

Escuela de Negocios

Tipo de documento: Tesis de maestría



EMBA | Executive MBA

IA Generativa en la Atención digital al cliente en la Industria de Telecomunicaciones

Autoría: Medina, Matías

Año: 2025

¿Cómo citar este trabajo?

Medina, M. (2025) "*IA Generativa en la Atención digital al cliente en la Industria de Telecomunicaciones*". [Tesis de maestría. Universidad Torcuato Di Tella]. Repositorio Digital Universidad Torcuato Di Tella.

<https://repositorio.utdt.edu/handle/20.500.13098/13897>

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



UNIVERSIDAD
TORCUATO DI TELLA

TRABAJO FINAL – MAESTRÍA EN DIRECCIÓN
DE EMPRESAS

*“IA Generativa en la Atención digital al cliente en la Industria de
Telecomunicaciones”*

AÑO 2025

ALUMNO: Matias Medina

TUTOR: Ignacio Barrera

Dedicatoria – Agradecimientos

En primer lugar quiero agradecer a mi familia, su apoyo incondicional ha sido fundamental en cada nuevo proyecto que emprendo. A mis compañeros del Grupo 1, “Nesquik Team”, hoy amigos con quienes comparto aprendizajes y desafíos. Y a la universidad, por ofrecerme oportunidades únicas, como la experiencia de intercambio en Duke, que enriqueció mi formación académica y personal.

Resumen Ejecutivo

Las empresas del sector de las telecomunicaciones se encuentran inmersas en un contexto complejo, caracterizado por una fuerte intensificación de la competencia y elevados niveles de inversión en infraestructura y costos estructurales. En este escenario, resulta fundamental explorar modelos operativos más eficientes que permitan alcanzar la rentabilidad sin descuidar la relación de largo plazo con los clientes. En este sentido, la transformación digital se consolida como un programa estratégico en estas empresas y la inteligencia artificial se posiciona como una tecnología clave para impulsar el cambio.

En los últimos años, la inteligencia artificial ha experimentado un gran auge, en particular con el surgimiento de la inteligencia artificial generativa (GenIA), una tecnología disruptiva que permite emular capacidades humanas como la comprensión del lenguaje natural, el reconocimiento de imágenes, audio y el habla. Entre los distintos ámbitos de aplicación, uno de los más prometedores es el de los servicios de atención al cliente, donde esta tecnología promete transformar la experiencia del usuario y optimizar los procesos.

El presente trabajo tiene como objetivo analizar el potencial de la inteligencia artificial generativa en los procesos de atención al cliente dentro del sector de las telecomunicaciones, y proponer una estrategia de implementación a partir del análisis de un caso práctico. Para ello, se desarrolla primero un abordaje teórico que permite comprender los ámbitos de aplicación de esta tecnología y los principales desafíos asociados a su adopción. Posteriormente se analiza un caso concreto en el canal de WhatsApp, con el fin de identificar oportunidades de mejora. En base a los hallazgos obtenidos se propone una estrategia de adopción estructurada en tres fases: la primera orientada a incorporar la tecnología para mejorar la capacidad de resolución automática del BOT; la segunda con foco en potenciar la productividad de los asesores humanos, mediante la habilitación de herramientas de ayuda basada en GenIA (co-pilots) y una tercera fase que consiste en hacer extensible estas capacidades a otros canales de atención, como ser la aplicación y el canal telefónico (IVR), para consolidar así una experiencia omnicanal y personalizada en todos los puntos de contacto con el cliente.

Por último, se destaca que la adopción de inteligencia artificial generativa requiere de una planificación cuidadosa que contemple no solo su integración tecnológica, sino también el desarrollo de capacidades organizacionales, así como el abordaje de consideraciones éticas, regulatorias y relacionadas a la privacidad de datos sensibles. Una implementación estratégica y responsable de esta tecnología puede construir una ventaja competitiva de gran valor para hacer frente a los desafíos que impone la industria.

Palabras clave

Inteligencia artificial generativa, Atención al cliente, Telecomunicaciones, Chatbots

Introducción / Prefacio

En la actualidad las operadoras de telecomunicaciones se enfrentan a un contexto complejo donde resulta cada vez más difícil sostener la rentabilidad. Esto debido a los altos costos de inversión en infraestructura, la intensificación de la competencia, la dificultad de conseguir diferenciación y la constante guerra de precios. Esta situación obliga a buscar constantemente formas de optimizar los costos operativos y brindar una experiencia cliente excelente para ser competitivos.

Por otro lado, la inteligencia artificial (IA) viene experimentando un gran crecimiento en años recientes, impulsado por el surgimiento de avanzados modelos de lenguaje (LLM) que dieron lugar a la IA Generativa, con la cual es posible automatizar ciertas tareas que antes solo podían ser realizadas por humanos.

La aplicación de IA generativa podría representar una gran oportunidad estratégica en la industria de telecomunicaciones para mejorar la experiencia y relacionamiento con los clientes, sobre todo en procesos claves como la atención. Sin embargo, existe el desafío de definir una estrategia que facilite la adopción de esta tecnología de la mejor manera posible.

Las preguntas motivan este trabajo y orientan su desarrollo son:

- *¿Cómo se podría aplicar IA generativa para mejorar la experiencia cliente en procesos de atención en la industria de telecomunicaciones?*
- *¿Puede la IA generativa contribuir en fortalecer los canales digitales en la estrategia de atención y relacionamiento con clientes? Especialmente en WhatsApp, que es el principal canal utilizado por la empresa analizada como caso de estudio.*
- *¿Cuáles son los principales desafíos y barreras de adopción de IA generativa? ¿Qué consideraciones deben tenerse en cuenta al momento de plantear una propuesta de implementación?*

Objetivo General:

Explorar el potencial de la inteligencia artificial generativa para optimizar la experiencia del cliente en procesos de atención en la industria de telecomunicaciones y diseñar una estrategia para su adopción a partir del análisis de un caso aplicado en el canal WhatsApp.

Objetivo Específico:

- Identificar los principales desafíos del sector de telecomunicaciones en los servicios de atención al cliente.
- Analizar cómo la IA generativa puede contribuir a resolver dichos desafíos.
- Identificar los principales riesgos y barreras para la adopción de esta tecnología.
- Diseñar una posible estrategia para la adopción de IA generativa en canales digitales a través del análisis de un caso práctico en el sector Telco.

Índice / Tabla de Contenido

Tabla de contenido

<i>MARCO TEÓRICO</i>	10
<i>Capítulo 1: Fundamentos de la IA generativa</i>	10
Subsección 1.1 Historia de la Inteligencia Artificial	10
Subsección 1.2: Inteligencia Artificial Generativa.....	11
Subsección 1.3: Ámbitos de aplicación de la IA generativa	14
Subsección 1.4: Desafíos que enfrenta la IA Generativa	15
Subsección 1.5: Diferencia entre IA tradicional e IA generativa.....	17
Subsección 1.6: Impacto de la IA generativa en el campo de procesamiento del lenguaje natural (NLP)	18
<i>Capítulo 2: IA Generativa en Atención al cliente</i>	19
Subsección 2.1: El rol estratégico de la inteligencia artificial en las organizaciones	19
Subsección 2.2: Atención al cliente en la era digital.....	21
Subsección 2.3: Importancia estratégica de la Atención al cliente.....	21
Subsección 2.4: IA generativa en atención al cliente y aplicación en sector Telco.....	22
Subsección 2.5: Casos de éxito en la aplicación de IA generativa en atención al cliente	24
<i>Capítulo 3: Desafíos de la industria de Telecomunicaciones</i>	27
Subsección 3.1: Diagnóstico de la industria.....	27
Subsección 3.2: Estrategias de transformación	29
<i>Capítulo 4: Consideraciones éticas y regulatorias de la Inteligencia Artificial</i>	32
<i>INVESTIGACIÓN EMPÍRICA-DOCUMENTAL</i>	35
<i>Capítulo 5: Descripción del caso de estudio</i>	35
Subsección 5.1: Presentación de la empresa.....	35
Subsección 5.2: Rol de WhatsApp en estrategia de relacionamiento Digital	35
Subsección 5.3: Bot conversacional en WhatsApp	36
Subsección 5.4: Talento humano y dinámica organizacional	36
Subsección 5.5: Problemática y limitaciones actuales.....	37
<i>Capítulo 6: Fuente de datos y alcance</i>	38
Subsección 6.1: Datos disponibles.....	38

Subsección 6.2: Tipos de experiencias en el canal en el canal de WhatsApp.....	38
Subsección 6.3: Alcance.....	39
Subsección 6.4: Consideraciones éticas y de confidencialidad.....	39
<i>Capítulo 7: Metodología de análisis</i>	<i>40</i>
Subsección 7.1: Descripción del tipo de análisis.....	40
Subsección 7.2: Metodología para identificación de oportunidades de mejora	40
<i>Capítulo 8: Análisis de datos</i>	<i>41</i>
<i>CAPÍTULO 9: Recomendaciones y conclusiones.....</i>	<i>57</i>
Subsección 9.1: Recomendación general	57
Subsección 9.2: Estrategia de implementación	57
Subsección 9.3: Conclusiones generales.....	59

Lista de figuras

Figura 1 Funcionamiento general de un modelo fundacional. Fuente: https://www.coit.es/sites/default/files/digitales_libro_blanco_ia_generativa.pdf . © 2023 DigitalES y COIT.....	11
Figura 2 Ejemplos de generación de imágenes a partir de instrucciones en lenguaje natural mediante DALL·E 2. Fuente: https://arxiv.org/pdf/2303.04226	12
Figura 3 Uso de IA en actividades funcionales. Fuente: Generative artificial intelligence: Opportunities and risks, S. Kniazieva y S. Kniaziev, 2022, The Problems of Economy, p75 http://tppe.econom.univ.kiev.ua/data/2022_45/zb45_07.pdf . © 2022 The Problems of E	19
Figura 4 Disminución de costos atribuida a la adopción de IA. Fuente: Generative artificial intelligence: Opportunities and risks, S. Kniazieva y S. Kniaziev, 2022, The Problems of Economy, p76 http://tppe.econom.univ.kiev.ua/data/2022_45/zb45_07.pdf . © 2022 Th	20
Figura 5 Hype Cycle de tecnologías para atención al cliente (Customer Service). Fuente: Hype Cycle for Customer Service and Support Technologies, 2023, Gartner. © 2023 Gartner, Inc.	23
Figura 6 Principales preocupaciones identificadas por ejecutivos C-level del sector telecomunicaciones. Fuente: McKinsey & Company, 2024. © 2024 McKinsey & Company.....	28
Figura 7 Palancas estratégicas identificadas por ejecutivos C-level del sector telecomunicaciones. Fuente: McKinsey & Company, 2024. © 2024 McKinsey & Company.	30
Figura 8 Esquema del proceso de aprendizaje automático y evaluación de desempeño del modelo. Fuente: Towards intelligent regulation of artificial intelligence, M. C. Buiten, 2019, https://doi.org/10.1017/err.2019.8 . © 2019 Cambridge University Press.	33
Figura 9 NPS General del canal de whatsapp. Fuente: elaboración propia.	41
Figura 10 NPS de la atención del BOT en el canal de whatsapp. Fuente: elaboración propia.	42
Figura 11 NPS de la atención asistida en el canal de whatsapp. Fuente: elaboración propia.	43
Figura 12 Gráfico de coocurrencias en comentarios detractores del BOT. Fuente: elaboración propia.	45
Figura 13 Gráfico de coocurrencias en comentarios detractores del BOT, tópico central. Fuente: elaboración propia.....	45
Figura 14 Gráfico de coocurrencias en comentarios detractores del BOT, tópico secundario(1). Fuente: elaboración propia.	46
Figura 15 Gráfico de coocurrencias en comentarios detractores del BOT, tópico secundario(2). Fuente: elaboración propia.	46
Figura 16 Gráfico de coocurrencias en comentarios detractores del Asistido. Fuente: elaboración propia.	47
Figura 17 Gráfico de coocurrencias en comentarios detractores del Asistido, tópico central. Fuente: elaboración propia.	47

Lista de Tablas

Tabla 1 - Metodología análisis de coocurrencias. Fuente: Elaboración propia	45
Tabla 2 - Metodología análisis de combinación de CDUs. Fuente: Elaboración propia.....	49
Tabla 3 - Frecuencia de casos en el BOT. Fuente: Elaboración propia.....	51
Tabla 4 - NPS de las combinaciones de casos de uso más frecuentes en el BOT. Fuente: Elaboración propia.	54

MARCO TEÓRICO

Capítulo 1: Fundamentos de la IA generativa

Esta sección aborda los principales conceptos que sustentan la inteligencia artificial generativa, incluyendo su origen, arquitectura, ámbitos de aplicación y desafíos actuales. El propósito es proporcionar una base teórica que permita comprender el alcance, las capacidades y limitaciones de esta tecnología.

Subsección 1.1 Historia de la Inteligencia Artificial

Según Kai-Fu Lee (2021), el concepto de inteligencia artificial (IA) surgió en la conferencia de Dartmouth en 1956, donde destacados científicos como Marvin Minsky, John McCarthy y Herbert Simon acuñaron el término. El objetivo planteado fue desarrollar máquinas inteligentes capaces de realizar tareas que hasta ese momento eran exclusivas de los seres humanos.

El autor también señala que, desde sus inicios, la inteligencia artificial atravesó ciclos de auge y declive, conocidos como “inviernos de la IA”, caracterizados por grandes expectativas seguidas de recortes de inversión ante la falta de resultados concretos. El campo se dividió en dos enfoques principales: por un lado, los sistemas simbólicos o expertos, basados en reglas lógicas del tipo “Si X, entonces Y”; por otro lado, el desarrollo de redes neuronales artificiales que recrean el funcionamiento del cerebro humano y aprenden patrones a partir de datos.

Asimismo, Kai-Fu Lee menciona que las primeras redes neuronales, surgidas en las décadas del 50 y 60, generaron grandes expectativas, pero rápidamente perdieron relevancia, dando lugar a uno de los primeros inviernos de la IA en los años 70. Durante los años 90, el campo volvió a estancarse debido a las limitaciones técnicas y a la falta de potencia computacional, a pesar del crecimiento exponencial en la disponibilidad de datos gracias al avance de internet.

El autor destaca que un punto de inflexión se produjo en la década del 2000, cuando Geoffrey Hinton descubrió una nueva forma de entrenar redes neuronales artificiales, lo que permitió grandes avances en tareas como el reconocimiento de voz e imágenes. Este desarrollo dio origen al aprendizaje profundo o *deep learning*, una tecnología que, desde 2012, ha desplazado a modelos anteriores en múltiples aplicaciones.

Kai-Fu Lee también menciona que en ese mismo año, el equipo de Hinton ganó con una amplia diferencia una competencia internacional de visión por computadora, consolidando el potencial del aprendizaje profundo. En 2013, Google adquirió su startup, y al año siguiente compró DeepMind, empresa que desarrolló AlphaGo, el sistema que en 2017 logró vencer al campeón mundial Ke Jie en el juego Go, reconocido por su gran complejidad. Este acontecimiento refleja cómo el uso de redes neuronales profundas ha permitido que las máquinas igualen e incluso superen el desempeño humano en diversas tareas.

Subsección 1.2: Inteligencia Artificial Generativa

El impulso que tomó en 2012 la evolución de las redes neuronales con el aprendizaje profundo sentó las bases para el surgimiento en 2014 de las redes neuronales generativas antagónicas (GAN - *Generative Adversarial Network*). (DigitalEs, 2024).

La Inteligencia Artificial Generativa es un tipo de Inteligencia Artificial que puede crear contenido nuevo basado en patrones que ha aprendido (p ej. texto imágenes, audio...).

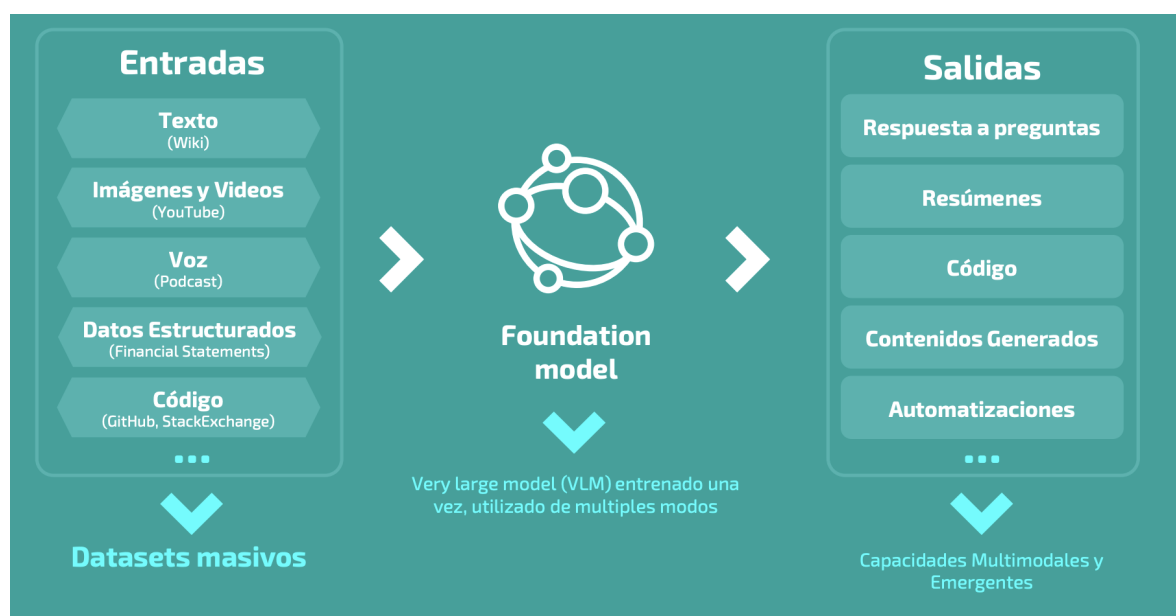


Figura 1 Funcionamiento general de un modelo fundacional. Fuente: https://www.coit.es/sites/default/files/digitales_libro_blanco_ia_generativa.pdf. © 2023 DigitalEs y COIT.

En la actualidad, el contenido generado por inteligencia artificial ocupa el centro de atención más allá del ámbito científico, despertando el interés general de la sociedad hacia productos de IA, como lo son ChatGPT o DALL-E.

ChatGPT es un modelo de lenguaje desarrollado por OpenAI, orientado a la creación de sistemas IA conversacionales con la capacidad de comprender y responder instrucciones en lenguaje humano. En cuanto a DALL-E 2 es otro modelo avanzado de IA generativa, también creado por OpenAI, especializado en generar imágenes de alta calidad a partir de instrucciones escritas (Cao, Y. et al., 2023).




Figura 2 Ejemplos de generación de imágenes a partir de instrucciones en lenguaje natural mediante DALL-E 2. Fuente: <https://arxiv.org/pdf/2303.04226>.

Cao, Li, Liu, Yan, Dai, Yu y Sun (2023) presentan una revisión académica detallada sobre la evolución de la inteligencia artificial generativa. Si bien el concepto de IA generativa no es nuevo, los principales avances en los más modernos sistemas de IA generativa son el resultado del entrenamiento de modelos generativos más sofisticados sobre grandes volúmenes de datos, el uso de arquitecturas basadas en modelos fundacionales y la posibilidad de acceso a mayores recursos computacionales para el procesamiento.

Los orígenes de los modelos generativos se remontan a la década de 1950, con el desarrollo de los modelos como HMMs (*Hidden Markov Models*) y GMMs (*Gaussian Mixture Models*). Estos modelos eran capaces de generar datos secuenciales como la voz o series temporales. Con la revolución del aprendizaje profundo estos modelos lograron aumentar su ampliamente su rendimiento (Cao, Y. et al., 2023)

La aplicación del aprendizaje profundo y de los modelos de inteligencia artificial generativa ha tenido un gran impacto en los campos del procesamiento del lenguaje natural (NLP) y la visión por computadora, impulsando avances significativos en ambas áreas.

Un habilitador clave para el avance de los distintos modelos generativos resultó ser la arquitectura Transformer (*transformer architecture*). Esta arquitectura fue presentada por primera vez en 2017 por el investigador Vaswani, inicialmente para el área de procesamiento del lenguaje natural (NLP). Sin embargo, su uso se extendió rápidamente a otros dominios, como la visión por computadora, convirtiéndose en el estándar predominante para la mayoría de los modelos generativos (Cao, Y. et al., 2023).

El estado del arte respecto a lo más avanzado en modelos generativos como GPT-3, DALL-E-2, Codex y Gopher utilizan la arquitectura de Transformer como su estructura principal.

En su revisión académica, Yenduri et al.(2023) describen como la arquitectura de transformer utilizada en GPT representa un avance significativo respecto a enfoques anteriores. Esto debido a que se utiliza un mecanismo de autoatención (*self-attention*) que permite al modelo considerar el contexto de toda la oración al generar la siguiente palabra, lo que mejora su capacidad para comprender y generar lenguaje. Otra gran ventaja de la arquitectura de transformer es que permite

un alto grado de paralelización, lo que la hace especialmente adecuada para procesos de pre-entrenamiento a gran escala.

Los modelos de lenguaje pre-entrenados son la opción predominante desde la adopción de la arquitectura de transformer (Cao, Y. et al., 2023)

Además de los avances en la arquitectura, el aumento en la capacidad de cómputo y el crecimiento en el volumen de datos disponibles para el entrenamiento han permitido una rápida evolución de los modelos. Por ejemplo, la estructura principal o *framework* de GPT-3 se mantiene similar a la de GPT-2; sin embargo, el conjunto de datos utilizado para su entrenamiento aumentó de 38 GB a 570 GB, y el tamaño del modelo fundacional pasó de 1.500 millones a 175.000 millones de parámetros. Esto permitió que GPT-3 tenga una mayor capacidad de generalización que GPT-2 en muchas tareas, como por ejemplo, identificar con mayor precisión la intención humana. (Cao, Y. et al., 2023)

Adicionalmente al aumento en el volumen de datos y en la capacidad de cómputo, los investigadores también han explorado formas de integrar nuevas tecnologías en los algoritmos de inteligencia artificial generativa. Por ejemplo, ChatGPT utiliza aprendizaje por refuerzo basado en retroalimentación humana (RLHF) para seleccionar la respuesta más adecuada ante una instrucción proporcionada, lo que permite mejorar continuamente la precisión del modelo. (Cao, Y. et al., 2023)

El avance de los modelos generativos también dio origen a una nueva forma de interacción con ellos, el *prompt learning*, una técnica que permite guiar su comportamiento a través de instrucciones específicas.

Subsección 1.3: Ámbitos de aplicación de la IA generativa

En el estudio sobre inteligencia artificial generativa (Cao et al., 2023) se destaca el papel de la técnica de prompt learning, o aprendizaje mediante instrucciones, en el contexto del uso de grandes modelos de lenguaje preentrenados (large language models, LLMs). Según explican los autores, esta técnica propone guiar a los modelos ya entrenados mediante instrucciones especialmente diseñadas (denominadas prompts), en lugar de reentrenarlos desde cero. Hay autores que proponen aplicar principios de la ingeniería de software al diseño y mantenimiento de prompts, lo que permitiría mejorar el mantenimiento y adaptación de los modelos a distintos usos (Clarísó & Cabot, 2023).

Este cambio de paradigma ha facilitado la expansión de la inteligencia artificial generativa hacia una variedad de dominios de aplicación. Uno de los más relevantes es el de los asistentes conversacionales o chatbots, como Xiaoice, desarrollado por Microsoft, que combina procesamiento de lenguaje natural y análisis de sentimientos para lograr interacciones que contemplen el estado emocional de los usuarios.

El estudio de Cao también destaca un avance significativo en el campo artístico, con modelos como DALL-E, Jukebox o AIVA, capaces de generar imágenes, música y composiciones creativas a partir de instrucciones en lenguaje natural. Sin embargo, su aplicación en el ámbito creativo ha generado gran controversia. Como señala Anand et al. (2023) en el artículo *Generative AI Has an Intellectual Property Problem*, publicado en Harvard Business Review, esta tecnología plantea interrogantes sobre la autoría y la legitimidad cultural de las obras generadas. Además, existen preocupaciones legales relacionadas al uso de materiales protegidos por derechos de autor en el entrenamiento de estos modelos, muchas veces sin el obtener el consentimiento explícito de los creadores.

En el ámbito de la programación, herramientas como Codex y CodeParrot asisten a desarrolladores mediante generación automática de código y sugerencias personalizadas, lo que mejora la productividad y facilita el aprendizaje (Cao et al., 2023). En esta misma línea, otros estudios académicos han demostrado que los chatbots de IA aplicados a la enseñanza de programación permiten una asistencia personalizada, promoviendo una mejor comprensión de conceptos complejos y fomentando la autonomía del estudiante en el proceso de aprendizaje (Gómez & Pérez, 2024).

Subsección 1.4: Desafíos que enfrenta la IA Generativa

Seguridad:

Uno de los problemas recurrentes en la inteligencia artificial generativa es la veracidad del contenido que produce.

Los modelos de inteligencia artificial generativa pueden generar información falsa o inventada, existe un fenómeno conocido como *alucinación de conocimiento*. Esto ocurre porque el modelo predice basado en patrones previamente aprendidos y estos patrones pueden conducir a errores. Por ejemplo, aunque las respuestas generadas por ChatGPT suelen parecer siempre coherentes y razonables, muchas veces no son del todo confiables. El modelo puede generar respuestas incorrectas o incluso absurdas, lo que representa un riesgo importante en la difusión de información falsa en internet (Cao, Y. et al., 2023).

El problema de veracidad del contenido generado no se limita al procesamiento del lenguaje natural, también se evidencia en el ámbito de la visión por computadora. Por ejemplo, el modelo *Stable Diffusion*, es reconocido por su alto rendimiento y capacidad para generar imágenes de alta calidad, sin embargo presenta dificultades a la hora de representar manos humanas de manera realista (Cao, Y. et al., 2023).

Sesgos & toxicidad:

Diversos estudios han abordado los problemas de toxicidad y falta de imparcialidad en los contenidos generados por inteligencia artificial, entre los que se incluyen respuestas con sesgos, reproducción de estereotipos y propagación de desinformación.

Según la investigación de Navigli, Conia y Ross (2023) estos sesgos son causados por la selección de datos de entrenamiento y se manifiestan en distintos sesgos sociales, como género, edad, orientación sexual, etnia, religión, etc.

Los autores proponen conceptualizar y medir estos sesgos mediante la definición de métricas que permitan identificar los sesgos y entender si están presentes en los datos de entrenamiento, durante el pre-procesamiento, o surgen en las respuestas generadas por el modelo de lenguaje (Post-procesamiento). Una vez medido, sugieren aplicar técnicas de corrección centradas en el diseño del dominio de datos y ajuste de parámetros: por ejemplo generar variaciones de ejemplos subrepresentados para equilibrar la distribución de raza, sexo, etc. En sí, se promueve incorporar desde la etapa del diseño los principios de diversidad y equidad.

Dificultades de adopción en contextos de alto riesgo

La aplicación de contenido generado por inteligencia artificial en contextos de alto riesgo, como la salud, los servicios financieros, los vehículos autónomos y el descubrimiento científico, sigue representando un desafío. Esto se debe a que en estos ámbitos las tareas son críticas y exigen un altísimo nivel de precisión, confiabilidad, transparencia y una tolerancia al error prácticamente nula. Por eso, es fundamental que los modelos generativos utilizados en estos contextos incorporen

puntuaciones de confianza, explicaciones sobre el razonamiento seguido y referencias a las fuentes utilizadas. En estos casos, los profesionales deben comprender claramente cómo se generaron los resultados y de dónde provienen, para poder utilizar estas herramientas con mayor seguridad y responsabilidad (Cao, Y. et al., 2023).

Aprendizaje continuo y necesidades de reentrenamiento.

Cao et al. (2023) afirma que dado que el conocimiento humano evoluciona constantemente y aparecen nuevas tareas de forma continua, los modelos generativos deben ser capaces de incorporar nueva información para generar contenido actualizado.

De acuerdo con Navigli, Conia y Ross (2023) existe un sesgo de selección que surge por el “tiempo de creación” de los textos utilizados en el entrenamiento de los modelos de lenguaje. Dado que el lenguaje evoluciona y las palabras pueden cambiar su significado a lo largo del tiempo, resulta fundamental incluir información reciente, sobre todo en aquellas tareas que dependen de contar con el contexto de eventos actuales. En ciertos casos, esto puede lograrse mediante el aprendizaje continuo aplicado a tareas específicas, sin necesidad de modificar el modelo fundacional preentrenado. No obstante, en otras situaciones, es necesario realizar un reentrenamiento completo del modelo, lo cual puede implicar un alto costo en términos de recursos y tiempo.

Razonamiento.

Una de las debilidades de los modelos actuales de inteligencia artificial generativa es su tendencia a fallar en tareas que requieren razonamiento básico o sentido común. Este problema ha captado la atención de muchos investigadores que buscan soluciones efectivas.

En línea a lo planteado en la investigación académica de Cao, Y., Smith y colaboradores (2023) una propuesta reciente en este ámbito es el enfoque *Chain of Thought* (CoT) prompting, diseñado para enseñar a los modelos el proceso lógico de razonamiento que seguiría una persona para llegar a una respuesta, con el objetivo de que la inteligencia artificial pueda imitar ese camino mental de manera más precisa.

Escalabilidad

La escalabilidad en el entrenamiento de grandes modelos de lenguaje continúa siendo un desafío importante, ya que está condicionada por el presupuesto computacional, la disponibilidad de datos y el tamaño del modelo. A medida que el tamaño del modelo crece, también se incrementa el tiempo y los recursos requeridos necesarios para entrenarlos.

Subsección 1.5: Diferencia entre IA tradicional e IA generativa

Como se ha revisado previamente, la inteligencia artificial es una disciplina orientada al desarrollo de sistemas capaces de imitar el comportamiento humano en la resolución de tareas. Uno de sus enfoques tradicionales es la IA predictiva, la cual utiliza algoritmos como el “*Machine Learning*” o aprendizaje automático. Este enfoque se basa en la construcción de modelos capaces de “aprender” a partir de patrones detectados en los datos con los que han sido previamente entrenados. (IBM, 2024)

La IA predictiva contribuye a la toma de decisiones empresariales más inteligentes al facilitar tareas como la planificación estratégica, la proyección de ventas, la estimación de la demanda de productos, la recomendación personalizada y la optimización de procesos logísticos. Su capacidad para anticipar escenarios y tendencias permite mejorar la eficiencia operativa y la experiencia del cliente.

Por su parte, la IA generativa se centra en la creación de contenido original, como texto, audio, imágenes, código o video, a partir de instrucciones o indicaciones proporcionadas por el usuario.

Si bien tanto la inteligencia artificial predictiva como la generativa forman parte del campo de la inteligencia artificial, se trata de enfoques distintos que abordan problemáticas desde diferentes metodologías.

La IA generativa se entrena utilizando grandes volúmenes de datos no estructurados y se basa en modelos fundacionales (*foundation models*), una categoría de modelos de aprendizaje profundo. Dentro de estos, los *Large Language Models* (LLMs) son los comúnmente utilizados para la generación de texto. Debido al alto costo en este entrenamiento en general, la implementación de soluciones con IA generativa se basa en el uso de estos modelos ya pre-entrenados (Garza Ulloa, 2024).

Por el contrario, la IA predictiva trabaja con conjuntos de datos más pequeños y específicos, los cuales se utilizan como insumo para entrenar modelos enfocados en tareas concretas, como la clasificación, segmentación o predicción (Garza Ulloa, 2024).

En cuanto a los algoritmos y arquitecturas utilizadas, la IA generativa se basa principalmente en arquitecturas como los *transformers* y las redes generativas antagónicas (*Generative Adversarial Networks*, GANs), que permiten la generación de contenido a partir de patrones aprendidos. Por otro lado, en la predictiva se utilizan distintos algoritmos estadísticos y modelos de *machine learning*, tales como modelos de clasificación, árboles de decisión, regresiones y análisis de series temporales, orientados a predecir resultados a partir de un conjunto de datos históricos.

Respecto a la explicabilidad, la mayoría de los modelos de IA generativa presentan una baja transparencia, es decir que resulta muy complejo comprender el proceso decisorio detrás de los

resultados generados. En cambio, en los modelos de IA predictiva los resultados pueden ser explicados en función de las técnicas estadísticas y algoritmos utilizados. (IBM, 2024)

Subsección 1.6: Impacto de la IA generativa en el campo de procesamiento del lenguaje natural (NLP)

La comprensión y generación del lenguaje ocupa un rol central en la investigación en inteligencia artificial. El campo de estudio que se ocupa de abordar estos desafíos es el procesamiento del lenguaje natural (*NLP - Natural Language Processing*), que, junto con otras disciplinas como el reconocimiento automático de voz (*ASR - Automatic Speech Recognition*) y la conversión de texto a voz (*TTS - Text to Speech*), tiene como propósito dotar a las computadoras de la habilidad de comprender y generar lenguaje humano, de forma similar a como lo hacen las personas.

El NLP ha sido el área de mayor impacto desde la aparición de los modelos fundacionales. Los primeros modelos, como ELMo (2018) y BERT (2019), demostraron una gran capacidad para adaptarse a una variedad de contextos lingüísticos y resolver muchos diferentes tipos de tareas (Rishi Bommasani, 2022).

Históricamente, el enfoque tradicional en el procesamiento del lenguaje natural (NLP) consistía en diseñar sistemas específicos para cada tarea lingüística, como análisis sintáctico, clasificación de sentimientos o clasificación de palabras o frases (predecir si es un verbo o un sustantivo). Cada una de estas tareas requería el diseño y desarrollo de una arquitectura específica.

En cambio, los modelos fundacionales introducen un enfoque totalmente diferente. En lugar de desarrollar sistemas específicos para cada tarea, se parte de un único modelo base pre-entrenado, que luego se adapta según el objetivo a resolver. Este enfoque ha demostrado ser superior al paradigma previo y altamente efectivo para la mayoría de las tareas lingüísticas. Por ejemplo, hasta 2018, el mejor sistema disponible para responder preguntas abiertas de ciencias obtuvo un puntaje del 73,8 % en el examen de ciencias de octavo grado del NY Regents. Un año después, en 2019, un modelo fundacional base adaptado logró una puntuación del 91,6 % (Rishi Bommasani, 2022).

También se ha producido un cambio importante en la habilidad de las máquinas de generar lenguaje. Hasta 2018, abordar este tipo de tareas con la tecnología disponible resultaba extremadamente difícil o, en muchos casos, prácticamente inviable.

Capítulo 2: IA Generativa en Atención al cliente

Subsección 2.1: El rol estratégico de la inteligencia artificial en las organizaciones

La inteligencia artificial, junto con la digitalización y la transformación digital, constituye un factor fundamental para la generación de ventajas competitivas en las organizaciones. Su implementación tiene un impacto significativo en el crecimiento y el desarrollo económico de las empresas (Yevsieieva-Severyna, I. & Skopenko, N., 2022).

Durante la pandemia de COVID-19, el desarrollo de la IA avanzó más rápido que nunca. Las empresas utilizan más algoritmos y herramientas de IA para reconstruir y mejorar sus operaciones comerciales; por ejemplo, proporcionan instrucciones de voz para completar tareas complejas, utilizan chatbots y automatización robótica de procesos (RPA).

La adopción de IA en las organizaciones permite lograr impactos positivos en múltiples dimensiones de negocio. Según una encuesta global de McKinsey (2020), sobre inteligencia artificial el 50% de las organizaciones ya implementan IA en al menos una función, siendo las más comunes la atención al cliente, el marketing, las ventas y el desarrollo de productos.




Figura 3 Uso de IA en actividades funcionales. Fuente: *Generative artificial intelligence: Opportunities and risks*, S. Kniazieva y S. Kniaziev, 2022, *The Problems of Economy*, p75
http://tppe.econom.univ.kiev.ua/data/2022_45/zb45_07.pdf. © 2022 The Problems of E

Las empresas que adoptan esta tecnología obtienen diversos beneficios, como la reducción de costos operativos, la disminución de errores humanos y un incremento en los ingresos. Estos efectos se ven reflejados en los resultados de una encuesta global realizada por McKinsey




Figura 4 Disminución de costos atribuida a la adopción de IA. Fuente: *Generative artificial intelligence: Opportunities and risks*, S. Kniazieva y S. Kniaziev, 2022, *The Problems of Economy*, p76
http://tppe.econom.univ.kiev.ua/data/2022_45/zb45_07.pdf. © 2022 Th

Según Yenduri et al. (2023), la IA generativa y modelos como GPT han mostrado un gran impacto en múltiples industrias y sectores a través de diversos casos de uso, confirmando su viabilidad tanto técnica como económica.

Se prevé que la industria global de la inteligencia artificial crezca de 59.700 millones de dólares en 2021 a 422.400 millones de dólares en 2028, según Zion Market Research. Prácticamente todas las industrias se ven afectadas por la IA, la automatización y la robótica. Ya sea aprendizaje automático, aplicaciones y electrodomésticos inteligentes, asistentes digitales o vehículos autónomos, las empresas que no invierten en productos y servicios de IA corren el riesgo de perder competitividad (Yevsieieva-Severyna, I. & Skopenko, N., 2022).

En este contexto, resulta valioso analizar las oportunidades que la inteligencia artificial generativa ofrece en los procesos de atención al cliente, así como su potencial impacto en la experiencia del usuario, la eficiencia operativa y las posibles alternativas de aplicación.

Subsección 2.2: Atención al cliente en la era digital

La atención al cliente, o *Customer Service*, ha evolucionado constantemente a lo largo del tiempo. Sus orígenes se remontan a la Revolución Industrial, cuando surgió la necesidad de establecer los primeros mecanismos de asistencia a los consumidores. En ese entonces, las opciones de contacto estaban limitadas a la atención presencial y la correspondencia por carta (Fullview, 2023).

Con el avance de la tecnología, los medios de comunicación se ampliaron. La masificación del teléfono permitió a las empresas conectar con sus clientes de una forma mucho más sencilla y eficiente.

La expansión de internet dio lugar a una nueva etapa, habilitando canales digitales como el correo electrónico y, posteriormente, otras plataformas que ampliaron las posibilidades de comunicación entre empresas y consumidores.

Con el auge de las redes sociales y las aplicaciones de mensajería, los clientes comenzaron a demandar una atención cada vez más disponible, exigiendo respuestas rápidas y personalizadas a sus necesidades. En la actualidad, esta situación plantea a las organizaciones el desafío de adoptar soluciones que permitan automatizar la atención sin descuidar la experiencia del cliente.

En este contexto, los chatbots surgieron como una herramienta clave para integrarse a aplicaciones de mensajería, como WhatsApp.

En el estudio de Yanduri et. al (2023), se describe cómo modelos de lenguaje como GPT pueden ser utilizados en aplicaciones de atención al cliente para generar respuestas en lenguaje natural mediante chatbots, atender preguntas frecuentes de forma coherente y brindar experiencias personalizadas a través de análisis de sentimientos, publicidad adaptada a cada cliente y recomendaciones optimizadas.

No obstante, los autores señalan como principales desafíos: garantizar la coherencia del contenido generado con la marca, proteger la privacidad y la ética en el uso de datos, controlar sesgos y mejorar la interpretabilidad de los resultados.

Subsección 2.3: Importancia estratégica de la Atención al cliente

De acuerdo con los principios del marketing, retener a un cliente existente resulta mucho más económico que captar uno nuevo. Por eso, es estratégico impulsar iniciativas enfocadas en lograr una atención al cliente eficiente, que contribuya a fomentar la fidelidad de los clientes (Kumar, 2022).

En los centros de atención con baja inversión tecnológica, los empleados enfrentan limitaciones que dificultan brindar una atención eficiente y con tiempos de respuesta adecuados. Esta situación impacta negativamente tanto en la satisfacción del cliente como en la retención del personal,

debido al estrés que enfrentan en su labor. Según un estudio de Gartner, la tasa promedio de rotación entre los representantes de atención al cliente debido a esta causa alcanza el 25% en las organizaciones.


Frente a estos desafíos, las organizaciones se ven motivadas a explorar soluciones tecnológicas que permitan mejorar tanto la eficiencia operativa como la experiencia del cliente.

Subsección 2.4: IA generativa en atención al cliente y aplicación en sector Telco

La IA generativa tiene el potencial para transformar el servicio y la asistencia al cliente hacia 2028 (Gartner, 2023).

En el informe de Gartner *Hype Cycle for Customer Service and Support Technologies, 2023*, esta tecnología se ubica en el punto más alto del ciclo de expectativas. Esto se corresponde con la enorme promesa respecto al potencial de distintos casos de uso como la automatización de tareas, la atención mediante chatbots con IA, la generación de contenido, la posibilidad de potenciar la productividad de los agentes humanos y optimizar la experiencia del cliente.

Al poder acceder a información más contextual y oportuna sobre cada cliente, esta tecnología permite facilitar a los agentes humanos no solo una resolución más ágil y personalizada de las consultas, sino también la detección de oportunidades de ventas cruzadas, generando un mayor valor para la organización.



Fuente: Gartner (agosto de 2023)

Figura 5 Hype Cycle de tecnologías para atención al cliente (Customer Service). Fuente: *Hype Cycle for Customer Service and Support Technologies, 2023*, Gartner. © 2023 Gartner, Inc.

Lin et al. (2024) describe el gran impacto de la IA generativa en el sector de las telecomunicaciones con casos de uso que van desde chatbots de atención al cliente hasta asistentes para técnicos de campo, diagnóstico de redes o uso de LLMs para consultar especificaciones técnicas complejas.

En el ámbito de la atención al cliente, los LLM facilitan la resolución de problemas con la facturación y la gestión de solicitudes según el historial y contexto de cada usuario, generando respuestas en lenguaje natural y aprovechando el análisis de sentimiento para garantizar buena satisfacción durante la atención. Un ejemplo es la plataforma “amAlz” de Amdocs que optimiza LLM genéricos con datos de facturas, pedidos y políticas internas para automatizar el servicio de facturación (Lin et al., 2024).

Para los técnicos de campo, herramientas como “Baioniq” de Quantiphi actúan como co-pilotos, resumiendo manuales técnicos y proponiendo soluciones en sitio que reducen la carga administrativa y mejoran la precisión de los diagnósticos. Por otro lado, productos como “SQL-GPT” de Kinetica permite consultar los registros de red en lenguaje natural y visualizar problemas sobre mapas, facilitando la planificación y optimización de la red (Lin et al., 2024).

Otro uso destacado que mencionan los autores es el empleo de chatbots con IA generativa que simplifican el acceso a complejos estándares técnicos. Por ejemplo el chatbot O-RAN de NVIDIA que consulta múltiple documentación de O-RAN (Lin et al., 2024).

Los autores señalan la necesidad de introducir conocimiento propio del dominio de las telecomunicaciones en las respuestas de los LLM, con el fin de reducir las alucinaciones y aumentar la precisión en escenarios reales.

Subsección 2.5: Casos de éxito en la aplicación de IA generativa en atención al cliente

Eneco eMobility: Implementación de IA generativa en la atención al cliente

Existen diversos casos de éxito relacionados a la adopción de inteligencia artificial generativa en las organizaciones. Un ejemplo concreto, es un caso de estudio publicado por la consultora Capgemini basado en la empresa Eneco eMobility (Capgemini, 2024).

Eneco eMobility, uno de los principales proveedores de infraestructura de carga para vehículos eléctricos en Países Bajos y Bélgica, enfrentó un crecimiento acelerado de su base de clientes que derivó en un incremento sostenido de solicitudes de soporte, lo que puso en estado de alerta la capacidad operativa de los canales de atención existentes. El desafío consistía en poder escalar la capacidad del servicio, para no deteriorar la calidad de la experiencia brindada, bajo la restricción de no aumentar la dotación de agentes humanos disponibles.

La empresa ya contaba con una plataforma CRM consolidada (Microsoft Dynamics 365), y sobre esa base tomó la decisión de incorporar capacidades de inteligencia artificial generativa mediante la integración de Copilot, una solución de Microsoft que permite asistir a los agentes mediante generación automática de texto, respuestas y resúmenes. Esta elección se tomó considerando los servicios tecnológicos disponibles, de forma que se pudiera minimizar los costos de adopción.

Durante la implementación se requirió abordar desafíos tanto técnicos como organizacionales. Desde el punto de vista técnico, fue necesario instruir a los modelos de IA generativa para que respondiera a contextos específicos del negocio energético, entrenándolos con datos históricos de atención. A nivel organizacional, fue necesario adaptar los procesos de trabajo y capacitar a los equipos.

La estrategia adoptada se basó en automatizar las tareas repetitivas que usualmente realizaban los agentes humanos y en la incorporación de la inteligencia artificial como herramienta de soporte para acelerar la resolución de casos y permitir una atención más personalizada.

Esto permitió alcanzar destacados resultados:

- Redujo el tiempo de capacitación de los nuevos integrantes del equipo, pasando de 4hs a solo 1hs.
- Incrementó la satisfacción de los clientes, ya que *Copilot* podía ofrecer información relevante y personalizada para una mejor gestión de la relación con cada usuario.
- Una funcionalidad clave fue la habilitación de resúmenes automáticos de las conversaciones en vivo, lo que facilitó la transferencia de casos entre equipos y permitió ofrecer un soporte

más ágil y eficiente. Gracias a esto, el tiempo promedio de resolución de casos se redujo en un 50%.

- Incorporó un chat inteligente capaz de responder consultas complejas, basado en el conocimiento generado a partir de casos ya resueltos.

El caso Eneco eMobility ejemplifica cómo la IA generativa puede integrarse para potenciar la productividad de los agentes humanos.

En ese sentido, Reinhard, Li, Peters y Leimeister (2024) en su investigación “*Generative AI in Customer Support Services*” proponen un marco de trabajo para identificar cómo la IA generativa puede mejorar la eficiencia y la calidad del servicio al cliente, determinando una serie de actividades dentro del ciclo de atención donde esta tecnología puede agregar valor.

Asignación, referencia y transferencia de tickets: la IA puede preprocesar los tickets, completar información faltante y clasificarlos correctamente, agilizando su asignación inicial y reduciendo los tiempos de enrutamiento.

Recomendaciones al asesor: basado en casos históricos y resúmenes automáticos de conversaciones, disminuyendo la sobrecarga de información.

Generación de contenido personalizado: la IA puede utilizarse para crear respuestas personalizadas, enriquecer descripciones, mejorar la documentación y facilitar la transferencia de conocimiento interno.

Bajo este enfoque, los autores muestran como la IA no reemplaza al agente humano, sino que trabaja en colaboración con él y redefine el alcance de su función hacia la gestión de contenidos y la supervisión de los sistemas automáticos en los procesos de atención.

Mejora de la experiencia del cliente con inteligencia artificial generativa en centros de contacto de servicios financieros

El estudio de Ganesan (2024) analiza cómo las instituciones financieras han comenzado a integrar la Inteligencia Artificial Generativa en sus *contact centers* con el objetivo de mejorar la experiencia del cliente. Esta tecnología permite automatizar respuestas, personalizar interacciones automáticas y optimizar procesos, facilitando una atención más ágil y satisfactoria.

El estudio describe que durante la implementación, se encontraron distintos desafíos que requirieron la toma de decisiones estratégicas. En el aspecto tecnológico, uno de los principales desafíos fue garantizar la integración con sistemas legados y la capacidad de la inteligencia artificial para gestionar consultas financieras complejas. Como respuesta, se optó por soluciones basadas en la nube, capaces de integrarse al ecosistema tecnológico existente.

En el ámbito regulatorio, uno de los puntos clave fue garantizar la protección de los datos sensibles. Este desafío se abordó mediante la adopción de protocolos estrictos de seguridad y cumplimiento

normativo. Adicionalmente, el equipo de desarrollo identificó la importancia de controlar posibles sesgos en las respuestas generadas por la IA.

La solución implementada fue diseñada para ofrecer respuestas personalizadas con foco en elevar los niveles de satisfacción. El estudio menciona que como resultado de esta implementación se obtuvieron importantes mejoras: aumento del 50% en la tasa de resolución en la primera llamada, reducción del 40% en los tiempos de atención y un incremento del 45% en la satisfacción del cliente.

Capítulo 3: Desafíos de la industria de Telecomunicaciones

Subsección 3.1: Diagnóstico de la industria

La industria de las telecomunicaciones atraviesa un contexto desafiante, en el que no ha logrado reactivar su crecimiento ni resolver sus problemas estructurales. En un artículo publicado por McKinsey en diciembre de 2024, se analiza el estado actual y las perspectivas futuras del sector, y se identifican las principales rutas posibles hacia el éxito. El informe sostiene que los obstáculos que enfrenta la industria son de carácter estructural y existencial, y superarlos requerirá transformaciones sin precedentes.

El retorno sobre el capital invertido (*Return on Invested Capital - ROIC*) en la industria se ha visto afectado por las elevadas inversiones necesarias para desarrollar y mantener las infraestructuras de telecomunicaciones. Al mismo tiempo, la rentabilidad para los accionistas ha disminuido de manera constante.


Al analizar los principales problemas que enfrenta el sector es posible agruparlos en tres grandes categorías:

- **Modelos de negocio tradicionales insuficientes** para generar la rentabilidad y el retorno necesario que permita sostener los altos niveles de inversión de capital. Para superar este desafío se requiere explorar nuevas fuentes de ingresos, como por ejemplo el establecimiento de acuerdos con proveedores de servicios de streaming y plataformas OTT, que contemplen el pago por el uso intensivo de conectividad, o el desarrollo de nuevos servicios B2B basados en la apertura de APIs.
- **Intensificación de la competencia.** El avance de nuevas tecnologías, como la e-SIM, ha reducido las barreras de entrada, facilitando la aparición de nuevos competidores. Al mismo tiempo, crecen los operadores móviles virtuales (OMV), que ingresan al mercado con propuestas agresivas y un enfoque digital. Como respuesta muchas empresas de telecomunicaciones podrían optar por fusiones y adquisiciones a gran escala, lo que podría producir una importante consolidación del mercado.
- **Creciente presión regulatoria.** Las difíciles condiciones económicas que enfrentan los consumidores podrían llevar a que los reguladores presionen cada vez más a la baja los ingresos promedio por usuario (*ARPU - Average Revenue Per User*) de las empresas de telecomunicaciones y establezcan controles más estrictos acerca del uso y la protección de datos de los clientes (McKinsey, 2024).

Según los resultados de la encuesta realizada por McKinsey a 60 ejecutivos C-Level de la industria, entre las preocupaciones más urgentes se destacan la rentabilidad, la competencia de nuevos modelos de negocio y las restricciones regulatorias.

Telco leaders identify profitability, new business models, and regulation as the most pressing issues for the future.

Number of telco C-suite executives citing issue as one of their top 3 concerns¹



¹Q: How would you rank your current most pressing urgencies?
Source: McKinsey Global Telco Executive Survey, Feb 2024 (n = 60)

McKinsey & Company

Figura 6 Principales preocupaciones identificadas por ejecutivos C-level del sector telecomunicaciones. Fuente: McKinsey & Company, 2024. © 2024 McKinsey & Company.

Además del enfoque estructural del sector planteado por McKinsey, el informe de EY “*Los 10 principales riesgos para las telecomunicaciones en 2024*” ofrece una mirada complementaria, centrada en los riesgos más inmediatos que enfrenta actualmente la industria, en particular relacionados con el contexto económico, social y regulatorio. Entre los más destacados se encuentran:

- **Subestimar las exigencias en materia de privacidad, seguridad y confianza:** La creciente preocupación por la privacidad de los datos y la seguridad cibernética, en particular con el auge de la inteligencia artificial generativa, obligará a las empresas a reforzar sus controles internos y fomentar la confianza de los clientes.
- **Respuesta insuficiente a los clientes durante la crisis del costo de vida:** Muchos hogares perciben una falta de apoyo por parte de las empresas de telecomunicaciones frente a la crisis económica. Casi la mitad de los consumidores considera que los aumentos de precios son difíciles de justificar, lo que podría llevar a un aumento en la rotación de clientes que

buscan ofertas más económicas.

- **Gestión inadecuada del talento y las habilidades:** Las restricciones financieras llevaron a muchas empresas a limitar las contrataciones y reducir los beneficios para sus empleados, lo cual dificulta la atracción y retención del talento necesario para avanzar en el proceso de transformación digital (Ernst & Young, 2024).

Subsección 3.2: Estrategias de transformación

Según McKinsey, existen tres caminos estratégicos que la industria puede seguir para alcanzar el éxito:


A. Reinventar el modelo de negocio

En opinión de los líderes de la industria, alcanzar este objetivo requiere un rediseño profundo del modelo operativo, promoviendo la eficiencia y la eficacia a través de la adopción de tecnologías digitales.

La tecnología digital, la IA / IA Generativa, los datos y la automatización deben estar en el centro de todas las funciones empresariales. Esto permitirá construir una organización más flexible y centrada en el cliente. Según estudios de McKinsey, una transformación holística puede incrementar los ingresos hasta un 8% anual, reducir los costos del servicio entre un 10% y un 15% y mejorar la satisfacción del cliente entre 20 y 40 puntos (McKinsey, 2024).

Critical levers for value creation include digital technologies, organizational transformation, investment sharing/capex efficiency, and B2B growth.

Share of telco C-suite executives citing lever as most important for future value creation,¹ %



¹Q: How would you rank the top 3 levers you are trying to deploy for value creation?
Source: McKinsey Global Telco Executive Survey, Feb 2024 (n = 60)

McKinsey & Company

Figura 7 Palancas estratégicas identificadas por ejecutivos C-level del sector telecomunicaciones. Fuente: McKinsey & Company, 2024. © 2024 McKinsey & Company.

Otra palanca clave es fomentar los modelos de colaboración en grandes inversiones. El *Network sharing* puede ayudar a reducir entre 15% y 40% del gasto de capital requerido. Un ejemplo de este enfoque es el caso de Malasia, donde el gobierno ha creado un operador de red mayorista independiente para diseñar, construir, operar y mantener la única red 5G del país, de la cual diferentes operadores comparten la capacidad. Se estima que, de haber desarrollado su propia infraestructura, a las empresas de telecomunicaciones les habría costado entre un 30 % y un 60 % más que mediante el operador de red mayorista.

B. Abandonar el modelo tradicional de telecomunicaciones integradas

Romper con el modelo tradicional de telecomunicaciones integradas y avanzar hacia una separación en múltiples unidades independientes es una estrategia cada vez más adoptada en el sector. Lo más habitual es separar la unidad de servicios, denominada “ServCo”, de la

infraestructura de red, conocida como “NetCo” o “InfraCo”, la cual luego puede transformarse en un proveedor mayorista de acceso neutral para distintos operadores. Esta segmentación permite lograr una mayor transparencia y especialización, atraer inversiones específicas y mejorar la agilidad operativa (McKinsey, 2024).

C. Transición a un modelo de negocio y operativo similar al de una empresa de servicios públicos

Según la visión de muchos líderes del sector, si el mercado de las telecomunicaciones no va a crecer a un ritmo superior al PBI, lo más razonable sería adoptar una lógica de eficiencia por sobre crecimiento, similar a los servicios públicos. Otra alternativa posible sería avanzar hacia una integración con estas empresas, llegando a conformar una única unidad operativa (McKinsey, 2024).

Capítulo 4: Consideraciones éticas y regulatorias de la Inteligencia Artificial

A medida que crece el rol e impacto de la inteligencia artificial (IA) en la sociedad, también aumentan las preocupaciones en torno a los riesgos, así como a las implicancias éticas y de responsabilidad asociadas con su implementación.

En este contexto, los marcos legislativos de distintos países enfrentan el desafío de establecer regulaciones adecuadas para una tecnología en constante evolución.

La investigadora Miriam C. Buiten, especialista en inteligencia artificial y derecho, ha publicado un artículo en el que analiza las dificultades que implica legislar sobre esta tecnología.

La primera dificultad está asociada al problema de definir qué es la inteligencia artificial. No existe una definición única y aceptada, lo que convierte a la IA en una base inadecuada para la regulación (Buiten, M. C., 2019).

Algunas definiciones ponen el foco en la autonomía de las máquinas; otras, en su capacidad para imitar la inteligencia humana. Sin embargo, estas definiciones son ambiguas y su interpretación varía según quién las analice, e incluso puede cambiar con el tiempo. La falta de un alcance claro y delimitado generaría incertidumbre en la industria sobre si sus actividades están o no alcanzadas por la regulación.

La autora propone “abrir la caja negra”; es decir, enfocar la atención en los algoritmos subyacentes en lugar de en la tecnología per se. Esto permitiría estudiar los riesgos de manera más concreta y operativa.

La complejidad de los algoritmos puede variar desde reglas básicas y limitadas hasta sistemas mucho más complejos, como los algoritmos de aprendizaje automático, en los que el propio algoritmo aprende reglas y construye modelos de decisión a partir de los datos de entrenamiento. En este tipo de modelos, resulta muy difícil explicar cómo se llega a una determinada predicción.

Resulta conveniente analizar los posibles problemas de sesgo en los algoritmos examinando los principales factores que influyen en su capacidad para tomar decisiones. Estos factores son: los datos utilizados, el método de prueba o testeo, y el modelo de decisión que se aplica.

Towards Intelligent Regulation of Artificial Intelligence




Figura 8 Esquema del proceso de aprendizaje automático y evaluación de desempeño del modelo. Fuente: *Towards intelligent regulation of artificial intelligence*, M. C. Buiten, 2019, <https://doi.org/10.1017/err.2019.8>. © 2019 Cambridge University Press.

Datos de entrenamiento (Training data): Los datos pueden estar basados en muestras sesgadas, ya sea por un error en el diseño o porque reflejan desigualdades sociales preexistentes. Por ejemplo, la falta de representación de mujeres en determinados puestos de trabajo podría llevar a que un algoritmo genere una regla que favorezca a candidatos varones.

Testeo (Testing): Existe el riesgo de que la prueba o testeo de un algoritmo no se realice en un entorno realista o suficientemente diverso, lo que podría reproducir los mismos problemas de sesgo presentes en los datos utilizados para el entrenamiento.

Modelo de decisión: Evitar el sesgo o la discriminación no es tan simple como eliminar las variables sensibles que podrían influir en la decisión del modelo. En algoritmos avanzados, como las redes neuronales, el propio sistema puede generar discriminación indirecta al reconstruir correlaciones entre variables existentes, lo que dificulta la evaluación e identificación de fallas de manera sencilla.

Dado que explicar algoritmos complejos es técnicamente difícil y requiere una considerable inversión de tiempo, la autora sostiene que la exigencia de transparencia debe evaluarse en función del contexto específico de aplicación, analizando la viabilidad y la relación costo-beneficio de proporcionar la transparencia requerida.

En particular, las preocupaciones en torno a la inteligencia artificial generativa están relacionadas con el impacto que puede tener el contenido que produce en la sociedad. Los modelos de IA generativa podrían reproducir o incluso amplificar sesgos preexistentes de la

sociedad, lo que podría generar consecuencias negativas, como discriminación o desigualdad en procesos como la selección de personal, la aprobación de créditos o la toma de decisiones dentro del sistema judicial (Rishi Bommasani, 2022).

Otro aspecto preocupante es el uso del contenido generado por IA para crear y difundir *deepfakes*, que pueden utilizarse con fines maliciosos, como incitar a la violencia o dañar la reputación de personas y organizaciones (Rishi Bommasani, 2022).

Además, existen cuestionamientos en torno a posibles violaciones de derechos de autor y propiedad intelectual, así como a temas relacionados con la privacidad y la seguridad de los datos.

IA Generativa & GDPR

En relación al cumplimiento normativo, existe un conflicto entre las herramientas de IA generativa como ChatGPT y Dall-E y las leyes de protección de datos personales, como GDPR, de gran relevancia en el sector de telecomunicaciones (Ruscheimer, 2025).

Según describe Ruschemeier (2025), existen desafíos en la aplicación de estas leyes a los modelos de lenguaje (LLM). Mientras que GDPR establece minimizar el uso de datos, los LLM se basan en una recolección masiva de información. Por otro lado, la ley plantea delimitar la finalidad en el uso de los datos, siendo que los LLM suelen aplicarse a múltiples propósitos para los cuales no fueron concebidos desde el inicio.

La autora también señala la complejidad que existe en garantizar los derechos de los interesados, acerca del acceso, rectificación, supresión, oposición o portabilidad, en el contexto de LLM, considerando que estos pueden “memorizar” datos personales. La imposibilidad de identificar fragmentos específicos de textos con los que fueron entrenados dificulta atender el requerimiento normativo del derecho al olvido o portabilidad de la información.

Ruscheimer sostiene que, para conciliar el uso de IA generativa con leyes de protección de datos personales como GDPR, es necesario integrar la protección de datos desde el diseño (“*privacy by design*”) y realizar evaluaciones de impacto de forma frecuente en cada fase del ciclo de vida de la IA generativa (recolección, entrenamiento y puesta productiva).

INVESTIGACIÓN EMPÍRICA-DOCUMENTAL

Capítulo 5: Descripción del caso de estudio

Subsección 5.1: Presentación de la empresa

Con el objetivo de preservar el anonimato de la empresa analizada, en este trabajo se utiliza el nombre ficticio **InnovaTel**.

InnovaTel es una empresa argentina del sector telecomunicaciones que ofrece servicios de telefonía móvil, internet de banda ancha y televisión. Si bien mantiene una participación de mercado significativa, lo que la posiciona entre las compañías líderes del país, enfrenta importantes desafíos para mantenerse competitiva.

Dadas las restricciones financieras de la empresa en los últimos años, los planes estratégicos adoptaron un enfoque hacia la racionalización del mercado, donde se priorice la rentabilidad del parque de clientes por sobre el crecimiento. La empresa impulsó el avance de todas aquellas iniciativas que permitan mejorar la eficiencia operativa, la productividad y optimizar las operaciones comerciales.

En este contexto, los canales digitales adoptaron un rol protagónico al facilitar la gestión del relacionamiento con los clientes de forma más eficiente y a un menor costo, contribuyendo a reducir el *churn*, es decir la fuga, de clientes de alto valor.

Luego de la pandemia de COVID-19, la transformación digital de la compañía tomó un fuerte impulso, consolidando los canales digitales como una pieza clave en la estrategia de atención.

Subsección 5.2: Rol de WhatsApp en estrategia de relacionamiento Digital

Los principales canales digitales de atención de InnovaTel son su aplicación móvil y el canal de comunicación WhatsApp. A través de estos medios, los clientes pueden gestionar distintas necesidades relacionadas a sus productos, como consultar la factura, realizar un pago o un reclamo por inconvenientes técnicos.

El uso de WhatsApp en la compañía es relativamente nuevo y surge como respuesta a la necesidad de ofrecer al cliente un canal más accesible durante la pandemia de COVID-19, contexto en el cual la atención presencial se vio fuertemente afectada.

Los clientes valoran la facilidad de uso de WhatsApp, dado que es un canal de comunicación conocido y muy utilizado en la vida cotidiana por la mayoría de los argentinos.

Con el objetivo de avanzar en la automatización de la atención, InnovaTel desarrolló un bot conversacional que está integrado a este canal y tiene la capacidad de resolver de manera 100% autónoma muchas de las principales consultas de los clientes. Para aquellos casos en los que el bot no puede brindar una respuesta satisfactoria se permite la derivación a un agente humano, quien continúa la gestión por el mismo canal hasta completar la resolución.

Subsección 5.3: Bot conversacional en WhatsApp

La plataforma de Bot conversacional utilizada en el canal de WhatsApp es un producto desarrollado *in-house* por el equipo técnico de InnovaTel. Esta plataforma cuenta con una serie de casos de uso funcionales, entre los que se destacan:

- **Q&A:** Responde preguntas frecuentes de los clientes a partir de una base de conocimiento.
- **Casos de uso transaccionales:** Asiste en la gestión de consultas personalizadas y operaciones transaccionales, las cuales requieren integración con otros sistemas, como el sistema comercial. Ejemplos: consultar la factura, registrar un reclamo o visualizar el detalle del plan y los servicios contratados.
- **Envío de notificaciones:** Permite enviar comunicaciones proactivas al cliente, ya sean informativas o promocionales. Por ejemplo, notificar un beneficio o el vencimiento de una factura.
- **Intercanalidad:** Recibe tráfico derivado desde otros canales para continuar con una gestión en particular. Por ejemplo, un usuario que llama al IVR (sistema telefónico automatizado) y en ciertos escenarios, recibe una notificación invitándolo a continuar la gestión por WhatsApp. También puede darse el caso de una gestión iniciada en la aplicación móvil, que en cierto punto del flujo redirecciona al usuario al canal de whatsapp para poder concluir.

En cuanto a la interacción con el bot, esta puede realizarse a través de botones accionables de WhatsApp, que permiten guiar al cliente mediante un listado de opciones disponibles, o bien mediante la interpretación de lenguaje natural.

El uso de los botones permite ofrecer una experiencia más estructurada y controlar el flujo del diálogo, lo cual es muy útil para resolver gestiones frecuentes y predefinidas de manera sencilla y ágil. Por otro lado, la interpretación del lenguaje natural brinda mayor flexibilidad, facilitando que el cliente exprese sus necesidades de forma libre y conversacional, evitando que deba navegar entre distintas categorías y subcategorías de funciones.

Subsección 5.4: Talento humano y dinámica organizacional

Durante la pandemia de COVID-19, la necesidad de acelerar la digitalización y habilitar oficialmente el canal de WhatsApp exigió una acción rápida por parte de InnovaTel. En ese contexto y considerando los tiempos habituales de los procesos de licitación, sumado a la ausencia de un

presupuesto específico para este proyecto, se tomó la decisión de desarrollar una plataforma propia de forma in-house. La iniciativa fue impulsada por un grupo de colaboradores que ya venía investigando sobre el desarrollo de soluciones conversacionales y el campo del procesamiento del lenguaje natural (NLP).

Con el pasar del tiempo, la plataforma fue evolucionando en términos de robustez y capacidades funcionales. Unos años más tarde, InnovaTel inició un proceso de evaluación estratégica para definir el camino a largo plazo a seguir. Si adoptar una plataforma de mercado o continuar con el desarrollo de su solución interna. Luego de un análisis detallado de ventajas y desventajas, se optó por seguir evolucionando la plataforma interna.

Esta decisión estuvo acompañada por un plan de captación y desarrollo del talento humano necesario para sostener y escalar la solución. Entre los perfiles clave con los que hoy cuenta InnovaTel se destacan:

- **Desarrollador/a de bots conversacionales:** Responsable del desarrollo de nuevas capacidades en la plataforma y la implementación de flujos conversacionales.
- **Lingüista computacional:** Encargado de entrenar el modelo de comprensión del lenguaje del bot mediante la aplicación de técnicas de procesamiento de lenguaje natural (NLP).
- **Analista funcional:** Su rol consiste en traducir las necesidades del negocio en requerimientos funcionales, así como diseñar y coordinar integraciones entre la plataforma de bots y otros sistemas.
- **Especialista en UX conversacional:** Se ocupa de definir el tono, la personalidad y la experiencia general de la conversación, garantizando una buena experiencia en la interacción con el bot.
- **Product Owner:** Es quien actúa como nexo entre el negocio y el equipo técnico, gestionando el backlog del producto.

En cuanto a las dinámicas de trabajo, se adoptó un enfoque *agile*, organizando distintos equipos o “mesas de trabajo” orientados dar servicio sobre diversos focos estratégicos. Cada mesa cuenta con, al menos, un representante de cada uno de los perfiles previamente mencionados.

Subsección 5.5: Problemática y limitaciones actuales

A pesar de los esfuerzos que InnovaTel ha venido realizando para potenciar el canal de WhatsApp en su estrategia de relacionamiento y atención digital, aún persiste un desafío importante: la satisfacción de los usuarios que utilizan este canal no es lo suficientemente buena.

Esta situación limita las posibilidades de crecimiento y frena las intenciones de masificar aún más su uso y captar nuevos usuarios a través de este medio.

Los resultados obtenidos a partir de las encuestas de NPS y los comentarios de los clientes evidencian esta percepción negativa.

En este contexto, el presente trabajo se propone analizar en profundidad las causas de dicha insatisfacción y explorar alternativas de mejora, evaluando en particular el potencial de la inteligencia artificial generativa para mejorar la experiencia de este canal y definir una propuesta de implementación enfocada en cómo adoptar esta nueva tecnología, teniendo en cuenta las fortalezas y debilidades de la organización.

Capítulo 6: Fuente de datos y alcance

Subsección 6.1: Datos disponibles

Con el propósito de analizar el funcionamiento del canal de WhatsApp, se utilizarán las siguientes fuentes de datos:

- **Interacciones en el canal de WhatsApp:** Se cuenta con el registro completo de interacciones de clientes en el canal, incluyendo tanto las conversaciones con el bot como aquellas en las que intervino un agente humano. Para cada interacción es posible identificar el recorrido de casos de uso consultados y el tipo de experiencia gestionada.
- **Resultados de encuestas de satisfacción (NPS):** Se dispone de las calificaciones otorgadas por los clientes en relación con la atención recibida en el canal, con la posibilidad de distinguir entre las interacciones gestionadas exclusivamente por el bot y aquellas en las que intervino un agente humano. También se cuenta con comentarios realizados por los propios clientes, que permiten enriquecer el análisis.

La calificación sigue la metodología **NPS** (*Net Promoter Score*), basada en una escala de 1 a 10: Donde las puntuaciones de 1 a 6 se consideran detractores, las de 7 y 8 neutros, y las de 9 y 10 promotores.

Subsección 6.2: Tipos de experiencias en el canal en el canal de WhatsApp

Los usuarios que interactúan con el canal de WhatsApp pueden atravesar distintos tipos de experiencias, según el origen y la naturaleza de la interacción. A continuación, se describen las principales categorías identificadas:

1. **Demanda orgánica:** Corresponde a usuarios que acceden al canal de manera autónoma, por iniciativa propia, con el objetivo de gestionar alguna consulta, reclamo o necesidad puntual.
2. **Demanda inducida:** Se refiere a usuarios que interactúan con el canal en respuesta a un estímulo recibido, como una campaña promocional, un recordatorio de pago o una notificación informativa enviada por la empresa.
3. **Demanda por intercanalidad:** Incluye a aquellos usuarios que acceden al canal de WhatsApp como parte de un recorrido iniciado en otro canal. Por ejemplo, pueden haber sido derivados desde el sitio web, la aplicación móvil o el IVR (canal telefónico automatizado), con el fin de continuar o finalizar una gestión específica.

Subsección 6.3: Alcance

A continuación se detalla el alcance del análisis a realizar:

- Se analizarán datos correspondientes a un período de tres meses de funcionamiento del canal de WhatsApp. Enero, Febrero, Marzo y solo algunos días de Abril.
- El análisis incluirá todos los tipos de experiencias disponibles dentro de dicho canal, independientemente de su origen (demanda orgánica, inducida o por intercanalidad).
- No se contempla la evaluación de otros canales de relacionamiento con el cliente, como el IVR o la aplicación móvil.
- Se excluye del análisis el canal de WhatsApp utilizado por la compañía con fines de venta (eCommerce), enfocándose únicamente en aquellos canales orientados a la atención postventa (eCare).

La elección de este periodo se basa en la disponibilidad y relevancia de los datos durante este intervalo de tiempo. Se define un enfoque exclusivo sobre el canal de WhatsApp para procesos de eCare debido a su importancia estratégica en la atención digital de la compañía y al interés por explorar su potencial de mejora mediante la incorporación de inteligencia artificial generativa.

Subsección 6.4: Consideraciones éticas y de confidencialidad

Con el objetivo de preservar el anonimato de la empresa analizada, en este trabajo se utiliza el nombre ficticio InnovaTel. Toda la información utilizada será tratada con carácter confidencial.

Los datos utilizados en el análisis no contienen información personal identificable. Se garantiza su anonimización y el cumplimiento de principios éticos en el tratamiento de información sensible.

Este trabajo considera la importancia de considerar aspectos éticos y de seguridad relacionados con la adopción de tecnologías como la inteligencia artificial. Lo cual será abordado en el marco de la propuesta de implementación.

Capítulo 7: Metodología de análisis

Subsección 7.1: Descripción del tipo de análisis

Se llevará a cabo un análisis de datos cuantitativos, como ser métricas de interacción y clasificación NPS (promotores, neutros y detractores), en combinación con datos cualitativos, como los comentarios abiertos por parte de los clientes.

Los datos fueron previamente recolectados por la organización en el marco de su operación diaria, lo que permite trabajar con datos reales y representativos de los principales puntos de dolor a resolver.

Subsección 7.2: Metodología para identificación de oportunidades de mejora

Como parte del análisis, se buscará identificar los principales puntos críticos en la experiencia del cliente que podrían ser mejorados, con especial foco en aquellos casos donde la aplicación de inteligencia artificial generativa podría representar una solución de valor.

A partir de los datos disponibles se analizarán los principales patrones de insatisfacción y quiebres de experiencia del usuario, con el objetivo de plantear hallazgos y poder vincularlo con oportunidades concretas de mejora.

Capítulo 8: Análisis de datos

Se dispone del registro de conversaciones gestionadas a través del canal de atención por WhatsApp, junto con la calificación de satisfacción otorgada por los usuarios al finalizar el servicio.

El período analizado abarca desde el **1 de enero de 2025** hasta el **9 de abril de 2025**, e incluye un total de **129.527 conversaciones**.

El objetivo del análisis es comprender la diferencia en la experiencia de usuario entre aquellas interacciones que fueron 100% automáticas (gestionadas por el BOT) y aquellas que requirieron intervención humana (asistidas). Esta comparación busca identificar oportunidades de mejora en el *Net Promoter Score* (NPS) general del servicio, a partir de posibles optimizaciones en la experiencia ofrecida por el BOT.

Para ello, se evalúa el NPS desde distintas dimensiones:

- **NPS general del servicio en su totalidad.** Sin importar si las conversaciones fueron 100% automáticas o asistidas.
- **NPS exclusivo de conversaciones automatizadas** (sin intervención humana).
- **NPS en conversaciones asistidas**, donde participó un agente humano.

NPS General




Figura 9 NPS General del canal de whatsapp. Fuente: elaboración propia.

En la Figura 9 se presenta la evolución mensual del NPS del canal de atención por WhatsApp, considerando tanto las interacciones gestionadas completamente por el BOT como aquellas que incluyeron intervención humana (asistido).

Durante el período analizado, el NPS fue positivo oscilando entre un mínimo de 27% en febrero y un máximo de 34% en marzo.

NPS de Atención BOT




Figura 10 NPS de la atención del BOT en el canal de whatsapp. Fuente: elaboración propia.

La Figura 10 muestra la evolución del NPS en las conversaciones que fueron gestionadas de manera 100% automática, sin intervención humana.

Durante el periodo analizado, el NPS del BOT se mantuvo en valores negativos, con una leve mejora en marzo.

Si bien se observa una tendencia a la mejora, **los valores negativos indican una experiencia insatisfactoria para las interacciones exclusivamente gestionadas por el BOT.** Este resultado refuerza la hipótesis de que existen oportunidades concretas de mejora en la experiencia proporcionada por el BOT.

NPS de Atención Asistida




Figura 11 NPS de la atención asistida en el canal de whatsapp. Fuente: elaboración propia.

La Figura 11 presenta la evolución del NPS correspondiente a las conversaciones que requirieron intervención humana. En comparación con la atención 100% automatizada, los valores son mucho más altos, reflejando una experiencia más satisfactoria por parte de los usuarios.

Durante el período analizado, el NPS se mantuvo en valores positivos, iniciando en 43% en enero, con una leve caída en febrero (40%) y una recuperación en marzo y abril.

Estos resultados indican que la atención asistida compensa la deficiente experiencia del canal automatizado. Al comparar la gran distancia que existe con el NPS negativo del BOT, se valida la oportunidad clara de mejorar la calidad de atención en las conversaciones automáticas para contribuir a mejorar el NPS E2E del servicio.

Análisis de comentarios de las encuestas de NPS

Con el objetivo de comprender en mayor profundidad el feedback que sustenta las calificaciones, se realizó un análisis cualitativo de los comentarios registrados por los usuarios que completaron las encuestas de satisfacción. A continuación, se compara la “voz del cliente” en conversaciones gestionadas exclusivamente por el BOT vs aquellas con intervención humana, segmentando los resultados según el tipo de usuario: promotor o detractor.

De acuerdo con la metodología de Net Promoter Score (NPS), un usuario es considerado promotor cuando califica al servicio con puntajes 9 y 10, mientras que se clasifica como detractor a quienes califican con una puntuación igual o inferior a 6.

Para poder evaluar los comentarios registrados, se realizó un análisis de coocurrencias de palabras, con el objetivo de identificar los términos más frecuentes y las relaciones semánticas entre ellos.

Esta técnica permite obtener una visión general de los principales tópicos mencionados por los usuarios y de los problemas recurrentes que destacan dentro del grupo analizado.

Periodo analizado: 01 de enero 2025 al 9 de abril de 2025

Análisis de coocurrencia - Tabla metodológica			
	Descripción	Fuente/Datos	Herramienta utilizada
Base de comentarios NPS	De la base total de comentarios se filtraron aquellos clasificados como "detractores".	Base interna de NPS (export CSV)	Export en CSV desde BBDD de NPS
Nº de comentarios procesados	Total de comentarios procesados: 36.539 # Detractores en Asistido: 19.832 # Detractores en BOT: 16.707	-	
Periodo	1 de enero 2025 al 9 de abril 2025	-	
Pre-procesamiento	Tokenización, normalización de texto (minúscula, signos, etc) y eliminación de "stopword" en español.	BBDD comentarios detractores (CSV)	Librería NLTK en Python
Análisis de coocurrencias	Se procesa una matriz binaria de documento-término incluyendo términos presentes en al menos 3 documentos. Se establece un límite de 300 más frecuentes. A partir de esta matriz resultado se genera matriz de coocurrencia con aquellos pares mayor a 0.	Comentarios preprocesados	Scikit-learn 1.2, pandas 1.5 <i>CountVectorizer(min_df=3, max_features=300, binary=True)</i>
Visualización del grafo	Se grafica coocurrencias, donde cada nodo es una palabra.	Análisis de coocurrencias	NetworkX v2.6, Matplotlib 3.5
Resultado [1]	Figura 12 : Gráfico de coocurrencias en comentarios detractores del BOT.		
Resultado [2]	Figura 16: Gráfico de coocurrencias en comentarios detractores del Asistido		

Tabla 1 - Metodología análisis de coocurrencias. Fuente: Elaboración propia

Comentarios - Atención BOT (DETRACTORES)

Vista general



Figura 12 Gráfico de coocurrencias en comentarios detractores del BOT. Fuente: elaboración propia.

El gráfico de coocurrencias de palabras correspondiente a las encuestas asociadas a conversaciones gestionadas de forma 100% automática evidencia la presencia de un tópico central que predomina en la mayoría de los comentarios y otros tres temas secundarios que también resultan relevantes. A continuación, se presenta un análisis detallado de cada uno de estos tópicos identificados.

[1] Tópico Central




Figura 13 Gráfico de coocurrencias en comentarios detractores del BOT, tópico central. Fuente: elaboración propia.

El grafo de coocurrencias de la figura 13 muestra que el tópico principal entre los usuarios que interactúan exclusivamente con el BOT está fuertemente relacionado a la necesidad de interacción con un humano, esto se evidencia en la alta frecuencia de términos como “operador”, “representante”, “persona” y “alguien”. Esto sugiere una insatisfacción con la atención del BOT y una expectativa de ser asistido por un agente humano.

Además, surgen términos relacionados con la resolución de problemas, tales como “solución”, “resolver”, “problema”, “dan” y “dieron”. Esto indica que los usuarios no lograron resolver su problema a través del BOT.

Por otro lado, se destacan palabras vinculadas a ciertos temas como “baja”, “dar”, “plan”, “internet”, “pagar” y “días”, lo que sugiere que muchos usuarios enfrentan dificultades técnicas o económicas que motivan solicitudes de baja del servicio o reclamos técnicos. Estos casos requieren de un nivel de comprensión y resolución que actualmente el BOT no es capaz de alcanzar.

Temas secundarios [1]:




Figura 14 Gráfico de coocurrencias en comentarios detractores del BOT, tópico secundario(1). Fuente: elaboración propia.

Temas secundarios [2]




Figura 15 Gráfico de coocurrencias en comentarios detractores del BOT, tópico secundario(2). Fuente: elaboración propia.

Del grafo de coocurrencias se desprenden dos tópicos secundarios. El primero está vinculado a términos como “chip” y “activar”, lo que sugiere la presencia de un reclamo técnico recurrente relacionado con la activación de la línea. Estos casos parecen no ser resueltos de forma satisfactoria.

El segundo grupo de palabras, compuesto por términos como “atendieron”, “nadie”, “cliente” y “atención”, refleja falta de respuesta o resolución, similar a la temática central.

Vista general



Figura 17 Gráfico de coocurrencias en comentarios detractores del Asistido, tópico central. Fuente: elaboración propia.

También se puede observar términos como “internet”, “servicio”, “baja”, lo que sugiere que incluso con atención humana existen casos donde la atención brindada no cumple con las expectativas del usuario.

A partir del análisis realizado en los comentarios de los usuarios que utilizaron el servicio de whatsapp, se identifican una serie de oportunidades de mejora orientadas a optimizar la experiencia en las conversaciones asistidas:

1. Reforzar la capacidad de resolver temas complejos en el BOT

Una parte significativa de los comentarios negativos en las conversaciones automáticas reflejan la imposibilidad de resolver ciertos temas complejos como la imposibilidad de pago, inconvenientes técnicos, activaciones de línea, lo cual desencadena en pedidos de baja del servicio y deseo de hablar con un humano que pueda comprender mejor la necesidad.

Ampliar la inteligencia en el reconocimiento de la intención del usuario y expandir las capacidades de resolución mediante flujos complejos permitiría reducir la insatisfacción del usuario y evitar el pedido de intervención humana.

2. Mejorar la usabilidad del BOT

Muchos usuarios expresan la necesidad de hablar con una persona, lo que indica dificultades para encontrar la funcionalidad adecuada o entender cómo utilizar el BOT. Identificar y corregir puntos de fricción en la experiencia permitiría aumentar la autogestión y reducir la insatisfacción.

3. Facilitar la derivación a atención humana cuando sea necesario

A pesar de que el BOT tiene disponible la opción de escalamiento a un agente humano, existe un alto volumen de usuarios que manifiestan no haber podido acceder a un agente. El diseño actual podría poner muchas barreras para hacer efectivo el escalamiento en situaciones que lo ameriten.

Habilitar un diseño más ágil e inteligente de las interacciones permitiría derivar a un agente de forma segura cuando sea requerido y de esta forma mejorar el NPS.

Análisis de performance de las experiencias conversacionales

Para el periodo del mes de febrero, se cuenta con el detalle de las conversaciones gestionadas por el BOT. Con el propósito de identificar y validar qué experiencias generan mayor frustración en los usuarios, se presenta a continuación los resultados de un análisis de dichas conversaciones, enfocado en entender cuáles son los principales casos de uso del BOT y su desempeño en términos de NPS.

Periodo: Febrero de 2025

Volumen: 14.683 conversaciones

Los casos de uso identificados pueden clasificarse en tres tipos de experiencias. Por un lado, se encuentran las **demandas inducidas**, que corresponden a respuestas de los usuarios ante notificaciones enviadas por distintas campañas. Por otro lado, existen conversaciones originadas por **intercanalidad**, es decir, usuarios que acceden al canal de WhatsApp por haber sido derivados desde otros canales, como la atención telefónica o la aplicación móvil. Y las **interacciones orgánicas**, las cuales son iniciadas de forma autónoma por los usuarios con el objetivo de gestionar consultas o reclamos.

Análisis combinación de CDUs - Tabla metodológica			
	Descripción	Fuente/Datos	Herramienta utilizada
Base de conversaciones	Base de conversaciones con el BOT	Fuente interna (export CSV)	CSV
Nº de comentarios procesados	Total de conversaciones procesadas: 14.683	-	
Periodo	Febrero	-	
Pre-procesamiento	Se lista CDUs y cantidad de apariciones para cálculo de frecuencia. Se genera una matriz binaria (1,0) para representar la aparición conjunta de CDUs.	BBDD conversaciones (CSV)	Python, pandas 1.5
Análisis de combinación de CDUs	Se aplica el algoritmo Apriori (min_support=0.01) para identificar todas las combinaciones de CDUs que aparecen en al menos el 1 % de las conversaciones. Se obtiene como resultado la tabla de combinaciones y su frecuencia. Para el top50 combinaciones frecuentes se calcula su NPS promedio.	Datos preprocesados	scikit-learn 1.2, mlxtend.frequent_patterns, pandas
Resultado [1]	Tabla 3. Frecuencia de casos en el BOT.		
Resultado [2]	Tabla 4. NPS de las combinaciones de casos de uso más frecuentes en el BOT		

Tabla 2 - Metodología análisis de combinación de CDUs. Fuente: Elaboración propia

Principales casos de uso en las conversaciones analizadas:

CASO DE USO	FRECUENCIA	TIPO DE EXPERIENCIA
CDU-CONFIRMACIÓN DE ANI	21554	Orgánica
CDU-MENÚ	13087	Orgánica
CDU-BIENVENIDA	9895	Orgánica
CDU-SOLICITUD DE ANI	6340	Orgánica
CDU-BIENVENIDA WA VENTAS	6209	Intercanalidad
CDU-BAJA	5535	Orgánica
CDU-ROAMING	5453	Orgánica
CDU-HANDOVER	5280	Orgánica
CDU-SUBMENÚ FACTURAS PAGOS Y DEUDAS	4970	Orgánica
CDU-MIGRA NEGATIVA DESDE LA APP	4121	Intercanalidad
PROMO	2163	Inducida
CDU-NO VEO MI PLAN	2163	Orgánica
CDU-EXPLICACIÓN DE FACTURA	1956	Orgánica
CDU-INFO DE PAGO	1792	Orgánica
CDU-BAJA PROV DE LA APP	1647	Intercanalidad
CDU-RECOMENDADOR	1605	Orgánica
CDU-EQUIPOS	1428	Orgánica
CDU-ASESOR TÉCNICO APP	1344	Orgánica
CDU-PROBLEMA TÉCNICO PROV DE HADA	1344	Intercanalidad
CDU-SEGUIMIENTO DE AVERÍAS	1221	Orgánica
CDU-MI CHIP	1090	Orgánica
CDU-DESPEDIDA	1058	Orgánica

CDU-RECLAMO POR REINTEGRO	705	Orgánica
CDU-MEDIOS DE PAGO	636	Orgánica
CDU-ACTIVAR CHIP	609	Orgánica
ESIM	609	Orgánica
CDU-PEDIR CHIP	574	Orgánica
CDU-CONTRATAR SERVICIOS	549	Orgánica
CDU-PORTABILIDAD	548	Orgánica

Tabla 3 - Frecuencia de casos en el BOT. Fuente: Elaboración propia.

Los principales casos de uso presentes en las conversaciones están asociados al menú de bienvenida y a la confirmación del ANI, es decir, el número de identificación telefónica necesario para gestionar la línea desde la cual el usuario realiza la consulta. Dentro de las interacciones de tipo orgánico, también se destacan solicitudes de baja del servicio, consultas relacionadas con roaming y pedidos de escalamiento explícito hacia un agente humano (handover). Adicionalmente, se identifican consultas referidas a facturación, pagos, reclamos técnicos por averías y activación de línea (chip).

En cuanto a los casos de intercanalidad, se observa una alta frecuencia de conversaciones originadas en la web de ventas, generalmente asociadas a consultas por altas de nuevos servicios. También se registran casos de migración negativa desde la aplicación, es decir usuarios que intentaron cambiar su plan por uno más económico, e intentos de gestión de baja del servicio que comienzan en la App y continúan en WhatsApp. También se identifican derivaciones desde HADA (módulo de soporte técnico en la App), principalmente en situaciones donde los usuarios no pudieron resolver el inconveniente técnico y son direccionados directamente hacia un asesor humano en WhatsApp

Análisis por combinación de casos de uso en una conversación:

Cada conversación puede involucrar uno o varios casos de uso, dependiendo del recorrido que haya seguido el usuario. Con el objetivo de identificar qué trayectorias presentan mejor desempeño y en cuáles podrían existir fricciones en la experiencia, se analizaron las combinaciones más frecuentes de casos de uso. Luego, se comparó el NPS promedio asociado a cada combinación, con el fin de detectar puntos críticos y oportunidades de mejora en la interacción con el BOT.

COMBINACIÓN DE CDU	Q	NPS
{{'CDU-HANDOVER'}}	1705	16,72
{{'CDU-MENÚ', 'CDU-BIENVENIDA', 'PROMO', 'CDU-CONFIRMACIÓN DE ANI', 'CDU-NO VEO MI PLAN'}}	329	49,24
{{'CDU-GRACIAS'}}	307	44,95
{{'CDU-CONFIRMACIÓN DE ANI', 'CDU-BAJA', 'CDU-ROAMING'}}	300	27,33
{{'CDU-CHIP MULTITRÁMITE'}}	289	14,88
{{'CDU-MENÚ', 'CDU-BIENVENIDA', 'CDU-ROAMING', 'CDU-CONFIRMACIÓN DE ANI', 'CDU-BAJA'}}	251	27,49
{{'CDU-MENÚ', 'CDU-HANDOVER', 'CDU-CONFIRMACIÓN DE ANI', 'CDU-BIENVENIDA'}}	223	27,80
{{'CDU-MENÚ', 'CDU-CONFIRMACIÓN DE ANI', 'CDU-BIENVENIDA', 'CDU-RECLAMO POR REINTEGRO'}}	216	37,04
{{'CDU-ALTA CHIP MULTITRÁMITE'}}	214	6,54
{{'CDU-MENÚ', 'CDU-SOLICITUD DE ANI', 'CDU-BIENVENIDA', 'CDU-CONFIRMACIÓN DE ANI', 'CDU-BAJA'}}	206	35,44
{{'CDU-CONFIRMACIÓN DE ANI', 'CDU-BAJA'}}	200	9,00
{{'CDU-MENÚ', 'CDU-BIENVENIDA', 'CDU-SUBMENÚ FACTURAS PAGOS Y DEUDAS', 'CDU-ROAMING', 'PROMO', 'CDU-EXPLICACIÓN DE FACTURA', 'CDU-CONFIRMACIÓN DE ANI', 'CDU-NO VEO MI PLAN'}}	192	34,38
{{'CDU-CONFIRMACIÓN DE ANI', 'CDU-SOLICITUD DE ANI', 'CDU-BAJA'}}	180	11,67

{{'CDU-MI CHIP', 'CDU-EQUIPOS', 'CDU-MENÚ', 'CDU-BIENVENIDA', 'CDU-PEDIR CHIP', 'CDU-CONFIRMACIÓN DE ANI'}}	174	31,03
{{'CDU-CONFIRMACIÓN DE ANI'}}	165	-35,76
{{'CDU-CONFIRMACIÓN DE ANI', 'CDU-BIENVENIDA'}}	159	-47,17
{{'CDU-MENÚ', 'CDU-CONFIRMACIÓN DE ANI', 'CDU-BIENVENIDA'}}	153	-61,44
{{'CDU-CONFIRMACIÓN DE ANI', 'CDU-SOLICITUD DE ANI', 'CDU-BAJA', 'CDU-BAJA PROV DE LA WEB'}}	146	58,22
{{'CDU-MENÚ', 'CDU-SOLICITUD DE ANI', 'CDU-BIENVENIDA', 'CDU-HANDOVER', 'CDU-CONFIRMACIÓN DE ANI'}}	144	36,11
{{'CDU-CONFIRMACIÓN DE ANI', 'CDU-SOLICITUD DE ANI'}}	143	-53,15
{{'CDU-MENÚ', 'CDU-SOLICITUD DE ANI', 'CDU-CONFIRMACIÓN DE ANI', 'CDU-BIENVENIDA'}}	142	-43,66
{{'CDU-CONFIRMACIÓN DE ANI', 'CDU-SOLICITUD DE ANI', 'CDU-BIENVENIDA'}}	139	-48,92
{{'CDU-CONFIRMACIÓN DE ANI', 'CDU-HANDOVER', 'CDU-BIENVENIDA'}}	132	15,15
{{'CDU-BAJA', 'MODIFICACIÓN DÉB AUTOM DESDE APP'}}	130	49,23
{{'CDU-MENÚ', 'CDU-BAJA', 'CDU-CONFIRMACIÓN DE ANI', 'CDU-BIENVENIDA'}}	123	14,63
{{'CDU-ROAMING', 'PROMO', 'CDU-EXPLICACIÓN DE FACTURA', 'CDU-CONFIRMACIÓN DE ANI', 'CDU-NO VEO MI PLAN'}}	110	38,18
{{'CDU-MOVISTAR CON TODO DESDE APP'}}	102	44,12
{{'CDU-MENÚ', 'CDU-SOLICITUD DE ANI', 'CDU-BIENVENIDA', 'CDU-SUBMENÚ FACTURAS PAGOS Y DEUDAS', 'CDU-CONFIRMACIÓN DE ANI', 'CDU-INFO DE PAGO'}}	100	11,00
{{'CDU-INSULTOS'}}	94	-23,40
{{'CDU-MENÚ', 'CDU-SOLICITUD DE ANI', 'CDU-BIENVENIDA', 'CDU-SUBMENÚ FACTURAS PAGOS Y DEUDAS', 'CDU-CONFIRMACIÓN DE ANI'}}	88	-1,14
{{'CDU-CONFIRMACIÓN DE ANI', 'PROMO', 'CDU-NO VEO MI PLAN'}}	87	60,92
{{'CDU-MENÚ', 'CDU-CONFIRMACIÓN DE ANI'}}	85	-64,71
{{'CDU-MENÚ', 'CDU-SOLICITUD DE ANI', 'CDU-BIENVENIDA', 'CDU-SUBMENÚ FACTURAS PAGOS Y DEUDAS', 'CDU-ROAMING', 'CDU-EXPLICACIÓN DE FACTURA', 'CDU-CONFIRMACIÓN DE ANI'}}	80	63,75

{{'CDU-SEGUIMIENTO DE AVERÍAS', 'CDU-SOLICITUD DE ANI', 'CDU-BIENVENIDA', 'CIERRE UNIVERSAL', 'CDU-CONFIRMACIÓN DE ANI'}}}	78	-58,97
{{'CDU-MENÚ', 'CDU-SOLICITUD DE ANI', 'CDU-BIENVENIDA', 'CDU-SUBMENÚ FACTURAS PAGOS Y DEUDAS', 'CDU-HANDOVER', 'CDU-CONFIRMACIÓN DE ANI'}}}	76	25,00
{{'CDU-MENÚ', 'CDU-BIENVENIDA', 'CDU-SUBMENÚ FACTURAS PAGOS Y DEUDAS', 'CDU-CONFIRMACIÓN DE ANI', 'CDU-INFO DE PAGO'}}}	76	27,63
{{'CDU-CONFIRMACIÓN DE ANI', 'CDU-MIGRA NEGATIVA', 'CDU-ROAMING', 'CDU-PREPAGO'}}}	76	38,16
{{'CDU-MENÚ', 'CDU-BIENVENIDA', 'CDU-SUBMENÚ FACTURAS PAGOS Y DEUDAS', 'CDU-HANDOVER', 'CDU-CONFIRMACIÓN DE ANI'}}}	75	36,00
{{'CDU-RECOMENDADOR', 'CDU-MENÚ', 'CDU-BIENVENIDA', 'CDU-RECLAMO POR REINTEGRO', 'CDU-CONFIRMACIÓN DE ANI'}}}	73	35,62
{{'CDU-MENÚ', 'PROMO', 'CDU-CONFIRMACIÓN DE ANI', 'CDU-NO VEO MI PLAN'}}}	72	37,50
{{'CDU-RECOMENDADOR', 'CDU-BIENVENIDA', 'CDU-ROAMING', 'PROMO', 'CDU-EXPLICACIÓN DE FACTURA', 'CDU-CONFIRMACIÓN DE ANI', 'CDU-NO VEO MI PLAN'}}}	72	47,22
{{'CDU-CAMBIO DE TITULARIDAD', 'CDU-MENÚ', 'CDU-CONFIRMACIÓN DE ANI', 'CDU-BIENVENIDA'}}}	69	39,13
{{'CDU-ACTIVAR CHIP', 'CDU-MI CHIP', 'CDU-EQUIPOS', 'CDU-MENÚ', 'CDU-BIENVENIDA', 'CIERRE UNIVERSAL', 'ESIM', 'CDU-CONFIRMACIÓN DE ANI'}}}	68	-64,71
{{'CDU-MI CHIP', 'CDU-EQUIPOS', 'CDU-MENÚ', 'CDU-SOLICITUD DE ANI', 'CDU-BIENVENIDA', 'CDU-PEDIR CHIP', 'CDU-CONFIRMACIÓN DE ANI'}}}	66	40,91

Tabla 4 - NPS de las combinaciones de casos de uso más frecuentes en el BOT. Fuente: Elaboración propia.

El cuadro presentado muestra las combinaciones de casos de uso (CDUs) más frecuentes que se registraron en las conversaciones y su correspondiente NPS promedio.

Los datos permiten observar una gran disparidad en los niveles de satisfacción según el recorrido que haya seguido el usuario. Algunas combinaciones, como aquellas que incluyen CDU-HANDOVER o CDU-CONFIRMACIÓN DE ANI, reflejan NPS bajos o incluso negativos. Estas combinaciones están asociadas a intentos de escalar a un agente humano y validaciones de la línea por la cual se consulta, que podrían generar fricción si no se resuelven de manera fluida.

Otras combinaciones que incluyen interacciones como CDU-BIENVENIDA, PROMO, CDU-NO VEO MI PLAN o casos como CDU-BAJA PROV DE LA WEB presentan NPS considerablemente más altos. Esto

se explica en el hecho de que corresponden a experiencias de intercanalidad de la aplicación, que suelen incluir un pase más directo hacia un agente humano.

Resumen de hallazgos

Se ha identificado patrones que permiten comprender con mayor profundidad la experiencia actual en el canal de WhatsApp:

- **Existe una gran brecha entre el NPS de la atención automática y la asistida:** Las conversaciones donde interviene un agente humano mantienen un NPS estable y positivo, mientras que las gestionadas por el BOT obtienen una calificación mayormente negativa, lo que evidencia una experiencia insatisfactoria en la interacción con el BOT.
- **Recurrente pedido de escalamiento hacia humano:** los clientes manifiestan recurrentemente su necesidad de hablar con una persona, ante la falta de resolución por parte del BOT o imposibilidad de encontrar allí lo que buscan.
- **Necesidad de resolver temas complejos:** Adicional al pedido de asistencia humana, los comentarios reflejan la necesidad de resolver ciertas consultas complejas como problemas económicos, inconvenientes técnicos, activación de línea o de baja del servicio. A pesar de que el BOT contiene flujos para atender esta demanda, el usuario no llega a ellos, por falta de interpretación o una mala experiencia en la interacción.
- **Necesidad de resolver temas complejos:** Además del pedido de asistencia humana, los comentarios reflejan la necesidad de resolver consultas complejas, como problemas económicos, inconvenientes técnicos, activación de línea o solicitudes de baja del servicio. Si bien el BOT tiene disponibles flujos para atender estos temas, muchos usuarios no logran llegar a ellos, ya sea por una interpretación incorrecta del lenguaje y/o por una experiencia deficiente durante la interacción.
- **Interacción con el menú y validación de ANI insatisfactoria:** La etapa inicial de la conversación, en la que el BOT presenta las funcionalidades disponibles y solicita la validación del número de línea (ANI), resulta insatisfactoria para los usuarios. Esta experiencia presenta el NPS más bajo entre todas las interacciones analizadas, lo que pone en evidencia una importante oportunidad de mejora en este flujo.
- **Experiencia satisfactoria en los casos de uso de intercanalidad:** Los flujos en los que el usuario es redirigido al canal de WhatsApp para continuar una gestión iniciada en otro canal, como la app, obtienen calificaciones mucho más altas. Esto se debe a que son experiencias más controladas desde su diseño y por lo general facilitan un pase hacia asesor humano mucho más directo.

Se identifican oportunidades de mejora en los casos de uso orgánicos gestionados automáticamente por el BOT, especialmente en la resolución de temas complejos, la comprensión del lenguaje natural y los mecanismos de escalamiento a atención humana. Abordar estas problemáticas permitirían elevar el NPS general del canal.

CAPÍTULO 9: Recomendaciones y conclusiones

Subsección 9.1: Recomendación general

Considerando los hallazgos obtenidos a partir del caso de estudio, se recomienda abordar la adopción de inteligencia artificial generativa mediante una estrategia gradual, que permita incorporar de forma progresiva las capacidades técnicas y el conocimiento organizacional necesario para su integración en los procesos de atención al cliente. Se propone plantear un roadmap en tres grandes fases:

Fase 1: Optimización del BOT en WhatsApp. Aplicar IA generativa para mejorar la comprensión del lenguaje natural y la capacidad de resolución del BOT, en particular en aquellos casos de uso identificados como críticos y de alta complejidad que actualmente no logran ser gestionados de forma satisfactoria.

Fase 2: Asistencia al agente humano. Incorporar IA generativa como *co-pilot* para los agentes de atención, incorporando funciones como sugerencia de respuestas, resúmenes automáticos y acceso contextual a información del cliente. Esto permitirá agilizar la resolución de casos y ofrecer una atención más eficiente y personalizada.

Fase 3: Expansión multicanal. Extender las capacidades desarrolladas con IA generativa a otros canales de atención, como la aplicación móvil y el canal telefónico (IVR), con el objetivo de consolidar una experiencia omnicanal coherente en todos los puntos de contacto con el cliente.

Subsección 9.2: Estrategia de implementación

Optimización del BOT en WhatsApp

Objetivos de la fase:

- Mejorar la comprensión del lenguaje y usabilidad del BOT para interpretar consultas de los usuarios.
- Foco en aplicar las capacidades de IA en temas críticos y complejos de resolver, como asistencia en problemas técnicos, gestión y contención de pedidos de baja del servicio.
- Ofrecer una experiencia conversacional personalizada e inteligente que permita reducir los pedidos de escalamiento hacia un agente humano.
- Incrementar NPS en conversaciones 100% automáticas.

Capacidades requeridas

- Integrar modelos de lenguaje avanzados (LLMs) a la solución tecnológica existente, promoviendo un esquema híbrido que permita activar las capacidades de IA generativa en aquellos casos donde aporte mayor valor.
- Instruir a los modelos con información contextual del negocio y datos específicos necesarios para abordar los casos de uso definidos.
- Adoptar un abordaje multidisciplinario, basado en el modelo de organización ágil de la compañía, que facilite la colaboración entre perfiles técnicos, de negocio y experiencia de cliente.
- Estructurar un plan de capacitación que permita fortalecer las competencias del equipo en inteligencia artificial generativa.

Riesgos:

- Resolver limitaciones técnicas para integrar capacidades de IA generativa a la solución.
- Privacidad de los datos, generación de respuestas ambiguas o incorrectas y aparición del fenómeno de alucinaciones por parte del modelo de IA, lo que podría afectar la confianza del usuario. Es importante considerar estos aspectos junto a equipos de seguridad de datos, legales, compliance y monitoreo, para plantear planes de acción que permitan controlar el proceso.
- Requerimientos éticos y regulatorios sobre la transparencia y el uso de datos personales. Se deberá analizar mecanismos que permitan proteger datos sensibles de los usuarios.

Indicadores de éxito

- Incremento del NPS en conversaciones automáticas.
- Reducción en la derivación hacia agentes humanos.
- Aumento de resolución del BOT en casos de uso complejos.
- Valoración del cliente en las encuestas.

Caso de uso ejemplo:

- Desarrollar un agente conversacional basado en IA capaz de comprender y gestionar solicitudes de baja del servicio, incorporando capacidades de empatía en la interacción para contener al cliente y evitar la necesidad de escalamiento hacia un asesor humano. En los casos en que el motivo declarado sea una dificultad económica, el agente podrá ofrecer alternativas como descuentos o beneficios, con el objetivo de disuadir la cancelación y fomentar la retención.

Las fases 2 y 3 son etapas complementarias que permitirán consolidar una estrategia integral de adopción de IA generativa en la organización. La implementación de ambas fases podrá planificarse

en función de los aprendizajes que se obtengan durante la fase inicial: optimización del BOT en WhatsApp.

Subsección 9.3: Conclusiones generales

En un sector altamente competitivo como el de las telecomunicaciones, la inteligencia artificial constituye un aliado estratégico para enfrentar los desafíos estructurales que afectan la rentabilidad y la eficiencia operativa. En particular, la adopción de inteligencia artificial generativa en la atención al cliente representa una oportunidad concreta para generar ventajas competitivas, permitiendo alcanzar grandes eficiencias. Como se desarrolló a lo largo de este trabajo, esta tecnología posibilita mejorar la atención al cliente mediante una mayor capacidad de comprensión y resolución en los canales automatizados, al mismo tiempo que tiene el potencial de aumentar la productividad de los agentes humanos, ampliando su capacidad de respuesta sin incrementar la dotación existente. Estos beneficios son relevantes en un contexto donde la presión financiera y la necesidad de optimizar recursos son factores clave.

Además del impacto en la eficiencia, la inteligencia artificial generativa también contribuye en gran medida a la fidelización del cliente. Al permitir interacciones más personalizadas y contextualizadas, esta tecnología mejora la calidad de la experiencia, incrementa la satisfacción del usuario y fomenta la fidelidad con la marca. Y este aspecto resulta de suma relevancia frente al objetivo estratégico de reducir el *churn*.

Si bien son numerosos los beneficios potenciales de esta tecnología, su adopción requiere de una estrategia cuidadosamente diseñada que contemple distintos aspectos. Desde el punto de vista tecnológico, es fundamental asegurar su integración con los sistemas de datos y el ecosistema tecnológico existente en la organización. Respecto a la dimensión organizacional, resulta necesario implementar un plan de *re-skilling* que permita desarrollar las competencias de los colaboradores en este tipo de tecnología. Por último, desde la perspectiva de seguridad y gobernanza de los datos, es importante considerar los riesgos asociados en el ámbito de ética, privacidad, transparencia y cumplimiento normativo.

LISTA DE REFERENCIAS

References

- Buiten, M. C. (2019). *Towards intelligent regulation of artificial intelligence*. *European Journal of Risk Regulation*, 10(1), 41–59. <https://doi.org/10.1017/err.2019.8>
- Cao, Y., Li, S., Liu, Y., Yan, Z., Dai, Y., Yu, P. S., & Sun, L. (2023). *A comprehensive survey of AI-generated content (AIGC): A history of generative AI from GAN to ChatGPT*. <https://arxiv.org/pdf/2303.04226>
- Garza Ulloa. (2024). *Artificial Intelligence: Predictive vs Generative vs New Mixing AI*. *American Journal of Biomedical Science & Research*.
- Kai-Fu lee. (2021). *Superpotencias de la Inteligencia Artificial* (3rd ed.). Valleta Ediciones.
- Kumar, S. (2022, December 12). *Customer Retention Versus Customer Acquisition*. Forbes. Retrieved April 9, 2025, from <https://www.forbes.com/councils/forbesbusinesscouncil/2022/12/12/customer-retention-versus-customer-acquisition/>
- Rishi Bommasani. (2022, Julio). *On the Opportunities and Risks of Foundation Models*. Stanford University.
- Yevsieieva-Severyna, I., & Skopenko, N. (2022). *Artificial intelligence as a driver of the development of modern business. Theory and Practice of Public Administration and Economics*. <https://doi.org/10.17721/tppe.2022.45.7>
- Ganesan, S. K. (2024). *Mejorando la experiencia del cliente con Inteligencia Artificial Generativa en centros de contacto de servicios financieros*. *International Journal of Scientific Research in Computer Science, Engineering and Information Technology*, 10(5). <https://doi.org/10.32628/CSEIT241051084ijsrcseit.com>

Appel, G., Neelbauer, J., & Schweidel, D. A. (2023, abril 7). *Generative AI has an intellectual property problem*. Harvard Business Review. <https://hbr.org/2023/04/generative-ai-has-an-intellectual-property-problem>

Navigli, R., Conia, S., & Ross, B. (2023). *Biases in Large Language Models: Origins, Inventory and Discussion*. *Journal of Data and Information Quality*, 15(2), 1–21. <https://doi.org/10.1145/3597307>

Lin, X., Kundu, L., Dick, C., Canaveras Galdon, M. A., Vamaraju, J., Dutta, S., & Raman, V. (2024). *A primer on generative AI for telecom: From theory to practice* <https://doi.org/10.48550/arXiv.2408.09031>

Yenduri, G., Ramalingam, M., Selvi, C. G., Supriya, Y., Srivastava, G., Maddikunta, P. R., Raj, D. G., Jhaveri, R. H., Prabadevi, B., Wang, W., Vasilakos, A. V., & Gadekallu, T. R. (2023). *Generative Pre-trained Transformer: A Comprehensive Review on Enabling Technologies, Potential Applications, Emerging Challenges, and Future Directions*. <https://doi.org/10.48550/arXiv.2305.10435>

Ruscheimer, H. (2025). *Generative AI and data protection*. *Cambridge Forum on AI: Law and Governance* <https://doi.org/10.1017/cfl.2024.2>

Reinhard, P., Li, M. M., Peters, C., & Leimeister, J. M. (2024). *Generative AI in Customer Support Services: A framework for augmenting the routines of frontline service employees*. En Proceedings of the 57th Hawaii International Conference on System Sciences (HICSS). Waikiki, Hawaii, USA

Capgemini. (2024). *Eneco eMobility supercharges its customer care with generative AI*. <https://www.capgemini.com/wp-content/uploads/2024/05/Eneco-eMobility-client-story-case-study-2.pdf>

Capgemini. (2024). *Envision a new era of customer service with generative AI*.

DigitalEs (Ed.). (2024, Junio). *Libro blanco de la inteligencia artificial generativa*.

https://www.coit.es/sites/default/files/digitales_libro_blanco_ia_generativa.pdf

Ernst & Young. (2024). *Los 10 principales riesgos para las telecomunicaciones en 2024*. EY.

https://www.ey.com/es_ar/insights/telecommunications/top-10-risks-for-telecommunications

Fullview. (2023). *A Concise History Of Customer Service*.

<https://www.fullview.io/blog/history-of-customer-service>

IBM. (2024). <https://www.ibm.com/think/topics/generative-ai-vs-predictive-ai-whats-the-difference?>

McKinsey. (2024). <https://www.mckinsey.com/capabilities/operations/our-insights/where-is-customer-care-in-2024#/>

McKinsey. (2024, December 18). *The future of telcos: Mapping the routes to renewed success*. McKinsey & Company. Retrieved April 9, 2025, from

<https://www.mckinsey.com/industries/technology-media-and-telecommunications/our-insights/the-future-of-telcos-mapping-the-routes-to-renewed-success#/>