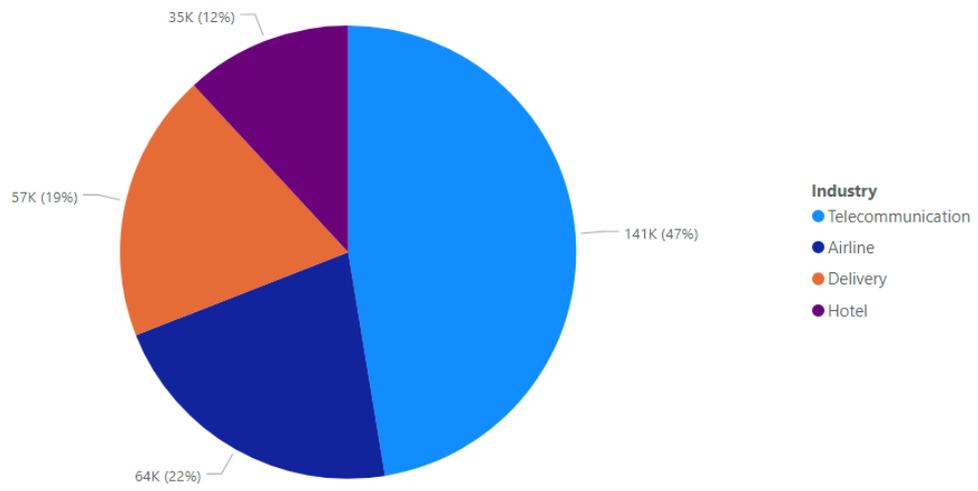


Figura C2: Composición de la Muestra por Industria

Sample Composition by Industry



Appendix D. ERA5 Temperature Extraction

El conjunto de datos ERA5, desarrollado por el Centro Europeo de Previsiones Meteorológicas a Medio Plazo (ECMWF), representa un avance significativo en el reanálisis del clima y el tiempo a nivel mundial. Ofrece estimaciones exhaustivas de los parámetros atmosféricos, oceánicos y de la superficie terrestre a escala horaria, abarcando más de ocho décadas desde 1940 en adelante. En comparación con su predecesor, ERA-Interim, ERA5 proporciona datos más refinados, incluyendo la media y la dispersión del conjunto, lo que facilita mejores estimaciones de incertidumbre y aplicaciones climáticas mejoradas.

Acceso y Recuperación de Datos:

Acceder a los datos de temperatura ERA5 implica utilizar la API web de Python proporcionada por el ECMWF. El proceso típicamente involucra los siguientes pasos:

1. **Acceso a Datos del ECMWF:** Utilizar la API web de Python del ECMWF para acceder a los datos de temperatura ERA5.
2. **Descargar Datos:** Recuperar los datos de temperatura para la región y el período de tiempo deseados. Asegúrese de especificar parámetros como latitud, longitud, rango de tiempo y variables deseadas (por ejemplo, temperatura a 2m).
3. **Procesar Datos:** Extraer y manipular la información de temperatura de los archivos de datos descargados, que generalmente están disponibles en formatos como GRIB o netCDF.
4. **Analizar y Visualizar:** Analizar los datos de temperatura utilizando métodos estadísticos y técnicas de visualización para derivar conocimientos y patrones relevantes para los objetivos de la investigación.

Generación de Credenciales para el Acceso a Datos ERA5

Acceder a los datos de la base de datos ERA5 requiere obtener credenciales únicas, a saber, el User ID (UID) y la API Key, proporcionadas por el Centro Europeo de Previsiones Meteorológicas a Medio Plazo (ECMWF). Estas credenciales otorgan a los usuarios acceso al portal de datos del ECMWF, permitiendo la recuperación de datos ERA5 para propósitos académicos, de investigación y educativos.

Siga estos pasos para generar las credenciales necesarias para acceder a los datos ERA5:

1. **Crear una Cuenta:** Visite el sitio web oficial del ECMWF y regístrese para obtener una cuenta. Proporcione la información requerida y complete el proceso de registro.
2. **Acceder al Perfil del Usuario:** Una vez registrado e iniciado sesión, navegue a la sección de su perfil de usuario o configuración de cuenta.
3. **Generar API Key:** Busque la opción para generar una API Key dentro de la configuración de su perfil de usuario. Siga el proceso guiado para crear una API Key única asociada con su cuenta.

4. **Recuperar User ID (UID):** Su User ID (UID) se proporciona típicamente durante el proceso de registro de la cuenta. Si no es así, generalmente se puede encontrar en la configuración de su cuenta o en la información de su perfil.
5. **Registrar Credenciales:** Asegúrese de registrar tanto su User ID (UID) como su API Key de manera segura. Estas credenciales serán necesarias para autenticar y acceder a los datos ERA5 a través de la API del ECMWF.
6. **Configurar Acceso:** Una vez que tenga sus credenciales, puede configurar sus scripts o herramientas de acceso a datos para utilizarlas en la autenticación al realizar solicitudes a la API del ECMWF.

Solicitud de API y Extracción de Datos:

Después de obtener las credenciales, el proceso para generar la llamada a la API es muy sencillo. Esto se debe a que, en la misma página, podemos elegir qué datos queremos extraer según varias categorías. Entre ellas, podemos seleccionar las variables en sus diferentes categorías:

Variable ?

At least one selection must be made

- ▶ Popular
- ▶ Temperature and pressure
- ▶ Wind
- ▶ Mean rates
- ▶ Radiation and heat
- ▶ Clouds
- ▶ Lakes
- ▶ Evaporation and runoff
- ▶ Precipitation and rain
- ▶ Snow
- ▶ Soil
- ▶ Vertical integrals
- ▶ Vegetation
- ▶ Ocean waves
- ▶ Other

También podemos elegir las variables de tiempo:

Year

At least one selection must be made

<input type="checkbox"/> 1940	<input type="checkbox"/> 1941	<input type="checkbox"/> 1942	<input type="checkbox"/> 1943	<input type="checkbox"/> 1944	<input type="checkbox"/> 1945
<input type="checkbox"/> 1946	<input type="checkbox"/> 1947	<input type="checkbox"/> 1948	<input type="checkbox"/> 1949	<input type="checkbox"/> 1950	<input type="checkbox"/> 1951
<input type="checkbox"/> 1952	<input type="checkbox"/> 1953	<input type="checkbox"/> 1954	<input type="checkbox"/> 1955	<input type="checkbox"/> 1956	<input type="checkbox"/> 1957
<input type="checkbox"/> 1958	<input type="checkbox"/> 1959	<input type="checkbox"/> 1960	<input type="checkbox"/> 1961	<input type="checkbox"/> 1962	<input type="checkbox"/> 1963
<input type="checkbox"/> 1964	<input type="checkbox"/> 1965	<input type="checkbox"/> 1966	<input type="checkbox"/> 1967	<input type="checkbox"/> 1968	<input type="checkbox"/> 1969
<input type="checkbox"/> 1970	<input type="checkbox"/> 1971	<input type="checkbox"/> 1972	<input type="checkbox"/> 1973	<input type="checkbox"/> 1974	<input type="checkbox"/> 1975
<input type="checkbox"/> 1976	<input type="checkbox"/> 1977	<input type="checkbox"/> 1978	<input type="checkbox"/> 1979	<input type="checkbox"/> 1980	<input type="checkbox"/> 1981
<input type="checkbox"/> 1982	<input type="checkbox"/> 1983	<input type="checkbox"/> 1984	<input type="checkbox"/> 1985	<input type="checkbox"/> 1986	<input type="checkbox"/> 1987
<input type="checkbox"/> 1988	<input type="checkbox"/> 1989	<input type="checkbox"/> 1990	<input type="checkbox"/> 1991	<input type="checkbox"/> 1992	<input type="checkbox"/> 1993
<input type="checkbox"/> 1994	<input type="checkbox"/> 1995	<input type="checkbox"/> 1996	<input type="checkbox"/> 1997	<input type="checkbox"/> 1998	<input type="checkbox"/> 1999
<input type="checkbox"/> 2000	<input type="checkbox"/> 2001	<input type="checkbox"/> 2002	<input type="checkbox"/> 2003	<input type="checkbox"/> 2004	<input type="checkbox"/> 2005
<input type="checkbox"/> 2006	<input type="checkbox"/> 2007	<input type="checkbox"/> 2008	<input type="checkbox"/> 2009	<input type="checkbox"/> 2010	<input type="checkbox"/> 2011
<input type="checkbox"/> 2012	<input type="checkbox"/> 2013	<input type="checkbox"/> 2014	<input type="checkbox"/> 2015	<input type="checkbox"/> 2016	<input type="checkbox"/> 2017
<input type="checkbox"/> 2018	<input type="checkbox"/> 2019	<input type="checkbox"/> 2020	<input type="checkbox"/> 2021	<input type="checkbox"/> 2022	<input type="checkbox"/> 2023
<input type="checkbox"/> 2024					

Month

At least one selection must be made

<input type="checkbox"/> January	<input type="checkbox"/> February	<input type="checkbox"/> March	<input type="checkbox"/> April	<input type="checkbox"/> May	<input type="checkbox"/> June
<input type="checkbox"/> July	<input type="checkbox"/> August	<input type="checkbox"/> September	<input type="checkbox"/> October	<input type="checkbox"/> November	<input type="checkbox"/> December

Day

At least one selection must be made

<input type="checkbox"/> 01	<input type="checkbox"/> 02	<input type="checkbox"/> 03	<input type="checkbox"/> 04	<input type="checkbox"/> 05	<input type="checkbox"/> 06
<input type="checkbox"/> 07	<input type="checkbox"/> 08	<input type="checkbox"/> 09	<input type="checkbox"/> 10	<input type="checkbox"/> 11	<input type="checkbox"/> 12
<input type="checkbox"/> 13	<input type="checkbox"/> 14	<input type="checkbox"/> 15	<input type="checkbox"/> 16	<input type="checkbox"/> 17	<input type="checkbox"/> 18
<input type="checkbox"/> 19	<input type="checkbox"/> 20	<input type="checkbox"/> 21	<input type="checkbox"/> 22	<input type="checkbox"/> 23	<input type="checkbox"/> 24
<input type="checkbox"/> 25	<input type="checkbox"/> 26	<input type="checkbox"/> 27	<input type="checkbox"/> 28	<input type="checkbox"/> 29	<input type="checkbox"/> 30
<input type="checkbox"/> 31					

Finalmente, podemos especificar qué región geográfica queremos extraer:

Geographical area ?

Whole available region

With this option selected the entire available area will be provided

Sub-region extraction ?

North

West **East**

South

Una vez elegido el formato de archivo, se genera una solicitud de API para especificar los parámetros de datos y los requisitos de descarga. Para nuestro análisis, pretendemos descargar datos del año 2021, abarcando todos los meses, días y horas. La variable seleccionada de interés es "2t", que representa la temperatura del aire a 2 metros sobre la superficie.

Descripción de la Variable:

- **Nombre de la Variable:** 2t

- **Descripción:** Temperatura del aire a 2 metros sobre la superficie de la tierra, el mar o aguas interiores.
- **Unidades:** Kelvin (K)
- **Conversión:** La temperatura en Kelvin se puede convertir a grados Celsius (°C) restando 273.15.

La solicitud de API resultante para un año específico, mes, día y hora sería la siguiente:

```
uid = ''
apikey = ''

c = cdsapi.Client(key=f"{uid}:{apikey}", url="https://cds.climate.copernicus.eu/api/v2")

c.retrieve(
    'reanalysis-era5-single-levels',
    {
        'product_type': 'reanalysis',
        'format': 'netcdf',
        'variable': '2m_temperature',
        'year': [
            '2022'
        ],
        'month': [
            '01'
        ],
        'day': [
            '01'
        ],
        'time': [
            '00:00'
        ],
        'area': [
            23.1136, -82.3666, 23.1136, -82.3666
        ],
    },
    'download.nc')
```

Procesamiento de Datos:

Después de descargar los archivos NC, en nuestro caso, es necesario poder extraer las variables y transformarlas en una tabla final. Para ello, utilizamos el siguiente código:

```

import xarray as xr
import pandas as pd

# Open the NetCDF dataset
ds = xr.open_dataset('/content/drive/My Drive/')

# Convert temperature from Kelvin to Celsius
ds['t2m_celsius'] = ds['t2m'] - 273.15

# Convert xarray Dataset to DataFrame
df = ds.to_dataframe()

# Reset index to make latitude, longitude, and time columns accessible
df.reset_index(inplace=True)

# Drop any unwanted columns if necessary
df = df.drop(['t2m'], axis=1)

print(df.head(10))

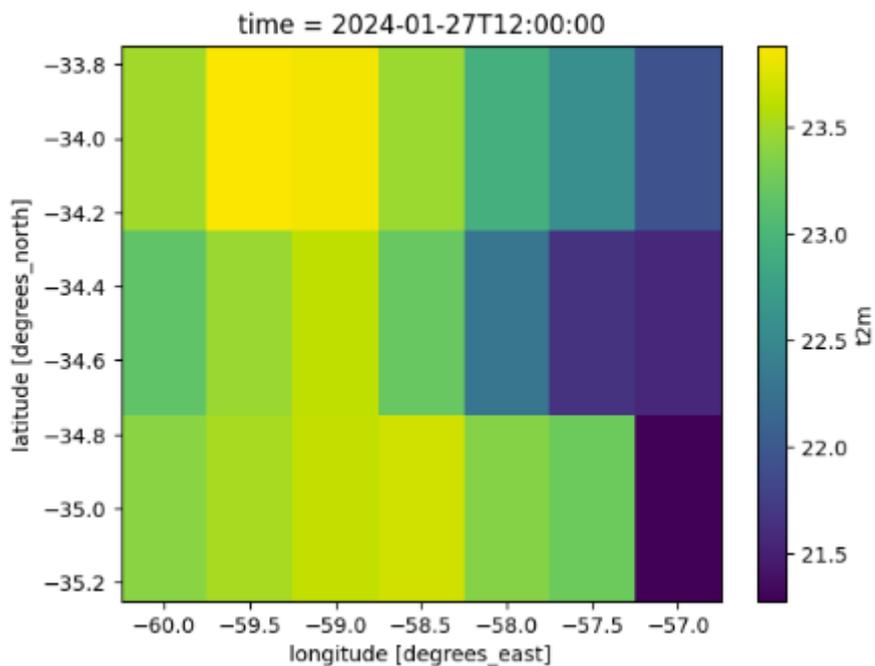
# Count the number of unique dates
unique_dates = df['time'].nunique()

print("Number of different dates in the dataset:", unique_dates)

```

A modo de ilustración, si decidimos graficar el contenido del archivo netCDF (NC), obtendríamos lo siguiente:

Figura D1: Distribución de Temperatura según Octoparse



El archivo netCDF contiene una matriz de coordenadas latitudinales y longitudinales. Para cada combinación de estas medidas, para una fecha y hora específica, se registra un valor para cada variable. En este ejemplo, la variable graficada es "t2m", que representa la temperatura del aire

a 2 metros sobre la superficie. Los valores de temperatura se convierten a grados Celsius para fines de visualización.

Este gráfico proporciona una representación visual de la distribución espacial de la temperatura en la región geográfica especificada en una fecha y hora particular, permitiendo un análisis e interpretación más profundos de los patrones y variaciones de temperatura.

Appendix E. Large Language Model

Parte 1: Tweets Simulados

En la fase inicial de entrenamiento de nuestro Modelo de Lenguaje Grande (LLM), es fundamental proporcionarle datos relevantes para el aprendizaje. Este proceso comienza con la extracción de una muestra de nuestro conjunto de datos de Tweets, que sirve como base para entrenar el modelo. Esta muestra se selecciona meticulosamente para incluir oraciones adecuadas para la clasificación de sentimientos, formando la columna vertebral de los datos de entrenamiento de nuestro modelo.

Construcción de una Muestra para la Clasificación de Sentimientos

El objetivo principal de esta fase es construir un conjunto de datos que permita el desarrollo de un clasificador de sentimientos capaz de discernir los diferentes grados de sentimientos expresados en los tweets de los clientes. Cada oración en el conjunto de datos está etiquetada en una escala de neutral (0) a altamente incivil (5), representando el espectro de niveles de sentimiento encontrados en interacciones reales con los clientes.

Asegurando el Equilibrio de la Muestra

Para garantizar la efectividad de nuestro clasificador de sentimientos, es crucial abordar cualquier desequilibrio en la distribución de los niveles de sentimiento dentro del conjunto de datos. Al observar la disparidad en el número de muestras a través de diferentes niveles de sentimiento, reconocemos la necesidad de crear un conjunto de datos equilibrado. Esto implica muestrear aleatoriamente un número igual de oraciones de las clases de sentimiento mayoritarias para igualar la cantidad de muestras en la clase de sentimiento minoritaria. Este enfoque equilibrado asegura que nuestro clasificador aprenda a distinguir con precisión entre sentimientos negativos, positivos y neutrales.

Ejemplos de Oraciones por Nivel de Sentimiento

Para ilustrar la diversidad de expresiones de sentimientos dentro de cada nivel, presentamos oraciones de ejemplo representativas de las cinco categorías de sentimientos:

Nivel 1: Sentimiento Positivo

Oraciones de ejemplo que expresan satisfacción y experiencias positivas con los respectivos proveedores de servicios.

- "Great experience at @TorontoPearson airport and loved their express security line experience! Additionally, @WestJet yet again turns out to be great!"
- "Big thank you to @WestJet for their ongoing support of our Ukraine response. They have continued to help fly our Rapid Response Team members to and from our ongoing food security programs based in Moldova and Romania."
- "Can't wait to see my Halifax peeps! Heading home from Calgary on a 5-hour @WestJet flight. Excellent service so far and I was happy for the 19-hour layover to celebrate my nieces 17th birthday!"
- "Imagine being evacuated because of wildfires, only to have @CanadianNorth charge you nearly \$500 to get your pets back home safely. I don't have a lot of great things to

say about @WestJet most days, but they flew my babies out with me free of charge- no questions asked."

- No hay nada como acabar el día con un cóctel en el Sunset Sky Bar de Iberostar Bahía de Palma. #Iberostar

Nivel 2: Sentimiento Neutral

Oraciones neutras o consultas que abordan problemas o preocupaciones relacionadas con el servicio prestado.

- "Hey @WestJet what is the point of giving out companion vouchers if you can't book any flights stateside with them?"
- "It wasn't sold out. And as you can see I'm not the only one who had this issue."
- "There is nothing on that page regarding your in-flight entertainment app not working. But thanks for the reply."
- "Hey @WestJet, hoping for a smoother travel experience! Flight from CDG - YYQ - YVR with an 8-hour layover at YYQ. Asked for an earlier flight, but quoted \$3k! "#CustomerExperience #TravelWoes #FlightOptions #WestJetHelp"
- "No puedo hacer mi check-in del vuelo de salida."

Nivel 3: Sentimiento Ligeramente Negativo

Oraciones que expresan insatisfacción o decepción con el servicio, acompañadas de quejas o agravios específicos.

- "@FlairAirlines please stay away from the low budget airlines, they spilt hot kettle on us and missing luggage and stolen items, they will not contact us @WestJet Worst service ever"
- "@WestJet 1hour20mins to get a refund (bag chgs x 2flights I shouldn't have had to pay "so called glitch") after 1st 25mins call to get the reply to go online and fill out form- reply from online: 7 days later- call CS! Smooth."
- "@Westjet So disappointed in the execution of the #Westjet 35% off sale today. Entering my cc info and all of a sudden got a Gateway error followed by another error page. Tried 3 other browsers and same. Tried calling, by the time I got through it was sold out."
- "Disappointed with @WestJet and a poor website. Encountered multiple Gateway 505 errors, inability to validate my WestJet rewards numbers and then the final insult, kicked out from submitting payment after finally securing a 35% off fare in their Summer Sale. Missed the sale."
- "Hey @WestJet - awfully nice of you to post a 35% off code and not allow me to check out on your site for 3 hours. And of course, your website starts to run smoothly as soon as the 35% off code "is sold out" and replaced with a 15% off code. Classic #baitandswitch tactics"

Nivel 4: Sentimiento Moderadamente Negativo

Críticas o quejas más severas dirigidas a los proveedores de servicios, destacando casos de mal servicio o situaciones mal manejadas.

- "It's the worst, west jet! They've lost baggage, lost my daughter that had a wj rep fly with her, and a couple of other children. I had to call the police in Calgary to get answers."
- "@WestJet @westjetnews in my extensive travels around the world for global health, I've NEVER faced such blatant disregard for passengers! Losing my luggage and then the audacity to reply inadequately? Disgraceful! Shame! @CTA_gc , are you endorsing this kind of shoddy service?"
- "Hi I reset the password twice. As soon as I searched a flight with the discount code I'd get logged out and would not be able to login. My partner had the same issue. Also you couldn't use the app with the discount code. WestJet obviously does not have the right systems in place."
- "@WestJet 2 of 2 when I didn't have to pay with WestJet b4 & send me two 15.00 meal vouchers that I can't use in LAX & expires that day. What a crappy experience & this is the 2nd time you've done this to me in trips I've booked with you this year. I'll be choosing diff next time."
- "@WestJet really left us for dead. Omg"

Nivel 5: Sentimiento Altamente Negativo

Oraciones que transmiten una intensa frustración o ira hacia los proveedores de servicios, a menudo acompañadas de lenguaje fuerte o acusaciones.

- "I've messaged @WestJet multiple times, through multiple means and still, nothing other than a reply to my calling them out on Twitter, saying to call them directly or through the website. I have, and they continue to F me OFF! #WestJetSucks #NeverAgainWestJet"
- "Equipo premiamos que dice dar solución en 24 horas.... han pasado 3 días ya!!! Ladrones mentirosos. No tengo ningún dm de ustedes....ni así dan buen servicio. No viajen en @LATAMAirlines nunca. Si no quieren ser estafados y maltratados. Por su propia seguridad y salud mental, NO VIAJEN CON ELLOS. "
- "@RappiArgentina y voy a romperles los huevos hasta que me den una solución y me devuelvan la guita"

Con la construcción de nuestro conjunto de datos de entrenamiento equilibrado, que comprende diversas expresiones de sentimientos en múltiples niveles, establecemos la base para las fases subsiguientes de nuestro proceso de entrenamiento del LLM. Este conjunto de datos meticulosamente curado sirve como la piedra angular del entrenamiento de nuestro modelo, permitiéndole aprender y comprender de manera efectiva los matices de los sentimientos expresados en los tweets de los clientes.

Part 2: Fine-tune de un Modelo Transformer Preentrenado

Con el conjunto de datos fundamental construido en la Parte 1, procedemos a ajustar fino un modelo Transformer preentrenado para clasificar efectivamente el sentimiento expresado en los tweets de los clientes. Esta fase implica aprovechar técnicas avanzadas de procesamiento del lenguaje natural (NLP) para mejorar la comprensión del modelo de las expresiones de sentimiento matizadas.

Carga de Bibliotecas Necesarias

Antes de adentrarnos en el proceso de ajuste fino, primero importamos las bibliotecas y módulos necesarios esenciales para esta fase. Estos incluyen bibliotecas para manipulación de datos, carga de modelos, tokenización y entrenamiento.

```
from tqdm import tqdm
import pickle5 as pickle
import numpy as np
import pandas as pd
import torch
import transformers as ppb
import warnings
warnings.filterwarnings('ignore')
```

Selección del Modelo Preentrenado

En este proyecto, optamos por trabajar con el modelo DistilBERT, disponible en la biblioteca Hugging Face Transformers. Si bien DistilBERT ofrece un rendimiento eficiente, otros modelos preentrenados como BERT, XLNet, DeBERTa y BERTweet también son opciones viables.

```
model_name = 'distilbert-base-cased'
tokenizer = AutoTokenizer.from_pretrained(model_name)
```

Preparación de los Datos

Carga de la Muestra Equilibrada: Cargamos la muestra equilibrada preprocesada obtenida en la Parte 1, asegurándonos de que cada nivel de sentimiento esté adecuadamente representado en el conjunto de datos.

```
df = pd.read_pickle("SentimentSampleBalanced.pkl")
```

División de Datos para Entrenamiento y Pruebas: Utilizando la función `train_test_split` de la biblioteca scikit-learn, dividimos el conjunto de datos en subconjuntos de entrenamiento y pruebas para facilitar el entrenamiento y la evaluación del modelo.

```
from sklearn.model_selection import train_test_split
train_sentences, test_sentences, train_labels, test_labels = train_test_split(sentences, labels, test_size=0.2, stratify=labels, random_state=42)
print(f'Training Sample contains {len(train_sentences)} sentences\nTesting Sample contains {len(test_sentences)} sentences.')
```

Conversión de los Datos para el Fine-Tuning DistilBERT

Después de dividir nuestro conjunto de datos en muestras de entrenamiento y prueba, procedemos al paso crucial de convertir los datos textuales a un formato adecuado para el ajuste fino del modelo DistilBERT. Este proceso incluye varias transformaciones clave, como la tokenización, el relleno y el enmascaramiento.

Proceso de Tokenización

Para tokenizar las oraciones y prepararlas para la entrada en el modelo DistilBERT, definimos una función `tokenize_sentences` que itera sobre cada oración en el conjunto de datos. Dentro de esta función, las oraciones se codifican utilizando el tokenizador de DistilBERT, asegurando que estén adecuadamente tokenizadas, rellenas y truncadas según sea necesario.

```
def tokenize_sentences(sent):
    input_ids = []
    attention_mask = []

    for i in tqdm(range(len(sent))):
        sentence = sent[i]
        encoded = tokenizer.encode_plus(text=sentence,
                                       add_special_tokens=True,
                                       padding=padding_type,
                                       max_length=max_length,
                                       truncation=True,
                                       return_token_type_ids=True,
                                       return_tensors='pt')

        input_ids.append(encoded['input_ids'])
        attention_mask.append(encoded['attention_mask'])

    input_ids = torch.cat(input_ids, dim=0, out=None)
    attention_mask = torch.cat(attention_mask, dim=0, out=None)

    return input_ids, attention_mask
```

Conversión de los Datos de Entrenamiento

- Garantizar Consistencia de los Datos: Confirmamos que todos los elementos en las oraciones de entrenamiento sean cadenas de texto.
- Concatenar Oraciones: Concatenamos todas las oraciones dentro de cada observación para formar un documento único coherente.
- Tokenizar las Oraciones Concatenadas: Tokenizamos los documentos concatenados utilizando la función `tokenize_sentences` definida anteriormente.

```
train_sentences = [str(sentence) for sentence in train_sentences]
concatenated_train_sentences = [" ".join(observation) for observation in train_sentences]
train_input_ids, train_attention_mask = tokenize_sentences(concatenated_train_sentences)
```

Conversión de los Datos de Prueba

Similar al proceso de conversión de datos de entrenamiento, garantizamos la consistencia, concatenamos las oraciones y tokenizamos los datos para las pruebas.

```
test_sentences = [str(sentence) for sentence in test_sentences]
concatenated_test_sentences = [" ".join(observation) for observation in test_sentences]
test_input_ids, test_attention_mask = tokenize_sentences(test_sentences)
```

Conversión de Etiquetas a Tensores y Creación del Cargador de Datos

En esta sección, convertimos nuestras etiquetas en tensores de PyTorch, los cuales son esenciales para entrenar nuestro modelo eficientemente en GPU. Los tensores de PyTorch son similares a los arreglos de NumPy pero ofrecen una migración de datos fluida entre CPU, GPU y memoria local, lo que los hace ideales para cálculos de aprendizaje profundo.

Beneficios de los Tensores:

- Cómputo en GPU: Los tensores facilitan cálculos en GPU, permitiendo un procesamiento paralelo más rápido.
- Migración de Datos: Migración fluida entre diferentes tipos de memoria (CPU, GPU, local) sin sobrecarga adicional.
- LongTensor para Datos Enteros: LongTensor de PyTorch es adecuado para manejar tensores enteros, similar al tipo de datos int en lenguajes de programación tradicionales/

```
# Convert labels to PyTorch tensors
train_labels = torch.LongTensor(train_labels)
test_labels = torch.LongTensor(test_labels)
```

Creación del Cargador de Datos

Para recuperar eficientemente lotes de datos para cálculos en GPU, creamos una clase de conjunto de datos personalizada llamada TaskDataset. Esta clase nos permite encapsular nuestras entradas tokenizadas, máscaras de atención y etiquetas en un único objeto de conjunto de datos.

```
class TaskDataset(torch.utils.data.Dataset):
    def __init__(self, input_ids, attnmasks, labels):
        self.input_ids = input_ids
        self.attnmasks = attnmasks
        self.labels = labels

    def __getitem__(self, idx):
        item = {}
        item['input_ids'] = self.input_ids[idx]
        item['attention_mask'] = self.attnmasks[idx]
        item['labels'] = self.labels[idx]
        return item

    def __len__(self):
        return len(self.labels)

# Convert training and test data into data loader objects
train_loader = TaskDataset(train_input_ids, train_attention_mask, train_labels)
test_loader = TaskDataset(test_input_ids, test_attention_mask, test_labels)
```

Métricas de Evaluación del Modelo

Para evaluar el rendimiento de nuestro modelo, utilizamos métricas como precisión (accuracy), puntuación F1, precisión y recall. Estas métricas proporcionan información sobre el rendimiento de clasificación del modelo en diferentes clases.

```

# Import necessary libraries
from sklearn.metrics import precision_recall_fscore_support, accuracy_score
from scipy.special import softmax

# Function to compute precision, recall, F1 score, and accuracy
def compute_metrics(pred):
    labels = pred.label_ids
    preds = pred.predictions.argmax(-1)
    pred_scores = softmax(pred.predictions, 1)
    pred_scores = np.max(pred_scores, 1)
    if numclasses > 2:
        avg = 'macro'
    else:
        avg = 'binary'
    precision, recall, f1, _ = precision_recall_fscore_support(labels, preds, average=avg)
    acc = accuracy_score(labels, preds) * 100
    return {
        'accuracy': acc,
        'f1': f1 * 100,
        'precision': precision,
        'recall': recall,
        'pred_scores': pred_scores,
        'pred_indices': preds
    }

```

Arquitectura del Modelo

Nuestra arquitectura de modelo consta de una capa DistilBERT seguida de una capa de clasificación. La capa de clasificación produce dos probabilidades para cada clase, lo que nos permite predecir efectivamente el sentimiento de las oraciones de entrada.

Instanciación del Modelo y Parámetros de Entrenamiento

En esta sección, inicializamos nuestro modelo para la clasificación de secuencias utilizando la biblioteca Hugging Face. Definimos el número de clases en nuestro conjunto de datos, instanciamos el modelo y configuramos los parámetros de entrenamiento antes del ajuste fino.

Instanciación del Modelo

- Importamos los métodos necesarios de la biblioteca Hugging Face.
- Definimos el número de clases en nuestro conjunto de datos, que es 5 para la clasificación de sentimientos.
- Instanciamos el modelo para la clasificación de secuencias utilizando AutoModelForSequenceClassification de la biblioteca Hugging Face.

```

# Import necessary methods from Hugging Face
from transformers import AutoModelForSequenceClassification

# Define the number of classes
numclasses = 5

# Instantiate the model
model = AutoModelForSequenceClassification.from_pretrained(
    model_name,
    output_hidden_states=False,
    output_attentions=False,
    num_labels=numclasses
)

```

Configuración de Parámetros de Entrenamiento

Antes de iniciar el proceso de ajuste fino, configuramos varios hiperparámetros y argumentos de entrenamiento utilizando TrainingArguments de la biblioteca Hugging Face. Estos parámetros controlan el proceso de entrenamiento y ayudan a optimizar el rendimiento del modelo.

```

# Define hyperparameters and training arguments
numepochs = 5
logging_steps = 10000000
save_steps = 1000000

# Import TrainingArguments from Hugging Face
from transformers import TrainingArguments

# Set up training arguments
training_args = TrainingArguments(
    output_dir=' ',
    num_train_epochs=numepochs,
    warmup_steps=500,
    weight_decay=0.01,
    per_device_train_batch_size=32,
    logging_dir=' ',
    logging_steps=logging_steps,
    save_steps=save_steps
)

```

Fine-Tuning Process

Ahora que tenemos todos los componentes necesarios preparados, podemos proceder con el ajuste fino del modelo pre-entrenado DistilBERT para nuestra tarea de clasificación de sentimientos

Ejecución Fine-Tuning:

- Importamos la clase Trainer de Hugging Face.
- Inicializamos el entrenador con nuestro modelo, argumentos de entrenamiento, conjuntos de datos y métricas de evaluación.

- Ejecutamos el proceso de ajuste fino utilizando el método `trainer.train()`.

```
# Import Trainer from Hugging Face
from transformers import Trainer

# Load the trainer class
trainer = Trainer(
    model=model,
    args=training_args,
    train_dataset=train_loader,
    eval_dataset=test_loader,
    compute_metrics=compute_metrics
)

# Fine-tune the model
trainer.train()
```

Guardado y Evaluación del Modelo

Después de ajustar fino nuestro modelo, es crucial guardarlo para uso futuro y evaluar su rendimiento en los datos de prueba. También analizamos el reporte de clasificación y la matriz de confusión para obtener información sobre el comportamiento del modelo.

Guardado del Fine-Tuned Model

Guardamos el modelo Fine-Tuned en un directorio especificado usando la variable `output_dir`. Esto nos permite reutilizar el modelo más tarde o compartirlo con otros.

```
# Specify the path to save the model
output_dir = 'model/'

# Save the fine-tuned model
trainer.save_model(output_dir)
```

Evaluación del Fine-Tuned Model

Evaluamos el modelo DistilBERT ajustado fino en los datos de prueba para evaluar su precisión y puntuación F1. Además, generamos un reporte de clasificación y una matriz de confusión para analizar más a fondo el rendimiento del modelo.

```
# Evaluate the model on test data
testscores = trainer.evaluate()

# Print accuracy score and F1 score
print("Test Accuracy: {}".format(testscores['eval_accuracy']))
print("Test F1 Score: {}".format(testscores['eval_f1']))

# Generate classification report
print(classification_report(test_labels, test_pred_labels))

# Plot confusion matrix
sns.heatmap(confusion_matrix_df, annot=True, annot_kws={"size": 20}, fmt="d", cmap="Blues")
plt.ylabel('Actual', fontsize=14)
plt.xlabel('Predicted', fontsize=14)
```

Análisis de Clasificaciones Erróneas e Incertidumbres

Examinamos dónde falló nuestro clasificador y dónde tuvo más incertidumbre para identificar áreas potenciales de mejora.

```
# Show misclassified sentences
misclassified = df[df.predicted_labels != df.test_labels]

# Show sentences with low certainty
uncertain = df[df.predicted_scores < 0.7]
```

Puntos de Discusión

Considera las siguientes preguntas para entender las implicaciones de las clasificaciones erróneas e incertidumbres:

- ¿Qué es más preocupante: frases mal clasificadas con alta certeza o frases correctamente clasificadas con baja certeza?
- ¿Cómo podemos mitigar estas preocupaciones en futuras iteraciones del modelo?
- Mejorando el Rendimiento de Clasificación

Para mejorar el rendimiento de nuestro clasificador, podemos ajustar varios hiperparámetros como max_length, num_epochs, e incluso considerar cambiar la arquitectura del modelo.

Análisis de Texto Tradicional

Además de utilizar modelos transformers, también podemos aprovechar técnicas tradicionales de análisis de texto como el análisis de sentimientos utilizando VADER (Valence Aware Dictionary and Sentiment Reasoner). Este enfoque asigna etiquetas de sentimiento basadas en umbrales predefinidos para puntajes de sentimiento compuestos.

```
# Perform sentiment analysis using VADER
from vaderSentiment.vaderSentiment import SentimentIntensityAnalyzer

analyzer = SentimentIntensityAnalyzer()

def analyze_sentiment(text):
    sentiment = analyzer.polarity_scores(text)
    if sentiment['compound'] >= 0.5:
        return 'level_1' # Very Civil
    elif sentiment['compound'] >= 0.2:
        return 'level_2' # Civil
    elif sentiment['compound'] >= -0.1:
        return 'level_3' # Neutral
    elif sentiment['compound'] >= -0.3:
        return 'level_4' # Uncivil
    else:
        return 'level_5' # Very Uncivil

# Apply sentiment analysis to sentences in the dataframe
df['test_labels_2'] = df['sentences'].apply(analyze_sentiment)

# Evaluate performance of sentiment analysis compared to the classifier
misclassified_vader = df[df.predicted_labels != df.test_labels_2]
```

Parte 3: Clasificación de Nuevas Oraciones con nuestro Modelo Ajustado Fino Transformer

Clasificación de Nuevas Oraciones con el Modelo Fine-Tuned

Una vez que tenemos un modelo fine-tuned, podemos usarlo para clasificar nuevas oraciones de manera rápida y eficiente.

Requisitos Previos

Asegúrate de que todos los modelos y bibliotecas requeridas estén cargados:

```
from tqdm import tqdm
import pickle5 as pickle
import numpy as np
import pandas as pd
import torch
import transformers as ppb
import warnings
warnings.filterwarnings('ignore')
```

Nuevas Oraciones

Define las nuevas oraciones que necesitan clasificación.

```
# Define new sentences for classification
new_sentences = [
    "This product exceeded my expectations!",
    "I had a terrible experience with this company.",
    "The customer service was average.",
    "The food quality was poor, and the staff were rude.",
    ...
]
```

Loading Fine-Tuned DistilBERT Model

Para clasificar nuevas oraciones, primero necesitamos cargar el modelo fine-tuned que guardamos durante el entrenamiento. Sigue estos pasos:

```
# 1. Set the path where the trained model is saved
output_dir = '/content/drive/MyDrive/Tesis/Tesis_DiTella/model'

# 2. Import required libraries
from transformers import AutoTokenizer, AutoModelForSequenceClassification

# 3. Specify the model name used during training
model_name = 'distilbert-base-cased'

# 4. Load pretrained tokenizer
tokenizer = AutoTokenizer.from_pretrained(model_name)

# 5. Determine the number of classes in the dataset
numclasses = 3 # Adjust based on your dataset

# 6. Instantiate the model
model = AutoModelForSequenceClassification.from_pretrained(
    output_dir,
    output_hidden_states=False,
    output_attentions=False,
    num_labels=numclasses
)
```

Preparando Nuevas Oraciones para la Clasificación

Ahora, preparamos las nuevas oraciones para la clasificación mediante tokenización, padding y máscara.

```
# 1. Set maximum length and padding type
padding_type = 'max_length'
max_length = 75 # Adjust as needed

# 2. Define a function to tokenize the sentences
def tokenize_sentences(sent):
    input_ids = []
    attention_mask = []

    for i in tqdm(range(len(sent))):
        sentence = sent[i]
        encoded = tokenizer.encode_plus(text=sentence,
                                       add_special_tokens=True,
                                       padding=padding_type,
                                       max_length=max_length,
                                       truncation=True,
                                       return_token_type_ids=True,
                                       return_tensors='pt')

        input_ids.append(encoded['input_ids'])
        attention_mask.append(encoded['attention_mask'])

    input_ids = torch.cat(input_ids, dim=0, out=None)
    attention_mask = torch.cat(attention_mask, dim=0, out=None)

    return input_ids, attention_mask

# 3. Prepare new sentences
test_input_ids, test_attention_mask = tokenize_sentences(new_sentences)
```

Convirtiendo los Datos de las Nuevas Oraciones en un Objeto DataLoader

Para recuperar eficientemente lotes de datos para la clasificación, convertimos los datos de las nuevas oraciones en un objeto DataLoader.

```
# 1. Import required libraries
from torch.utils.data import TensorDataset, DataLoader

# 2. Convert data into the correct format
test_array = TensorDataset(test_input_ids, test_attention_mask)
test_loader = DataLoader(test_array, batch_size=8)
```

Inicialización del Modelo con Parámetros

Inicializamos el modelo para clasificar las nuevas oraciones, sin entrenarlo más.

```

# 1. Import TrainingArguments from huggingface
from transformers import TrainingArguments, Trainer

# 2. Define the training arguments
training_args = TrainingArguments(
    output_dir=' ',
    logging_dir=' ',
)

# 3. Initialize the trainer
# We will set train_dataset and eval_dataset to test_loader
trainer = Trainer(
    model=model,
    args=training_args,
    train_dataset=test_loader,
    eval_dataset=test_loader
)

```

Ahora, el modelo está listo para clasificar las nuevas oraciones utilizando el modelo DistilBERT fine-tuned.

Clasificación de Nuevas Oraciones

Ahora, utilizaremos el modelo DistilBERT fine-tuned para clasificar las nuevas oraciones. Sigue estos pasos:

```

%%time
# 1. Set the model to evaluation mode
model.eval()

# 2. Use GPU as primary device for computation
device = torch.device('cuda' if torch.cuda.is_available() else 'cpu')

# 3. Store the list of predictions
test_pred_labels = []
test_pred_scores = []
with torch.no_grad():
    for input_ids, attn_mask in test_loader:
        input_ids = input_ids.to(device)
        attn_mask = attn_mask.to(device)
        outputs = model(input_ids, attn_mask)
        outputs = outputs['logits']
        test_pred_labels.extend(torch.argmax(outputs, 1).cpu().detach().numpy().tolist())
        test_pred_scores.extend(torch.max(torch.softmax(outputs, 1), 1)[0].cpu().detach().numpy().tolist())

```

Revisando las Predicciones del Clasificador

Vamos a examinar las predicciones realizadas por nuestro modelo fine-tuned:

```

# 1. Display sentences classified as positive samples (1)
pd.set_option('max_colwidth', 300) # Ensure all sentences are visible
display(df[df.predicted_labels == 1].sort_values(by=['predicted_scores']))

# 2. Display sentences classified as negative samples (0)
pd.set_option('max_colwidth', 300) # Ensure all sentences are visible
display(df[df.predicted_labels == 0].sort_values(by=['predicted_scores']))

# 3. Display sentences classified as neutral samples (2)
pd.set_option('max_colwidth', 300) # Ensure all sentences are visible
display(df[df.predicted_labels == 2].sort_values(by=['predicted_scores']))

# 4. Save Sentences and Predictions to a CSV file
FILE_NAME_TO_SAVE = 'NewSentences_Classified_Sentiment.csv' # Change the file name as needed
df.to_csv(FILE_NAME_TO_SAVE, header=True, index=False)

```

Parte 4: ¿Hacia dónde vamos? Construyendo un Clasificador Mejor

Mejorar el rendimiento de tu clasificador es crucial para lograr mejores resultados y hacer predicciones más precisas. Aquí tienes algunas estrategias que puedes implementar para mejorar el rendimiento de tu clasificador:

1. Probar Diferentes Modelos Pre-Entrenados

Experimentar con diferentes modelos pre-entrenados puede impactar significativamente el rendimiento de tu clasificador. Considera lo siguiente:

- BERT Cased: Usa la versión cased de BERT y observa su rendimiento.
- RoBERTa: Prueba el modelo RoBERTa, que está basado en BERT pero con algunas mejoras.
- BERTweet: Si estás trabajando con Tweets, BERTweet está diseñado específicamente para datos de Twitter y puede ofrecer mejores resultados.

2. Etiquetar Más Oraciones

Agregar más datos etiquetados a tu conjunto de entrenamiento puede mejorar la precisión y generalización de tu clasificador. Sigue estos pasos:

- Identifica Oraciones Mal Clasificadas: Analiza las oraciones mal clasificadas de tus datos de entrenamiento.
- Etiqueta Oraciones Adicionales: Etiqueta estas oraciones mal clasificadas e incorpóralas a tu conjunto de entrenamiento.
- Entrena y Evalúa: Repite el proceso de entrenamiento con el conjunto de datos ampliado y evalúa el rendimiento del modelo.

3. Probar Aprendizaje Activo

El aprendizaje activo te permite mejorar iterativamente tu clasificador al etiquetar selectivamente las instancias más informativas. Aquí tienes cómo:

- Comienza Pequeño: Empieza con un conjunto pequeño y balanceado de datos etiquetados.
- Predice Instancias Inciertas: Usa tu clasificador para predecir instancias no etiquetadas e identificar las más inciertas.
- Etiqueta Instancias Inciertas: Etiqueta manualmente las instancias más inciertas y agrégalas a tu conjunto de datos de entrenamiento.
- Itera: Repite el proceso, aumentando gradualmente el tamaño de tu conjunto de entrenamiento y monitoreando el rendimiento del modelo.

Combinación de Estrategias

Para obtener resultados óptimos, considera combinar todas estas estrategias. Al aprovechar diferentes modelos pre-entrenados, etiquetar continuamente más datos y utilizar técnicas de aprendizaje activo, puedes mejorar iterativamente el rendimiento de tu clasificador hasta alcanzar el nivel deseado de precisión.

Implementar estas estrategias no solo mejorará la precisión de tu clasificador, sino que también profundizará tu comprensión de los datos y los patrones subyacentes, lo que conducirá a predicciones más robustas y confiables.

Appendix F. Validación del LLM

1. Métricas de Evaluación

1.1. Precisión, Sensibilidad y Puntuación F1

La precisión, la sensibilidad y la puntuación F1 son métricas fundamentales para evaluar el rendimiento de clasificación de los modelos. Cuantifican la capacidad del modelo para hacer predicciones positivas correctas, capturar todas las instancias positivas y equilibrar precisión y sensibilidad. Para el LLM desarrollado en este estudio, se calcularon las siguientes métricas:

- Precisión: 0.4746
- Sensibilidad: 0.5385
- Puntuación F1: 0.5045

Estas métricas ofrecen información sobre la efectividad del modelo en identificar instancias positivas, considerando tanto los falsos positivos como los falsos negativos..

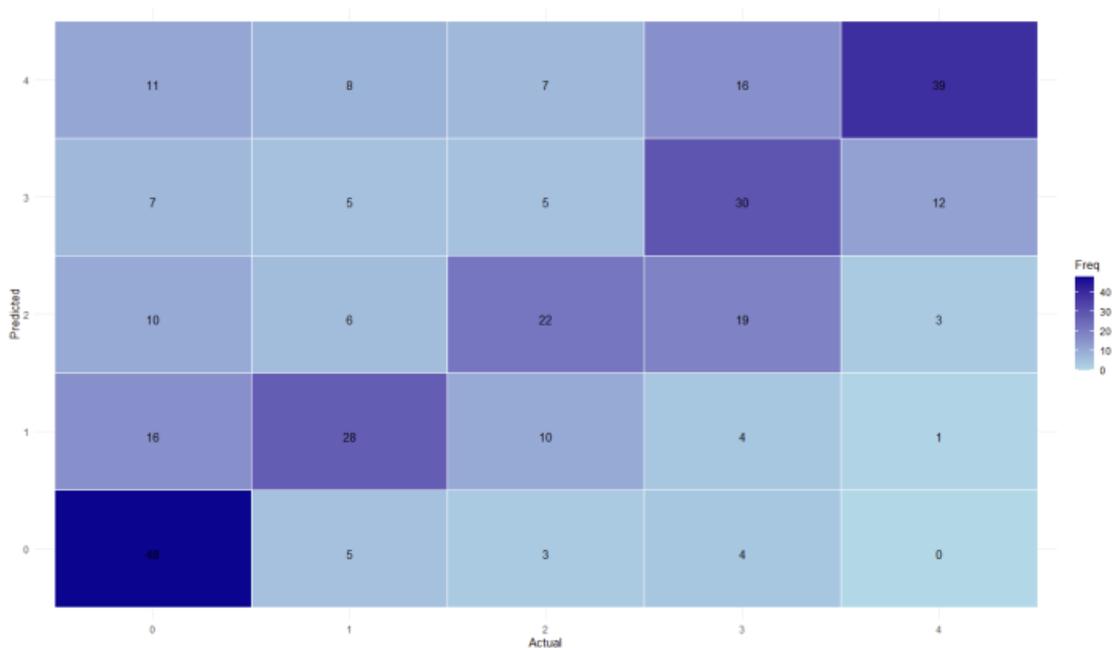
2. Análisis de la Matriz de Confusión

Se proporciona un análisis exhaustivo de cómo las predicciones del modelo se comparan con las etiquetas de clase reales a través de una matriz de confusión. En esta matriz, los ejemplos en una clase predicha se representan en cada columna, y las ocurrencias en una clase real se representan en cada fila. Esto permite analizar a fondo el rendimiento del modelo en varias clases, lo cual facilita el cálculo de múltiples medidas de rendimiento.

2.1. Matriz de Confusión

A continuación se presenta una visión detallada del rendimiento de clasificación del LLM a través de la matriz de confusión::

Figura F1: Matrix de Confusion



2.2. Estadísticas Generales

Las estadísticas generales ofrecen información clave sobre el rendimiento del LLM en todo el conjunto de datos:

- **Precisión:** El porcentaje de casos correctamente clasificados en relación con todas las instancias. En este caso, el LLM obtiene una precisión del 0.668, lo que significa que el modelo identificó correctamente aproximadamente el 66.8% de los casos.
- **Intervalo de Confianza del 95%:** Un intervalo que estima con un nivel de confianza del 95% el parámetro de la población, en este caso la precisión. Tenemos un nivel de confianza del 95% de que la verdadera precisión del modelo está dentro del intervalo (0.601, 0.735).
- **Tasa de Información Nula:** La precisión con la que un modelo predice la clase mayoritaria en cada caso. La tasa de información nula en este estudio es del 0.324, lo que significa que se lograría un modelo ingenuo con una precisión del 32.4% en la predicción de la clase mayoritaria.
- **Kappa:** Una medida estadística que considera el acuerdo basado en el azar entre las predicciones del modelo y las etiquetas reales. Las predicciones del modelo y las etiquetas reales muestran un acuerdo moderado, por encima del azar, como lo indica el valor de kappa de 0.415.

Estas estadísticas generales proporcionan una evaluación resumida del rendimiento del LLM y su acuerdo con las etiquetas de clase reales.

2.3. Estadísticas por Clase

La tabla proporciona un desglose completo de diversas métricas de rendimiento para cada clase en el conjunto de datos, ofreciendo insights sobre la capacidad del LLM para distinguir entre diferentes clases.

Tabla F1. Estadísticas por Clase

Statistics by Class:	Neutral	Mildly Uncivil	Moderately Uncivil	Highly Uncivil	Extremely Uncivil
Sensitivity	0.5217	0.53846	0.46809	0.41096	0.7091
Specificity	0.9471	0.88390	0.86029	0.88211	0.8409
Positive Predictive Value	0.8000	0.47458	0.36667	0.50847	0.4815
Negative Predictive Value	0.8301	0.90769	0.90347	0.83462	0.9328

Prevalence	0.2884	0.16301	0.14734	0.22884	0.1724
Detection Rate	0.1505	0.08777	0.06897	0.09404	0.1223
Detection Prevalence	0.1881	0.18495	0.18809	0.18495	0.2539
Balanced Accuracy	0.7344	0.71118	0.66419	0.64654	0.7750

- **Sensitivity (True Positive Rate):** La sensibilidad, también conocida como tasa de verdaderos positivos, es una métrica que expresa el porcentaje de ejemplos positivos reales para cada clase que el modelo identifica correctamente como verdaderos positivos.
- **Specificity (True Negative Rate):** El porcentaje de casos negativos genuinos entre todas las instancias negativas reales para cada clase que el modelo identifica correctamente se conoce como tasa de verdaderos negativos o especificidad.
- **Positive Predictive Value (Precision):** El valor predictivo positivo, también conocido como precisión, mide el porcentaje de casos que el modelo clasifica como positivos y que realmente son positivos para cada clase.
- **Negative Predictive Value:** Para cada clase, el porcentaje de casos que el modelo clasifica como negativos y que realmente pertenecen a esa categoría.
- **Prevalence, Detection Rate, Detection Prevalence:** La prevalencia es el porcentaje de casos en el conjunto de datos que pertenecen a cada clase. La tasa de detección es el porcentaje de ejemplos que el modelo clasifica correctamente para cada clase, y la prevalencia de detección es el porcentaje de instancias que el modelo clasifica como pertenecientes a cada clase.
- **Balanced Accuracy:** Al promediar la sensibilidad y la especificidad, y teniendo en cuenta los desequilibrios de clase en el conjunto de datos, la precisión equilibrada ofrece una evaluación justa del rendimiento de la clasificación.

3. Comparación con Modelos Dummy

Las comparaciones con modelos dummy se realizan para proporcionar contexto en la evaluación del rendimiento del LLM. Estos modelos dummy ofrecen predicciones básicas que actúan como estándares de referencia y proporcionan un punto de comparación para evaluar qué tan bien el LLM predice los resultados.

En este estudio, se consideran dos tipos de modelos dummy:

Modelo Dummy Aleatorio: El Modelo Dummy Aleatorio asigna aleatoriamente etiquetas a las instancias basándose en la distribución de clases observada en el conjunto de datos. En consecuencia:

- Precisión, Recall y F1 Score son aproximadamente iguales a la prevalencia de la clase positiva.

- Las predicciones del modelo son completamente aleatorias y no incorporan ningún patrón de reconocimiento significativo.

Modelo Dummy de Clase Mayoritaria: El Modelo Dummy de Clase Mayoritaria clasifica todas las instancias en la clase mayoritaria observada en el conjunto de datos. Este modelo puede mostrar:

- Alta precisión al predecir correctamente las instancias que pertenecen a la clase mayoritaria.
- Bajo recall, ya que no identifica correctamente las instancias pertenecientes a las clases minoritarias, lo que resulta en un bajo F1 Score.

4. Conclusión

El LLM demuestra un rendimiento moderado en la clasificación de instancias en múltiples categorías. Aunque logra una precisión de 0.668, también mantiene un equilibrio entre precisión y recall, como lo indica el F1 Score de 0.5045. Sin embargo, el rendimiento del modelo puede contextualizarse mejor al compararlo con modelos dummy. En comparación con los modelos dummy aleatorios y de clase mayoritaria, el LLM supera estos enfoques simplistas, lo que indica su efectividad en la captura de patrones significativos en los datos.

Appendix G. Tabla de Regresión OLS

Tabla G1. Tabla de Regresión OLS

	Coefficient	Std. Error	t-value	Pr(> t)	
(Intercept)	2.616932	0.046655	56.091	6e-16	***
temperature	0.002351	0.001676	1.402	6e-02	
Interaction_Temperature_Category_Extreme_Hot	0.313799	0.012074	25.989	1e-16	***
Interaction_Temperature_Category_Extreme_Hot	0.023258	0.003057	7.608	8e-14	***
Temperautre_CategoryExtreme Hot	-2.311624	0.097942	-23.602	3e-11	***
Temperautre_CategoryExtreme Cold	0.254742	0.040812	6.242	3e-09	***
Factor(Company) Amazon	-1.480053	0.039178	-37.778	1e-16	***
Factor(Company) Amazon Mexico	-0.296988	0.074886	-3.966	3e-05	***
Factor(Company) Amazon.com.br	-1.439754	0.072583	-19.836	1e-16	***
Factor(Company) americanair	-1.004905	0.039340	-25.544	1e-16	***
Factor(Company) AT&T Help	-0.943069	0.040029	-23.560	0.0065	***
Factor(Company) Avianca	-0.265179	0.097445	-2.721	1e-16	**
Factor(Company) Bell	-0.974883	0.078444	-12.428	8e-02	***
Factor(Company) Cable & Wireless	-0.080957	0.040979	-1.976	9e-12	*
Factor(Company) Claro Brazil	-0.300837	0.038863	-7.741	0.0023	***
Factor(Company) Claro Chile	-0.117958	0.038708	-3.047	1e-16	**
Factor(Company) Claro Colombia	-0.827605	0.069804	-9.153	1e-16	***
Factor(Company) Claro Ecuador	0.329548	0.037390	3.141	7e-09	***
Factor(Company) Claro Guatemala	-0.532057	0.043139	-0.718	1e-16	***
Factor(Company) Claro Honduras	-0.285506	0.070193	-6.558	7e-09	***
Factor(Company) Claro Nicaragua	-0.514907	0.056255	-19.393	1e-16	***
Factor(Company) Copa Airlines	0.123941	0.039465	-5.859	0.00068	**
Factor(Company) Delta Hotels	-0.573998	0.799671	-22.284	1e-16	
Factor(Company) Entel Chile	-0.299572	0.045681	-7.271	0.000043	***
Factor(Company) Entel Peru	-0.721160	0.037186	-27.195	1e-16	***
Factor(Company) FairmontHotels	-0.785241	0.134016	-12.044	1e-16	***
Factor(Company) Four Seasons Hotels	-1.123957	0.050437	-4.968	0.018	***
Factor(Company) Gol Linhas Aéreas	-0.274214	0.037714	-2.364	1e-16	***
Factor(Company) Hilton Hotels	-1.050216	0.038618	-13.816	2e-05	***
Factor(Company) Iberoestar	-0.689664	0.057261	-6.100	8e-03	***
Factor(Company) IHG	-0.698784	0.140645	-4.092	0.086	***

Factor(Company) LATAM Airlines	-0.093581	0.039583	-23.434	1e-16	*
Factor(Company) LATAM Brasil	-0.512137	0.037068	-4.185	1e-16	***
Factor(Company) Marriot Hotels	-0.809501	0.132715	-3.950	1e-16	***
Factor(Company) Melia Hotels International	-0.213427	0.052156	-9.586	0.00021	***
Factor(Company) Mercado Libre Chile	-1.298283	0.055402	-5.189	0.089	***
Factor(Company) Mercado Libre Colombia	-0.201124	0.048053	-2.760	1e-16	***
Factor(Company) Mercado Libre Mexico	-0.154457	0.039101	-1.718	1e-16	***
Factor(Company) MGM Grand Hotel	-1.056910	0.110254	-8.375	0.031	***
Factor(Company) Movistar Colombia	-0.204692	0.039448	-11.841	1e-16	**
Factor(Company) Movistar Mexico	-0.099596	0.036090	-8.728	0.000017	.
Factor(Company) Movistar Peru	-0.066528	0.038720	-10.912	1e-16	***
Factor(Company) Movistar Venezuela	-0.333322	0.039802	-2.331	1e-16	***
Factor(Company) Porter Airlines	-0.908488	0.076727	-1.701	0.031	***
Factor(Company) Rappi Argentina	-0.330541	0.037870	-8.728	1e-16	***
Factor(Company) Rappi Colombia	-0.430138	0.039419	-10.912	1e-16	*
Factor(Company) Rappi Ecuador	-0.096235	0.041288	-2.331	0.048	.
Factor(Company) Rappi Mexico	-0.062157	0.036532	-1.701	0.083	***
Factor(Company) Rappi Peru	-0.263040	0.039898	-6.593	0.29	.
Factor(Company) Rappi Chile	0.069191	0.038247	1.809	0.83	***
Factor(Company) RIU Hotels & Resorts	-0.491953	0.051954	-9.469	0.46	***
Factor(Company) Rogers	-1.029266	0.039135	-26.300	0.16	***
Factor(Company) Sheraton	-0.613883	0.239157	-2.567	0.86	***
Factor(Company) T-Mobile	-1.281126	0.038725	-33.083	1e-16	***
Factor(Company) Telcel	-0.756929	0.041273	-18.340	0.048	***
Factor(Company) Telefonica Argentina	-0.622585	0.145215	-4.287	0.083	***
Factor(Company) Telefonica Colombia	-0.303295	0.081153	-3.737	0.29	***
Factor(Company) TELUS Support	-0.772169	0.038855	-19.873	1e-16	***
Factor(Company) Tigo Panama	0.393846	0.040652	9.688	1e-16	***
Factor(Company) TIM AJUDA	-0.612541	0.038713	-15.823	1e-16	***
Factor(Company) United Airlines	-1.218874	0.039263	-31.044	1e-16	***
Factor(Company) Verizon Support	-1.072352	0.041762	-25.678	1e-16	***
Factor(Company) Volaris	-0.214066	0.037995	-5.634	0.031	***
Factor(Company) Westin Hotels	-0.522993	0.242641	-2.155	1e-16	*
Factor(Company) Westjet	-0.908582	0.040942	-22.192	1e-16	***
Factor(Month) 2	-0.066747	0.030525	-2.187	0.16	*
Factor(Month) 3	-0.072175	0.029162	-2.475	0.086	*
Factor(Month) 4	-0.056734	0.029465	-1.925	0.46	.
Factor(Month) 5	-0.029822	0.028540	-1.045	0.83	.
Factor(Month) 6	-0.111904	0.027458	-4.075	0.048	***

Factor(Month) 7	-0.005832	0.026647	-0.219	0.16
Factor(Month) 8	0.044657	0.026519	1.684	0.29
Factor(Month) 9	-0.018311	0.026368	-0.694	0.83
Factor(Month) 10	-0.020022	0.026929	-0.744	0.29
Factor(Month) 11	-0.056733	0.040507	-1.401	0.16
Factor(Month) 12	-0.006370	0.036727	-0.173	0.86

Signif. codes:

0 ‘‘ 0.001 ‘‘ 0.01 ‘‘ 0.05 ‘.’ 0.1‘

Appendix H. Figuras Adicionales del Análisis Transnacional

Tabla H1: Análisis de Tukey HSD del Grupo Claro por País

Country	Diff	lwr	Upr	O adj
Chile-Brasil	-0.05850392	-0.16970460	0.05269676	0.7134115
Colombia-Brasil	-0.74581056	-0.95773260	-0.53388852	0.0000000
Ecuador-Brasil	0.43049877	0.31866054	0.54233701	0.0000000
Guatemala-Brasil	-0.43110821	-0.55842533	-0.30379109	0.0000000
Honduras-Brasil	-0.11683594	-0.33237761	0.09870574	0.6834224
Nicaragua-Brasil	-0.39326096	-0.56433299	-0.22218894	0.0000000
Colombia-Chile	-0.68730664	-0.89939313	-0.47522015	0.0000000
Ecuador-Chile	0.48900269	0.37685316	0.60115223	0.0000000
Guatemala-Chile	-0.37260429	-0.50019495	-0.24501363	0.0000000
Honduras-Chile	-0.05833202	-0.27403538	0.15737135	0.9852892
Nicaragua-Chile	-0.33475705	-0.50603274	-0.16348135	0.0000002
Ecuador-Colombia	1.17630933	0.96388787	1.38873080	0.0000000
Guatemala-Colombia	0.31470235	0.09373914	0.53566555	0.0005357
Honduras-Colombia	0.62897462	0.34777486	0.91017438	0.0000000
Nicaragua-Colombia	0.35254959	0.10379123	0.60130796	0.0005856
Guatemala-Ecuador	-0.86160699	-0.98975368	-0.73346029	0.0000000
Honduras-Ecuador	-0.54733471	-0.76336745	-0.33130198	0.0000000
Nicaragua-Ecuador	-0.82375974	-0.99545005	-0.65206943	0.0000000
Honduras-Guatemala	0.31427227	0.08983520	0.53870935	0.0007254
Nicaragua-Guatemala	0.03784725	-0.14430495	0.21999944	0.9964418
Nicaragua-Honduras	-0.27642503	-0.52827417	-0.02457589	0.0207322

Appendix I. Uso de Herramientas de Inteligencia Artificial

Esta sección se incluye para destacar el papel e influencia de las herramientas de Inteligencia Artificial (IA) utilizadas en este trabajo. Es importante señalar que estas herramientas se emplearon como medios de apoyo para la información presente en el trabajo, no como herramientas de razonamiento.

ChatGPT y Bard:

Se reconoce el uso de ChatGPT y Bard por su papel integral en la metodología empleada para recopilar y buscar artículos relacionados con escándalos de corrupción. Bard, específicamente, facilitó la búsqueda exhaustiva de artículos sobre escándalos de corrupción presentes en el conjunto de datos. Estas herramientas fueron consideradas esenciales para la exhaustividad de la metodología, asegurando la inclusión de todos los casos relevantes para cada año y país en el conjunto de datos. Cada herramienta fue consultada de manera individual para casos dentro del período estudiado y para cada país, asegurando una cobertura completa de todas las instancias.

Además, estas herramientas se utilizaron para correcciones gramaticales en segmentos del marco teórico y para ordenar cronológicamente la bibliografía presentada en este trabajo. Sus capacidades se extendieron más allá de la recuperación de información para ayudar en el refinamiento lingüístico y la organización del material de investigación.

Grammarly:

Adicionalmente, se reconoce el uso de Grammarly por su papel en la realización de revisiones ortográficas y gramaticales durante el proceso de escritura. Grammarly sirvió como una herramienta valiosa para garantizar la corrección y claridad del lenguaje en el presente trabajo, contribuyendo a la calidad general de la escritura y su legibilidad.

En resumen, la integración de herramientas de IA como ChatGPT, Bard y Grammarly desempeñó un papel significativo en mejorar la eficiencia, precisión y calidad del proceso de investigación y el contenido escrito presentado en este trabajo. Sus contribuciones abarcaron desde la recuperación de información hasta el refinamiento lingüístico y la detección de errores, enriqueciendo colectivamente la empresa de investigación.