



UNIVERSIDAD DE CHILE
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
DEPARTAMENTO DE INGENIERÍA INDUSTRIAL

CHATBOT EN SUPPLY CHAIN: DISEÑO, IMPLEMENTACIÓN Y EVALUACIÓN DE UNA HERRAMIENTA DE APOYO A LA TOMA DE DECISIONES EN UNA EMPRESA MINERA

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERA CIVIL
INDUSTRIAL

MONSERRAT ISIDORA MARCHANT SAN MARTÍN

PROFESOR GUÍA:
FELIPE VILDOSO CASTILLO

MIEMBROS DE LA COMISIÓN:
JOSÉ NALDA REYES
CAROLINA SEGOVIA RIQUELME

SANTIAGO DE CHILE
2024

**RESUMEN DE LA MEMORIA PARA OPTAR AL
TÍTULO DE:** Ingeniera Civil Industrial
ESTUDIANTE: Monserrat Isidora Marchant San Martín
FECHA: 2024
PROFESOR GUÍA: Felipe Vildoso Castillo

CHATBOT EN SUPPLY CHAIN: DISEÑO, IMPLEMENTACIÓN Y EVALUACIÓN DE UNA HERRAMIENTA DE APOYO A LA TOMA DE DECISIONES EN UNA EMPRESA MINERA

El proyecto, desarrollado con SQM, se enfoca en diseñar e implementar un chatbot para el área de Supply Chain. Este chatbot mejora el acceso a información crítica, optimizando la toma de decisiones. La iniciativa responde a la necesidad de eficiencia en la gestión de datos.

El objetivo principal del proyecto es diseñar e implementar un chatbot que proporciona información crítica sobre indicadores relevantes, impulsando la innovación con el uso de tecnologías de inteligencia artificial generativa (GenAI).

La metodología seguida combina CRISP-DM y DevOps. CRISP-DM asegura un alineamiento con los objetivos del negocio y la calidad de los datos, abarcando etapas de comprensión del negocio, comprensión y preparación de los datos de SQM, y despliegue. DevOps, por otro lado, se centra en la planificación y desarrollo del chatbot, abarcando backend y frontend, integración continua de la herramienta, monitoreo, feedback y mejora continua en base a estos, gestionando cada etapa con un enfoque colaborativo para asegurar una entrega rápida y de alta calidad.

Entre los principales resultados, se implementó un chatbot funcional con un backend robusto y un frontend intuitivo. Este chatbot proporciona respuestas rápidas e informa a los usuarios sobre las bases de datos utilizadas mediante una página de FAQ, facilitando una toma de decisiones más informada y eficaz en el área de Supply Chain.

Las discusiones principales del proyecto giran en torno a la necesidad de una mayor colaboración con los usuarios desde el inicio, la incorporación de más bases de datos de subáreas adicionales, y la selección adecuada de herramientas tecnológicas. También se destaca la importancia de reducir las alucinaciones del chatbot para asegurar su fiabilidad en contextos críticos de toma de decisiones.

Finalmente, se concluye que se cumplieron los objetivos planteados, proporcionando un chatbot efectivo y eficiente que mejora el acceso a información crítica en Supply Chain. Además, se identifican áreas para futuras mejoras y expansiones, garantizando la adaptabilidad y eficacia del chatbot a largo plazo.

*“A veces cuesta creer que haya acabado, ¿verdad?
Es curioso cómo nos enganamos a las dificultades.”*

-Celeste (juego)

Agradecimientos

Quiero partir agradeciendo a quienes me han acompañado en este proceso de no solo formación profesional, sino también personal, agradezco infinitamente a mis padres: a mi papá, que siempre estuvo ahí, mandándome mensajitos preguntándome como estoy, dándome ánimo en mis estudios, trabajando para poder aportar en casa y permitir que pueda vivir en Santiago durante mis estudios de forma cómoda. Y a mi mamá que estuvo siempre en los momentos más difíciles, ayudándome con el orden de mi pieza y haciéndome comida cuando me veía estresada o sin tiempo, me acompañaba mientras nos relajamos viendo videos de Youtube, viajando de San Felipe a Santiago para poder hacer todo eso. Gracias por los sacrificios que han hecho por mí, sin ustedes dos no estaría donde estoy ahora.

A mis amigas del colegio, gracias niñas por siempre estar ahí a pesar de la distancia, agradezco mucho esas pocas salidas que tenemos al año, a pesar de no verlas o hablar mucho, siempre las tengo en mi corazoncito por todos esos años que estuvimos disfrutando (y sufriendo) juntas en el colegio.

A mis amigas de la U, les agradezco mucho. A mis amigas que pude conocer en primer año, recuerdo esas juntas para estudiar, donde nos quedábamos hasta tarde estudiando para los controles del DIM o de física, conversando o escuchando algún podcast, sin ustedes y su compañía no hubiera sido lo mismo mi primer año de U, gracias a ustedes no solo hubo sufrimiento. A mis amigos que conocí en Industrias gracias a Taller 1, aprecio mucho su compañía en todos los ramos, como nos apañábamos todas las semanas, ustedes hicieron mucho más amenas las clases y horas de estudio y sé que seremos excelentes profesionales.

A mis excompañeros de Brain Food que hicieron posible esta memoria. Gracias Nachito por siempre estar ahí tanto como jefecito y como amigo, siempre estando pendiente de mí, haciendo que pudiera aprender de esta experiencia lo más posible. Gracias Martín por ayudarme no solo en mis tareas de la pega, sino también en mejorar esta memoria gracias a tus correcciones que te ofrecías a hacer, te agradezco por tu compañía en todo este proceso. Agradezco a Brain Food por llevarme a conocer a hermosas personas como ustedes.

Y por qué no, también quiero agradecer a la persona que estuvo todos estos años en la universidad, dando todo de si (a veces) en los estudios, para no sólo pasar los ramos, sino también sacar buenas notas, muchas veces llegando al punto de llorar del estrés. Todo el esfuerzo valió la pena, porque está acá, a poco de titularse. Lo lograste yo del pasado, lo logramos. Me doy las gracias a mí misma, por nunca haberme rendido.

Tabla de contenido

Capítulo 1 : Antecedentes generales	1
1.1. Caracterización de la organización.....	1
1.1.1. Sector industrial	1
1.2. Caracterización del cliente	2
1.2.1. Sector industrial del cliente	2
1.3. Desarrollos de GenAI en el mundo	3
Capítulo 2 : Descripción del problema y oportunidad	5
2.1. Problema del cliente y oportunidad	5
Capítulo 3 : Descripción y justificación del proyecto	7
Capítulo 4 : Objetivos	9
4.1. Objetivo general.....	9
4.1.1. Objetivos específicos.....	9
Capítulo 5 : Alcances	10
Capítulo 6 : Marco conceptual	11
6.1. Inteligencia Artificial Generativa.....	11
6.2. Procesamiento de lenguaje natural.....	12
6.3. Modelo de lenguaje grande	12
6.4. Chatbot.....	13
6.4.1. Text-to-SQL.....	14
6.5. Prompts.....	15
6.5.1. Prompt chaining.....	16
Capítulo 7 : Metodología.....	17
7.1. Metodología de referencia	17
7.2. Metodología desarrollada durante el proyecto	17
7.2.1. Etapas de POC	17
7.2.2. Etapas de MVP	18

7.2.3. Ventajas y limitaciones de metodología	18
7.3. Recursos relevantes.....	19
7.3.1. Librerías.....	19
7.3.2. Softwares	20
Capítulo 8 : Desarrollo.....	21
8.1. Etapas de POC	21
8.2. Etapas de MVP	22
Capítulo 9 : Resultados.....	24
9.1. Etapas de POC	24
9.2. Etapas de MVP	25
Capítulo 10 : Discusiones	27
10.1. Análisis crítico de objetivos	27
10.2. Análisis crítico de alcances	27
10.3. Análisis crítico de resultados.....	27
Capítulo 11 : Conclusiones	29
Capítulo 12 : Bibliografía.....	32
ANEXOS	35
Anexo A	35
A.1. Perfiles profesionales de Brain Food	35
A.2. Organigrama de Brain Food.....	35
A.3. Servicios de Brain Food.....	36
Anexo B.....	37
B.1. Comparación de la demanda de minerales en diversas tecnologías energéticas.....	37
B.2. Organigrama de Supply Chain SQM Lithium	37
Anexo C	38
C.1. Inversión en GenAI 2019-2023.....	38

Anexo D	39
D.1. Ejemplo de GenAI.....	39
D.2. Benchmark de herramienta LLM.....	39
D.3. Prompt contexto compras	39
D.4. Prompt clasificación.....	40
Anexo E	41
E.1. Muestra de metadata de base Activación	41
E.2. Queries de ejemplo	42
E.3. Cambios a las bases en Azure Synapse	42
E.4. Campos de bases de datos modificadas	44
E.5. Frontend Chatbot.....	44
E.6. Gitflow	46
E.7. Mejora de chatbot actual con respecto a la prueba de concepto.....	47
E.8. Prototipo de Termómetro LLM	48
E.9. Arreglo de bugs y funcionalidades nuevas	48

Índice de Tablas

Tabla 1: Servicios Brain Food.....	36
Tabla 2: Campos de bases de datos modificadas	44

Índice de Ilustraciones

Ilustración 1: Mockup inicial de chatbot	8
Ilustración 2: Ejemplo text-to-sql.....	14
Ilustración 3: Flujo de consultas en altos ejecutivos	24
Ilustración 4: Flujo de chatbot.....	25
Ilustración 5: Flujo de Prompt Chaining	25
Ilustración 6: Interfaz de chatbot.....	26

Capítulo 1: Antecedentes generales

1.1. Caracterización de la organización

Brain Food destaca como una consultora especializada en transformación digital, analítica avanzada, ingeniería de datos, BI, automatización y software factory. Reconocida por su enfoque innovador y su habilidad para adaptarse a las cambiantes demandas del mercado dentro de la industria de consultoría (Brain Food, s.f.).

La compañía fue fundada en 2015 por David Albagil (Algabil, 2024). La empresa se ha destacado por su enfoque innovador y su capacidad para adaptarse a las cambiantes demandas del mercado dentro de la industria de consultoría. Actualmente, cuenta con un equipo de alrededor de 50 colaboradores organizados en distintos proyectos según sus perfiles técnicos, con el objetivo de ofrecer un valor significativo a sus clientes (Algabil, 2024). Consultar el anexo A.1 y A.2 para más información. Con sede en Santiago de Chile, Brain Food presta servicios en más de 14 países, incluyendo Estados Unidos, México, Panamá, Perú y Colombia, habiendo atendido a más de 40 clientes satisfechos y completado exitosamente más de 150 proyectos en más de 15 industrias diferentes (Brain Food, s.f.). En el anexo A.3 se puede ver más información sobre los servicios que ofrece Brain Food.

La empresa declara que su misión es: “Ser la consultora regional líder y el lugar preferido para trabajar en analítica avanzada, tecnología y transformación digital, combinando la visión estratégica con la capacidad técnica, creando soluciones de vanguardia para satisfacer las necesidades de todo tipo de organizaciones, sacándole el máximo provecho a la información que las empresas tienen disponible, generando un impacto positivo para nuestros clientes, colaboradores y la sociedad” (Algabil, 2024).

1.1.1. Sector industrial

Brain Food se ubica en el sector industrial de consultoría, un mercado de creciente relevancia a nivel mundial (Mordor Intelligence) para organizaciones consolidadas que buscan externalizar conocimientos y obtener nuevas perspectivas. Estas empresas ofrecen asesoramiento especializado en estrategia, operaciones, sistemas de información, recursos humanos o marketing, destacando por su enfoque en la innovación y la experiencia.

En Chile, el liderazgo del sector de consultoría lo ostentan firmas internacionales como BCG, McKinsey, Bain & Company, PwC, Deloitte y Accenture, entre otras (Peredo & Parraguez, 2023). A diferencia de estas, Brain Food se especializa en la transformación digital, posicionándola como una consultora boutique. Su propuesta de valor radica en

su profundo conocimiento en este ámbito, lo que la hace más accesible y facilita una relación estrecha con los clientes (Algabil, 2024).

Debido a su enfoque especializado, Brain Food tiene pocos competidores directos en el mercado. Los más cercanos en términos de especialización son MAS Analytics y Datalized, empresas que abordan desafíos empresariales mediante el uso de datos y tecnología, aunque operan a una escala más reducida y con alcance limitado a Chile (MAS Analytics, s.f.) (Datalized, s.f.).

1.2. Caracterización del cliente

En el proyecto actual, se está colaborando con SQM, una empresa minera global con sede en Chile, reconocida por su excelencia en áreas clave como salud, alimentación, tecnología y energías limpias. Con más de 52 años de experiencia, SQM se distingue por su enfoque en la innovación y la sostenibilidad, adaptándose constantemente a las demandas del mercado global (SQM, s.f.).

SQM declara como su misión y visión las siguientes (SQM, 2022):

- Misión: “Somos una empresa global, con un equipo de personas comprometidas con la excelencia, cuya actividad se enfoca en la extracción de minerales, capaces de integrarse selectivamente en el procesamiento y comercialización de productos para industrias esenciales en el desarrollo humano.”
- Visión: “Somos una empresa global, reconocida por sus altos niveles de competitividad, excelencia e innovación en sus áreas de negocio, orientada al desarrollo de productos esenciales para el desarrollo humano, en un marco de acción de altos estándares de integridad.”

SQM es una empresa química global listada en la Bolsa de Santiago (SSE) y en la bolsa de New York (NYSE). Su red comercial internacional especializada le permite a la empresa llegar con sus productos a más de 110 países, durante el 2022, del total de ventas, un 98% correspondió a exportaciones (SQM, 2022). El 2022 contó con US\$10.710,6 millones en ventas totales, una utilidad neta de US\$3.906,3 millones y con 6.997 trabajadores en Chile y en el mundo (SQM, 2022).

1.2.1. Sector industrial del cliente

En esta ocasión, el cliente es SQM Lithium, reconocido como uno de los líderes mundiales en la producción y comercialización de litio. En el año 2023, su capacidad de producción alcanzó las 180 mil toneladas de carbonato de litio. SQM Lithium declara que existe un proceso significativo en el cual los detalles logísticos son fundamentales para

cumplir con los plazos de entrega pactados en cada uno de los países donde opera, abarcando los cinco continentes (SQM Lithium).

El litio es esencial en la transición energética debido a su papel crucial en las baterías de iones de litio, fundamentales para la descarbonización del transporte y el almacenamiento de energía renovable. Este proceso implica una mayor demanda de minerales, como litio, cobre, níquel, cobalto y tierras raras, destacados en el anexo B.1 con una comparación de su demanda en diferentes tecnologías energéticas (IEA, 2021).

Los registros más recientes, de acuerdo con la USGS (USGS) muestran que la producción en 2022 fue liderada por Australia y Chile, con el 47,2% y el 30,2% respectivamente. El mercado del litio ha sido considerado oligopólico por algunos expertos, debido a la concentración del 36% de la producción en manos de Albemarle, minera estadounidense, y SQM (Cochilco, 2021).

En el contexto del proyecto, el equipo está trabajando con el sector de Supply Chain de SQM Lithium. En el anexo B.2 se presenta una imagen del organigrama de esta área, junto con los encargados de cada subárea, las cuales son Abastecimiento Estratégico, Abastecimiento Operacional, Inventario y Recuperación, SI Envasado y Despacho, SI Control de Operaciones y Almacenamiento, Mejoras y Mantenimiento, y Proyecto SAP Litio.

1.3. Desarrollos de GenAI en el mundo

El interés por la inteligencia artificial generativa ha ido creciendo cada año. En 2023, se registró un año excepcional para la inversión en startups de GenAI, con una financiación de capital que superó los 21.800 millones de dólares en 426 operaciones (CBInsights, 2024).

La financiación se multiplicó por cinco en 2023 en comparación con el año anterior (ver anexo C.1 para más información), mientras que las operaciones aumentaron un 66%. Actualmente, hay 36 empresas de GenAI que han alcanzado el estatus de unicornio (CBInsights, 2024).

A medida que la tecnología evoluciona, las grandes empresas tecnológicas y las nuevas startups están desarrollando agresivamente capacidades de IA generativa para satisfacer la demanda de las empresas que buscan adoptar esta tecnología. Esto está impulsando una expansión en la diversidad de casos de uso de GenAI, desde la tecnología con grandes modelos de lenguaje (LLM según sus siglas en inglés, para saber más de esta herramienta ver sección 6.3) hasta modelos adaptados a dominios específicos.

En la actualidad, el chatbot más popular es ChatGPT, con aproximadamente 180.5 millones de usuarios activos mensuales (Silverio, 2024). ChatGPT ofrece diversas

funciones, como redactar o corregir ensayos, traducir textos, resumir temas específicos, crear y corregir código, generar ideas para campañas de marketing, escribir artículos, entre muchas otras.

Ahora bien, los chatbots son una tecnología relativamente nueva, y actualmente las empresas los utilizan principalmente para gestionar la atención al cliente. En el contexto de la memoria, se han identificado distintos casos de éxito de proyectos que involucran chatbots dirigidos tanto a usuarios internos de empresas como herramientas innovadoras de IA generativa en el ámbito empresarial. Entre ellos se encuentran:

- Chatbot ACHS: En la Asociación Chilena de la Seguridad (ACHS), Brain Food detectó la oportunidad de gestionar eficientemente las dudas de los trabajadores respecto a información interna de la institución, ya que llegaban 200 solicitudes diarias al área de gestión de personas, que contaba con solo tres trabajadores respondiendo manualmente. La automatización del proceso con una herramienta de IA generativa que responde consultas de manera inteligente permitió acelerar los procesos y operaciones diarias, liberando al personal para que se dedique a tareas que generen mayor valor.
- Supply Chain de Amazon: Amazon utiliza modelos de GenAI para predecir la demanda de productos, optimizar rutas de entrega y gestionar inventarios en sus centros de distribución. Estos modelos analizan grandes volúmenes de datos históricos y tendencias actuales para prever cuáles productos serán más demandados en diferentes regiones, permitiendo a Amazon ajustar sus niveles de inventario y reducir costos de almacenamiento (Wlodarczak, 2023).
- “Alex” de Unilever: Alex, desarrollado por Unilever e impulsado por la API de GPT, filtra los correos electrónicos, separando el spam de los mensajes reales de los consumidores. Para los mensajes legítimos, recomienda respuestas a los agentes humanos de Unilever. La herramienta realiza las tareas más pesadas, permitiendo a los agentes humanos disponer de más tiempo para dedicarse a tareas de mayor utilidad. Hasta la fecha, Alex ha ayudado a Unilever a reducir en más de un 90% el tiempo que los agentes dedican a redactar respuestas (Olavsrud, 2023).

Los chatbots y las herramientas de inteligencia artificial generativa están transformando significativamente la forma en que las empresas gestionan diversas áreas operativas. Aunque inicialmente se centraban en la atención al cliente, su aplicación se ha expandido a otros dominios internos de las organizaciones, demostrando casos de éxito en diferentes sectores. Los ejemplos presentados evidencian el potencial y la creciente importancia de los chatbots y la IA en la mejora de procesos y la eficiencia operativa dentro de las empresas.

Capítulo 2: Descripción del problema y oportunidad

En los últimos 20 años se ha producido un crecimiento exponencial en el volumen, variedad, velocidad y valor de los datos, lo que ha catapultado la relevancia del análisis de datos (Ranjan & Foropon, 2021). Este proceso implica examinar e interpretar la información generada por una empresa, con el fin de comprender los eventos y patrones que subyacen a sus operaciones.

Esta comprensión profunda permite a los responsables tomar decisiones informadas y estratégicas que impulsen el logro de los objetivos empresariales establecidos (Cipolla, 2021). En un entorno empresarial cada vez más competitivo y dinámico, el análisis de datos se convierte en una herramienta indispensable para identificar oportunidades, detectar tendencias emergentes, mitigar riesgos y optimizar procesos.

2.1. Problema del cliente y oportunidad

El interés de SQM en analizar sus datos se centra actualmente en los registros de compras. Hasta el momento, el área de Supply Chain depende en gran medida de un reporte denominado "Reporte Diálogo Desempeño", el cual ofrece información detallada sobre compradores, proveedores, órdenes de compra, entre otros aspectos relevantes.

Sin embargo, la Gerencia del área enfrenta dificultades al buscar información relevante, ya que el reporte actual no está diseñado para su uso directo, lo que conlleva demoras al tener que pasar por múltiples canales y analistas para obtener los datos necesarios (Pérez, 2023). La complejidad de su uso se traduce en la pérdida de tiempo valioso, aproximadamente de 1 hora a 5 horas por requerimiento de información (Pérez, 2023).

Además, la naturaleza general del reporte dificulta la identificación clara de errores en la gestión o la identificación de oportunidades de mejora en el proceso de compras. Esta falta de visibilidad sobre los datos subyacentes impide a SQM aprovechar al máximo el potencial de sus datos para optimizar sus operaciones. En este sentido, se evidencia una clara necesidad de transformar la forma en que se accede y se interpreta la información histórica contenida en los reportes.

Se presenta un problema adicional en la gobernanza de datos para SQM: la empresa enfrenta una acumulación abrumadora de aproximadamente 4.000 informes que actualmente no están siendo utilizados. La falta de conocimiento acerca de la ubicación precisa y el contenido exacto de estos reportes añade una capa de complejidad a esta situación.

Este desconocimiento dificulta en gran medida el acceso a la información contenida en dichos reportes (Pérez, 2023).

A partir de esto, se concluye que no solo es difícil acceder a la información de compras, sino también a otros datos importantes para la Gerencia, como el OTIF (On-Time In Full), que corresponde a una métrica que evalúa la eficiencia de la cadena de suministro, midiendo la entrega de pedidos completos y a tiempo según lo acordado con el cliente, además de información de despachos, presupuesto e información sobre bodegas.

Por lo anterior mencionado, nace la oportunidad significativa para SQM de mejorar su eficiencia operativa y su capacidad de respuesta ante las dinámicas del mercado. La implementación exitosa de estas mejoras podría resultar en una ventaja competitiva sustancial, optimizando no solo el proceso de compras sino también reforzando la posición de la empresa en la industria.

Esta oportunidad permitiría a los usuarios obtener respuestas rápidas, sin la necesidad de navegar por múltiples sistemas o esperar la generación de informes. Además de reducir la carga de trabajo manual y liberar tiempo para las actividades más estratégicas como, por ejemplo, realizar tareas de mayor valor agregado en lugar de dedicar tiempo a buscar y procesar datos. Por otro lado, la capacidad para manejar consultas de manera rápida y eficiente lo hace ideal para entornos empresariales en constante cambio como lo puede ser la industria minera.

La inversión en esta solución tecnológica avanzada innovadora puede generar beneficios a largo plazo en términos de productividad, competitividad y toma de decisiones informadas.

Capítulo 3: Descripción y justificación del proyecto

El proyecto en el que está trabajando la estudiante consiste en la creación de un data lake debido a cambio de software en la compañía, a partir del cual se genera una estrategia de gobierno y explotación. Además, bajo este marco regulador, se trabaja en un portafolio de iniciativas asociadas a Data Engineering, Data Science y/o Business Intelligence que agreguen valor a la compañía en las operaciones del área de Supply Chain.

De estas iniciativas surge el “Proyecto LLM”, en el que está involucrada la estudiante, junto con un equipo de tres Data Engineer. Este proyecto se centra en el desarrollo de un chatbot impulsado por inteligencia artificial (se pueden ver más detalles en sección 6.4). El chatbot tiene la capacidad de consultar información almacenada en bases de datos estructuradas, originalmente en formato Azure SQL. Su implementación promete un ahorro significativo de tiempo, ya que permite obtener respuestas en cuestión de segundos, eliminando la necesidad de realizar búsquedas y consultas manuales en la base de datos.

El proyecto surge de la necesidad del usuario, quien es el Gerente de Supply Chain, de obtener respuestas de forma rápida sobre los productos vendidos en el pasado. El usuario ha reconocido que la capacidad de acceder de forma rápida y precisa a información histórica sobre productos vendidos es fundamental para optimizar la gestión de inventario, anticipar la demanda futura y tomar decisiones estratégicas en cuanto a la producción y distribución. Además, debido al volumen de datos y la necesidad de respuestas instantáneas, el usuario ha identificado limitaciones en los reportes actuales y la importancia de implementar una solución más ágil y eficiente.

Por tanto, se espera que este proyecto conduzca a una oportunidad de conseguir mayor eficiencia operativa y una mayor velocidad en la recopilación de información clave para tomar decisiones relevantes para SQM. La gerencia de Supply Chain podrá acceder rápidamente a información crucial, algo que antes no era posible debido a la fragmentación de datos y la necesidad de procesos manuales extensivos.

En líneas generales, la fase inicial del proyecto involucra el desarrollo de una prueba de concepto basada en inteligencia artificial generativa (GenAI según sus siglas en inglés, para saber más de esta herramienta ver sección 6.1) que permita a los responsables del área de Compras de SQM identificar el valor de consultar información de solicitudes de pedidos y órdenes de compra. Posteriormente, se avanzará hacia el desarrollo de una solución viable y productiva basada en GenAI que permita a los jefes de área de Supply Chain, consultar información de solicitudes de pedidos, órdenes de compra, proveedores y despachos desde Microsoft Teams.

En la Ilustración 1 (elaboración propia) se puede ver el prototipo inicial del chatbot realizado en la plataforma FIGMA.

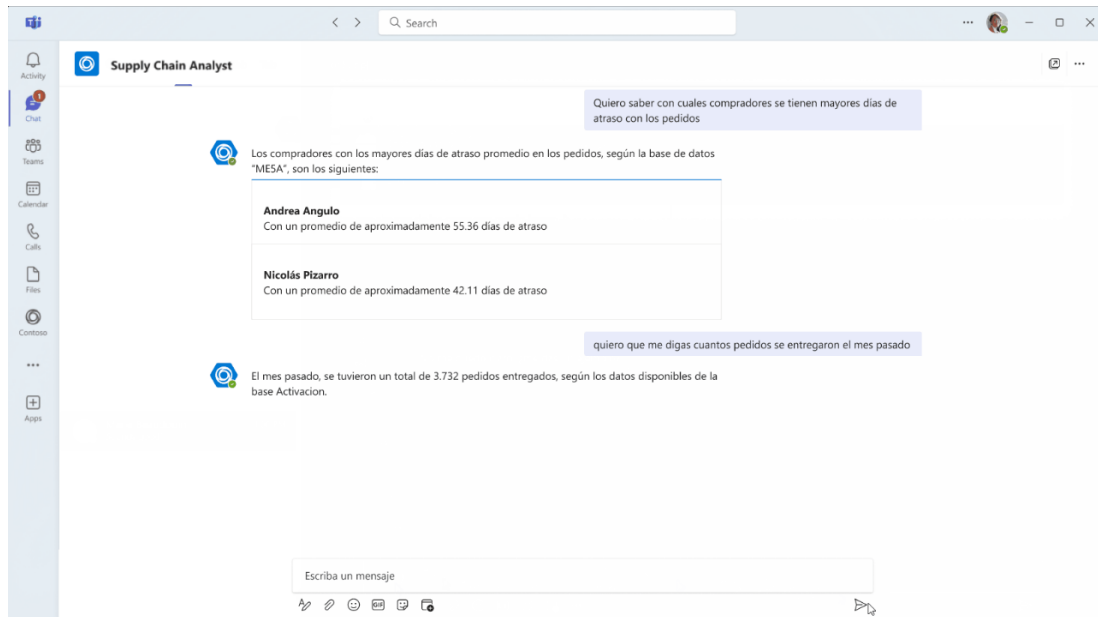


Ilustración 1: Mockup inicial de chatbot

Capítulo 4: Objetivos

4.1. Objetivo general

El objetivo general del proyecto es:

Diseñar e implementar un chatbot en el área de Supply Chain con foco en el acceso a información clave, el cual busca facilitar y agilizar la toma de decisiones para los cargos gerenciales.

4.1.1. Objetivos específicos

Los objetivos específicos del proyecto son:

- Analizar detalladamente las bases de datos ME5A, OC, Activación y OTIF de la empresa SQM para identificar patrones, tendencias y posibles anomalías.
- Llevar a cabo el proceso extracción, transformación y carga (ETL) en las bases de datos ME5A, OC, Activación y OTIF, optimizando su estructura para mejorar su accesibilidad y utilidad.
- Crear e implementar prompts específicos que faciliten la comprensión y el uso efectivo de las bases de datos ME5A, OC, Activación, OTIF y Despachos por parte del modelo LLM.
- Diseñar e implementar un frontend intuitivo y funcional para el chatbot, que permita a los usuarios interactuar de manera sencilla y eficiente con el sistema.
- Diseñar e implementar un marco de evaluación para medir y analizar el rendimiento del chatbot en términos de precisión, eficiencia y satisfacción del usuario.
- Llevar a cabo un análisis exhaustivo de la usabilidad del chatbot después de las pruebas, recopilando y evaluando feedback de los usuarios para identificar áreas de mejora.

Capítulo 5: Alcances

Para delimitar los alcances del proyecto y fundamentar la elección de esta solución, se establece que el desarrollo del chatbot se enfocará en dos etapas: la prueba de concepto y la entrega de un producto mínimo viable. En este contexto, el chatbot se diseña para traducir texto a consultas SQL (text-to-sql según sus siglas en inglés. Para saber más de esta herramienta ver sección 6.4.1) en las bases de datos designadas.

- **Bases de datos:** Para el desarrollo del chatbot se considerarán las bases de datos relacionadas con las solicitudes de pedido (ME5A), órdenes de compra (OC), órdenes de compra activadas (Activación), On Time In Full (OTIF) y sabanilla de despachos, quedando fuera del alcance las bases de datos relacionadas a bodegas, presupuesto, contratos y seguridad. La razón de esta exclusión se basa en la falta de tiempo para limpiar o traducir las bases, o bien por un problema de congelamiento del equipo de TI de SQM, ya que hay una paralización de la toma de requerimientos por parte del departamento.
- **Funciones:** Se implementa la herramienta de Prompt Chaining (para saber más de esta herramienta ver sección 6.5.1) la cual permite al usuario realizar consultas de las bases integradas nombradas anteriormente, consultas de datos contenidos en reportes en Power BI y, como función adicional, posibilita realizar preguntas generales (por ejemplo, "¿Quién es el presidente de Chile?"). Una limitación de las funciones del chatbot es que solo puede responder traduciendo la pregunta del usuario a una consulta SQL y luego traduciendo el resultado de esa consulta a texto. Puede mostrar la información en un párrafo o tabla, pero no tiene la capacidad de generar imágenes o gráficos, utilizar Python de forma automática, ni obtener audio en lugar de texto, entre otras funciones. Por otro lado, la función de búsqueda de reportes se limita a proporcionar únicamente el enlace del reporte y requiere permisos de acceso desde la base de datos, restringiendo el acceso solo a usuarios autorizados con las credenciales adecuadas. Estas limitaciones se justifican con el objetivo de obtener un producto mínimo viable dentro del tiempo y los recursos disponibles.
- **Grupo de pruebas:** Las pruebas de usabilidad del chatbot se están llevando a cabo con un grupo específico de usuarios dentro del área de ABO (Abastecimiento Operacional) de Supply Chain (ver anexo B.2). La razón de esta exclusión a las otras áreas se debe a que aún no se tienen implementadas bases de datos útiles para esas áreas o por problemas de coordinación con más personas de otras gerencias.

Capítulo 6: Marco conceptual

El desarrollo del chatbot en el área de Supply Chain de SQM está estrechamente relacionado con varias disciplinas de la ingeniería civil industrial. El análisis de datos y la ingeniería de datos desempeñan un papel crucial, puesto que el proyecto implica la extracción, transformación y carga de datos (ETL), así como la realización de un análisis de datos exploratorio en las primeras fases del proyecto. Además, la gestión de proyectos también es esencial para coordinar las distintas fases de desarrollo e implementación del chatbot, asegurando que los objetivos se cumplan de manera eficiente y efectiva. Estas disciplinas combinadas permiten abordar el proyecto de manera integral, garantizando un impacto positivo en la empresa.

A continuación, se mencionan teorías, modelos y/o conceptos que son relevantes para el proyecto.

6.1. Inteligencia Artificial Generativa

La inteligencia artificial generativa (conocida como GenAI en inglés) es una categoría amplia que engloba cualquier tipo de inteligencia artificial capaz de generar nuevos textos, imágenes, videos o audio. Este tipo de IA aprende de patrones a partir de datos de entrenamiento y produce resultados únicos con las mismas propiedades estadísticas (Rouse, 2024), como se ilustra en el ejemplo del anexo D.1.

La GenAI utiliza prompts para guiar la generación de contenido y emplea el aprendizaje por transferencia para mejorar su competencia. Si bien los primeros modelos se crearon con aplicaciones y tipos de datos específicos, el campo de la GenAI está evolucionando rápidamente hacia modelos multimodales, lo que significa que un mismo modelo puede manejar diversos tipos de datos y generar diferentes tipos de resultados (Rouse, 2024).

Actualmente, la tecnología de GenAI se emplea para aumentar la productividad y permitir que las personas dediquen más tiempo y energía a tareas de mayor valor. En campos de investigación donde los datos son escasos o costosos de obtener, la GenAI puede simular o amplificar los datos, acelerando así los resultados (Rouse, 2024).

Sin embargo, el uso indebido de la GenAI puede tener consecuencias negativas, como la clonación de voces para estafas. Esto puede afectar la confianza en las instituciones económicas, sociales y políticas. Además, dado que es una tecnología emergente, su adopción requiere un cambio cultural en las empresas para su implementación segura.

En el contexto del proyecto, se ha optado por utilizar GenAI como una forma de innovar en la recolección de información para el análisis de datos y la toma de decisiones. Se emplea GenAI para desarrollar un chatbot capaz de interactuar con los usuarios, responder preguntas frecuentes y proporcionar recomendaciones basadas en datos en tiempo real. Este chatbot también puede integrar y analizar grandes volúmenes de datos, facilitando así una toma de decisiones más ágil y precisa.

Para aprovechar al máximo esta tecnología, es necesario contar con experiencia en la creación y gestión de soluciones de IA a gran escala. Las empresas deben implementar las herramientas, procesos y estrategias de gestión adecuadas para garantizar el éxito de la implementación (Abdelhalim, 2023).

6.2. Procesamiento de lenguaje natural

El procesamiento de lenguaje natural (PLN) es la capacidad de un programa computarizado para comprender el lenguaje humano hablado y escrito, es decir, el lenguaje natural (Gillis, 2024).

En el ámbito del PLN, se emplean enfoques basados en reglas o en aprendizaje automático para analizar la estructura y el significado del texto. Esta tecnología desempeña un papel esencial en diversas aplicaciones, como chatbots, asistentes de voz y sistemas de traducción, entre otros (Gillis, 2024).

Dentro del contexto del proyecto, la implementación de PLN tiene como objetivo principal extraer información relevante de datos no estructurados basados en texto y posteriormente acceder a dicha información para obtener una comprensión más profunda de los datos en cuestión (Google Cloud).

El PLN facilita la interacción de los usuarios con el chatbot mediante el uso del lenguaje natural, es decir, el mismo lenguaje que emplearían al comunicarse con otra persona. Esta característica hace que la interacción sea más intuitiva y accesible, eliminando la necesidad de que los usuarios aprendan comandos específicos o terminología técnica. Además, permite que el chatbot sea flexible y se adapte a diferentes tipos de consultas y contextos, ya que puede reconocer sinónimos, variaciones gramaticales y diferentes formas de expresar una misma pregunta. Esta capacidad no sería posible de lograr con sistemas basados en comandos específicos o menús estáticos.

6.3. Modelo de lenguaje grande

Los modelos de lenguaje grande (conocidos como LLM en inglés) se entrenan con cantidades masivas de datos de texto heterogéneos y conjuntos de datos adaptados a

tareas específicas. Estos modelos son capaces de captar patrones estadísticos del lenguaje natural, lo que les permite generar nuevos textos complejos en función de la información proporcionada (Nicula y otros, 2023).

Los LLM son altamente adaptables a diversas tareas y dominios de procesamiento de lenguaje natural (PLN). Pueden ajustarse a conjuntos de datos o prompts para llevar a cabo una amplia variedad de tareas de generación de lenguaje natural, como resumir, traducir, completar textos y, como en el caso del proyecto, responder preguntas. Además, estos modelos manifiestan “capacidades emergentes”, es decir, habilidades para las que el modelo no fue específicamente entrenado, pero que son fáciles de resolver basándose en los patrones memorizados (Nicula y otros, 2023).

En el contexto del proyecto, se opta por utilizar GPT (Generative Pre-Trained Transformer en inglés) como herramienta de LLM a través de Langchain (ver anexo D.2 para benchmark realizado). Se elige esta herramienta debido a su capacidad avanzada en procesamiento de lenguaje natural, su adaptabilidad a contextos específicos, su eficiencia en la generación de respuestas, su capacidad para reducir la carga de trabajo manual, su integración con sistemas existentes y las continuas mejoras tecnológicas que ofrece. Además, GPT es una herramienta familiar para Brain Food.

6.4. Chatbot

Un chatbot es un sistema de Inteligencia Artificial diseñado para emular interacciones humanas con el fin de llevar a cabo una tarea específica. En la práctica, las plataformas de chatbot modernas exhiben una variedad de comportamientos y niveles de complejidad, pudiendo ofrecerse como aplicaciones independientes o como un servicio integrado en otra plataforma tecnológica (Skuridin & Wynn, 2024).

En el contexto del proyecto, se espera que el chatbot pueda responder a consultas formuladas por los usuarios en lenguaje natural, proporcionando respuestas escritas en forma de párrafos o tablas.

Los avances en modelos de lenguaje grande (LLM) y modelos generativos de texto han tenido un impacto significativo en el desarrollo de los chatbots. Uno de los avances más relevantes en el campo del Procesamiento del Lenguaje Natural (PLN) es la creación del modelo Generative Pre-trained Transformer (GPT) por OpenAI en 2018. Para este proyecto, se emplea la versión 1.14.3 de OpenAI.

Los chatbots representan una ventaja para las empresas al facilitar la atención al cliente a través de un estilo conversacional que resulta natural e intuitivo para los usuarios humanos.

Sin embargo, a pesar del rápido desarrollo tecnológico en este ámbito, las expectativas de éxito inmediato en la implementación de chatbots que muchas empresas tenían a mediados de la década pasada han sido reemplazadas por una actitud más escéptica hacia el potencial de los asistentes virtuales (Skuridin & Wynn, 2024). La falta de una cultura empresarial consolidada en el uso de esta tecnología dificulta su adopción.

La experiencia práctica ha demostrado que los chatbots no son efectivos en todas las situaciones, y la creación de un servicio de alta calidad requiere una inversión significativa. La complejidad tecnológica y la incertidumbre en los resultados del proyecto plantean desafíos adicionales a los equipos de implementación, que a menudo carecen de experiencia práctica y conocimientos teóricos sólidos (Skuridin & Wynn, 2024).

La decisión de desarrollar un chatbot en lugar de optar por una solución aparentemente más sencilla es estratégica y ofrece beneficios significativos a largo plazo. A través de la automatización, la accesibilidad, la escalabilidad y la mejora continua, el chatbot proporciona una solución robusta y eficiente que aborda las complejas necesidades de información de SQM. Esto no solo optimiza las operaciones actuales, sino que también prepara a la empresa para adaptarse y crecer en el futuro.

6.4.1. Text-to-SQL

El objetivo del texto a SQL (text-to-SQL) es generar una consulta SQL que responda de manera precisa a una pregunta determinada. Por ejemplo, en la Ilustración 2 (Jeong y otros, 2023), para la pregunta: «Nombra el número de semana para el sitio de juego siendo el estadio memorial para los buffalo bills», el modelo text-to-SQL genera una consulta SQL: “*SELECT COUNT(Week) FROM table WHERE Game_Site = «Memorial Stadium» AND Opponent = «Buffalo Bills».*”

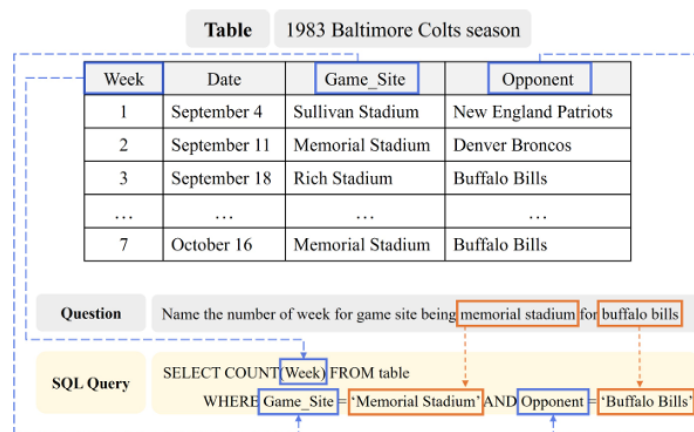


Ilustración 2: Ejemplo text-to-sql

El text-to-SQL resulta altamente útil en aplicaciones prácticas. Para buscar información en las tablas de una base de datos, se requiere un conocimiento sólido de SQL. Por lo

tanto, acceder y buscar información en una base de datos puede resultar difícil para usuarios sin experiencia en SQL. No obstante, al utilizar el modelo texto a SQL, incluso los usuarios sin conocimientos técnicos pueden buscar información fácilmente en una base de datos utilizando preguntas en lenguaje natural (Jeong y otros, 2023). Es por esta razón que se opta por emplear esta herramienta en el proyecto.

Sin embargo, presenta la desventaja de que el bot puede generar una consulta SQL incorrecta en ciertos casos. Por ejemplo, si en lugar de proporcionar la palabra "Buffalo Bills" como en el ejemplo anterior, se introduce solo "Buffalo" al formular la pregunta, la consulta SQL resultante podría buscar un oponente llamado "Buffalo" en lugar de "Buffalo Bills". Para abordar este problema, en el proyecto se han diseñado queries de ejemplo que guían al bot para utilizar la instrucción LIKE en la consulta SQL en lugar de utilizar '=' en determinadas circunstancias.

6.5. Prompts

En el ámbito de la interacción con la Inteligencia Artificial, un prompt se erige como la entrada clave que facilita la comunicación con la máquina. En esencia, representa la frase utilizada para formular preguntas, propuestas u órdenes a la IA (Pepinosa, 2023).

El prompt desempeña un papel crucial al permitir que las máquinas comprendan las solicitudes y generen respuestas significativas. A diferencia de los sistemas tradicionales que requerían comandos específicos o interfaces gráficas complejas, estos modelos se comunican a través del lenguaje natural.

La claridad del prompt resulta fundamental, ya que su comprensión precisa se traduce en respuestas más acertadas por parte de la IA. Cuanto más preciso y específico sea el prompt, mayores serán las posibilidades de obtener la respuesta deseada (Pepinosa, 2023).

Además del prompt evidente utilizado al formular preguntas, el chatbot desarrollado por el equipo de trabajo se guía mediante prompts diseñados para su entrenamiento y para responder correctamente a las consultas. Estos prompts contienen información sobre cada base de datos y detalles específicos de la empresa para asegurar respuestas coherentes. Asimismo, se proporcionan indicaciones detalladas, como utilizar la instrucción LIKE al buscar un nombre o buscar productos en singular. En el anexo D.3 se ilustra un ejemplo del prompt que proporciona un contexto inicial al bot.

No obstante, el sistema no es infalible y presenta limitaciones. Dada la extensa cantidad de prompts (casi 10 mil caracteres), el chatbot ocasionalmente no sigue estas indicaciones y produce respuestas inexactas. Para mitigar este problema, se procura ofrecer instrucciones claras mediante prompts como "haz esto obligatoriamente" o "utiliza exclusivamente...".

6.5.1. Prompt chaining

El prompt chaining representa una técnica empleada en la Inteligencia Artificial conversacional, la cual aprovecha los LLM para interpretar las entradas del usuario y generar respuestas coherentes y contextualmente relevantes. Esta estrategia da lugar a un chatbot dinámico y consciente del contexto, capaz de proporcionar respuestas personalizadas basadas en conversaciones previas o en la configuración del asistente, lo que contribuye a mejorar la experiencia del usuario (Botpress, 2023).

En el marco del proyecto, el prompt chaining se utiliza con el propósito de ofrecer respuestas diferenciadas según la naturaleza de las consultas. Por ejemplo, se emplea un enfoque distinto para las preguntas relacionadas con compras y proveedores, en comparación con las consultas sobre contenido en reportes o cuestiones más generales.

El prompt chaining utilizado en el proyecto se clasifica en tres categorías. Para las preguntas sobre compras y proveedores, se utiliza el modelo GPT4, que ofrece respuestas más precisas, y se emplea la técnica text-to-SQL para manejar consultas de mayor complejidad. Además, en esta clasificación se hace uso de la librería Vanna.AI, conocida por su eficacia en el manejo de consultas SQL.

Por otro lado, para las consultas de menor complejidad, se recurre al modelo GPT3.5 y se utiliza la librería Langchain, ya que estas preguntas suelen ser de naturaleza text-to-text y requieren menos precisión en las respuestas. El anexo D.4 ilustra un ejemplo del prompt utilizado para clasificar las consultas según su naturaleza.

Capítulo 7: Metodología

7.1. Metodología de referencia

Las metodologías utilizadas durante la realización del proyecto son la metodología CRISP-DM (Roberto, 2022) y DevOps (García, 2023).

La metodología CRISP-DM involucra los pasos iniciales de comprensión del negocio, comprensión de los datos, preparación de los datos y el despliegue.

La metodología de DevOps facilita la integración continua y la entrega eficiente del chatbot, lo que es fundamental para cumplir con los plazos establecidos para el proyecto. Se involucran las etapas de planificación, desarrollo, integración continua, monitoreo y feedback y mejora continua.

7.2. Metodología desarrollada durante el proyecto

El proyecto se divide en dos etapas distintas: prueba de concepto (POC) y la creación del producto mínimo viable (MVP). En la fase inicial, la prueba de concepto tiene como objetivo validar la viabilidad técnica y funcional del chatbot mediante la implementación de un prototipo inicial. En la segunda etapa se desarrolla y entrega una versión simplificada pero funcional del chatbot que cumple con los requisitos básicos identificados durante la prueba de concepto. El foco principal está en la implementación de las funcionalidades clave necesarias para proporcionar una experiencia de usuario satisfactoria.

7.2.1. Etapas de POC

Para todas estas etapas se ocupa la metodología CRISP-DM.

- **Etapas 1:** “Comprensión del negocio”. Se entiende el dolor del usuario y el impacto que puede tener esta herramienta sobre el área de Supply Chain.
- **Etapas 2:** “Comprensión de los datos”. Se recopilan y exploran los datos disponibles para conocer su calidad y relevancia en el proyecto.
- **Etapas 3:** “Preparación de los datos”. Se seleccionan, limpian y transforman los datos relevantes.
- **Etapas 4:** “Despliegue”. Los datos se cargan y monitorean, realizando ajustes según sea necesario.

7.2.2. Etapas de MVP

Para todas estas etapas se ocupa la metodología DevOps.

- **Etapas 5:** “Planificación”. Se definen los objetivos y las funcionalidades del chatbot.
- **Etapas 6:** “Desarrollo de chatbot”. Se escribe y se gestiona el código del backend y frontend del chatbot.
- **Etapas 7:** “Integración continua”. Se automatiza la integración de nuevos códigos con el existente en Dev. Cada cambio realizado en el código se integra regularmente en un repositorio central (usando Git).
- **Etapas 8:** “Monitoreo y feedback”. Se supervisa el desempeño del chatbot durante las pruebas de usabilidad y se recopila el feedback de los usuarios.
- **Etapas 9:** “Mejora continua”. El equipo realiza mejoras en el chatbot basándose en el feedback de los usuarios.

7.2.3. Ventajas y limitaciones de metodología

La metodología CRISP-DM, resulta crucial para el POC, ya que permite una exploración exhaustiva y un entendimiento profundo del problema del usuario, la calidad de los datos y su preparación antes de la implementación. Esta metodología ofrece ventajas como una estructura clara para el análisis y la gestión de datos, aunque puede presentar limitaciones en términos de flexibilidad y adaptabilidad a cambios rápidos en las necesidades del negocio.

Por otro lado, la metodología DevOps aplicada al MVP, facilita un proceso ágil e iterativo para la creación y optimización del chatbot. DevOps permite una integración fluida y continua de nuevas funcionalidades, mejora la colaboración entre equipos y acelera el ciclo de desarrollo mediante la automatización. Sin embargo, su enfoque intensivo en la automatización y la integración continua puede llevar a una complejidad adicional en la gestión de versiones y a la necesidad de una infraestructura sólida para soportar el proceso de desarrollo.

7.3. Recursos relevantes

7.3.1. Librerías

Se muestran las principales librerías ocupadas en el desarrollo del chatbot, las cuales son fundamentales para el desarrollo y éxito del chatbot. Estas herramientas aseguran que el chatbot no solo cumpla con los requisitos técnicos, sino que también ofrezca una experiencia de usuario superior, mejorando significativamente la eficiencia operativa y la toma de decisiones dentro de la organización.

7.3.1.1. Langchain

LangChain se presenta como un framework diseñado para el desarrollo de aplicaciones que se fundamentan en modelos de lenguaje grandes. Su objetivo principal es facilitar la integración de LLMs, como GPT-3.5 y GPT-4 de OpenAI, con diversas fuentes de datos externas, permitiendo así la creación y aprovechamiento de las ventajas ofrecidas por las aplicaciones de procesamiento del lenguaje natural (PLN). LangChain optimiza los procesos intermedios involucrados en el desarrollo de estas aplicaciones, lo que se traduce en una ingeniería de prompts más eficiente y efectiva (AWS).

La elección de LangChain para el proyecto se fundamenta en su notable versatilidad, ya que es capaz de conectarse con una amplia gama de modelos y bases de datos vectoriales. Además, la existencia de recursos de apoyo, como blogs y documentación, facilita considerablemente el proceso de desarrollo.

7.3.1.2. Vanna.AI

Vanna se presenta como una librería de Python que aprovecha el Retrieval-Augmented Generation (RAG) para generar consultas SQL precisas para bases de datos utilizando LLMs (Vanna.AI).

Su funcionamiento se divide en dos pasos fundamentales: en primer lugar, entrena un "modelo" RAG en los datos pertinentes; posteriormente, formula preguntas que resultarán en consultas SQL específicas, las cuales pueden ser configuradas para ejecutarse automáticamente en la base de datos (Vanna.AI).

En el contexto del proyecto, durante la etapa inicial de prueba de concepto, se optó por Langchain para la generación de consultas. Sin embargo, esta herramienta mostraba demoras significativas y presentaba fallos en varias ocasiones. Por ende, se buscó una alternativa más efectiva, lo que llevó al descubrimiento de Vanna. Esta herramienta, además de ser simple de utilizar, se basa en los datos de entrenamiento proporcionados, como las consultas de ejemplo y metadata de las bases de datos.

7.3.1.3. Streamlit

Streamlit es una poderosa y accesible librería de código abierto en Python que simplifica considerablemente la creación de aplicaciones web interactivas para el machine learning y la ciencia de datos. Esta herramienta permite desarrollar aplicaciones informativas y visualmente atractivas de manera sencilla (Streamlit).

Una de las principales ventajas de Streamlit es su facilidad de uso e implementación. Gracias a una variedad de widgets disponibles, facilita la creación de un chatbot más interactivo y amigable con el usuario. Dado que el proyecto se encuentra aún en etapas tempranas de desarrollo, Streamlit se presenta como la opción más conveniente para construir rápidamente un prototipo funcional del chatbot.

7.3.2. Softwares

7.3.2.1. GIT

Se utiliza la herramienta de control de versiones GIT para gestionar el desarrollo del código. Se establecen diferentes ramas, como "Main" para la versión definitiva del código, "Dev" para las demos, y ramas adicionales para agregar y mejorar el código existente. En el anexo E.6 se incluye una imagen que ilustra el flujo de trabajo utilizando Gitflow.

7.3.2.2. Azure Synapse

Es un servicio de análisis empresarial que acelera el tiempo necesario para obtener información de los sistemas de almacenamientos de datos y de macrodatos. Reúne tecnologías SQL que se usan en el almacenamiento de datos empresariales, la tecnología Apache Spark que se utilizan para macrodatos y Azure Data Explorer para el análisis de registros y de series temporales (Microsoft).

7.3.2.3. Dbeaver

DBeaver es un potente software de gestión de bases de datos, libre y de código abierto. Esta herramienta permite crear todos los componentes necesarios en una base de datos, tales como esquemas, tablas, disparadores, funciones, usuarios y roles. Además, facilita la ejecución de consultas SQL y NoSQL, la creación, modificación y eliminación de registros, así como la exportación y migración de datos. DBeaver también ofrece la funcionalidad de generar respaldos, crear datos simulados para pruebas y elaborar diagramas del modelo entidad-relación.

Capítulo 8: Desarrollo

8.1. Etapas de POC

- **Etapa 1:** “Comprensión del negocio”. Se llevan a cabo reuniones con stakeholders del área de Supply Chain de SQM para entender sus necesidades y cómo un chatbot podría ayudar a mejorar el acceso a información clave. Además, se realiza un análisis de los procesos actuales de acceso a la información y toma de decisiones, identificando puntos de dolor y oportunidades de mejora.
- **Etapa 2:** “Comprensión de los datos”. Se recopila información de diversas bases de datos de la empresa SQM, incluyendo las bases ME5A, OC, Activación y OTIF. Para esto se realiza un análisis exploratorio de datos (EDA) para entender la estructura y el contenido de las bases de datos, esto incluye la identificación de campos relevantes, tipos de datos, valores nulos y distribución de valores. Dado que las tablas provienen de SAP, presentan campos con nombres poco comprensibles, como "estado_liberacion", "indicador_borrado", "dias_transcurridos", "backlog", "status_tratamiento", entre otros, junto con valores como "L", "S", "Z04" o "S09". Por ello, el equipo se reúne con un ingeniero del área de ABO, quien posee conocimientos detallados sobre los campos al estar muy familiarizado con el reporte "Dialogo de Desempeño", que contiene las bases de compras en estudio.
- **Etapa 3:** “Preparación de los datos”. Se extraen los datos de las bases originales, luego se limpian y transforman para hacerlos más comprensibles y relevantes para el chatbot ocupando la plataforma Azure Synapse, mediante un dataflow que copia y modifica las bases originales. Esto incluye la eliminación de columnas innecesarias y el renombrado de campos a un lenguaje más intuitivo. Es importante destacar que este proceso fue iterativo y se ajustó conforme se realizaban pruebas, modificando nombres de campos y añadiendo o eliminando campos según fuese necesario.
- **Etapa 4:** “Despliegue”. En la plataforma de Azure Synapse, se crean tablas externas utilizando datos depurados almacenados en un archivo Parquet. Estas tablas se ubican dentro de una base de datos Azure SQL y están disponibles para ser utilizadas por el chatbot. Las tablas se encuentran en un esquema denominado "CONSUMPTION_LLM".

8.2. Etapas de MVP

- **Etapa 5: “Planificación”.** Se identifican y desglosan todas las tareas necesarias para el desarrollo del chatbot. El equipo se reúne para evaluar las funciones primordiales que el chatbot debe tener. Considerando que se trata de un producto mínimo viable, la estrategia es comenzar con una versión simple y posteriormente ir agregando más funciones conforme sea necesario. Se desarrolla una investigación y con esto se seleccionaron librerías útiles para el desarrollo del chatbot.
- **Etapa 6.1: “Desarrollo de chatbot” (Backend).** Se desarrollan las funciones principales del chatbot en Python, incluyendo la integración con las bases de datos previamente depuradas y la técnica de prompt chaining, que solicita al chat que clasifique la pregunta del usuario como 1, 2 o 3, y, según la respuesta, ejecuta la pregunta con el contexto y la librería correspondiente. Esta fase además incluye la construcción de prompts (prompt engineering) necesarios para que el chat pudiera conocer las bases y además poder clasificar bien cada pregunta realizada. Se integra un plan de reducción de alucinaciones, fabricando preguntas sobre las bases de compra, OTIF o despachos con su respectiva query. Las preguntas que los usuarios realizan con mayor frecuencia se incluyen como queries de ejemplo.
- **Etapa 6.2: “Desarrollo de chatbot” (Frontend).** Se diseña la interfaz de usuario usando Streamlit, asegurando que fuera intuitiva y fácil de usar. Se realiza una página de bienvenida, pidiendo al usuario entrar con su cuenta de Microsoft para poder comenzar a hacer preguntas. Se agregan páginas adicionales, además de la que contiene al chatbot. Estas son “FAQ”, la cual contiene información sobre las bases que a las que tiene acceso el chatbot y algunas queries de ejemplo para que el usuario conozca que preguntas puede contestar bien el chatbot. También están las páginas “COyA” y “ABE” que contienen un texto que informa al usuario que ambas páginas se encuentran en proceso de construcción. Al abrir el chatbot se muestra hasta que fecha están actualizados los datos. Se integra botón de “Me gusta” o “No me gusta” que aparece cuando el chatbot da una respuesta, para que el usuario pueda calificar la respuesta y el equipo pueda revisar las preguntas que salieron bien y arreglar/mejorar las que están mal calificadas. Además, se agrega un botón que permite al usuario ver la query que se utiliza para generar la respuesta y otro botón que le permite al usuario poder ver el dataframe generado a más detalle (se muestran todas las columnas y filas generadas. Se agrega visualización de carga para cuando el chatbot está generando una respuesta.
- **Etapa 7: “Integración continua”.** Se utiliza Git para gestionar el código fuente. Se crearon ramas específicas para diferentes funcionalidades (Dev para desarrollo

y Main para la versión definitiva). Cada vez que se integra nuevo código, se ejecutan pruebas manuales para asegurar que las nuevas funcionalidades no introducen errores en el sistema existente. Cuando se asegura que las nuevas funcionalidades funcionan de manera correcta, se realiza un merge de estas ramas "Feature" a la rama "Dev".

- **Etapa 8: "Monitoreo y feedback"**. Se implementa herramienta llamada "Termómetro LLM" para monitorear el desempeño del chatbot en las pruebas de usabilidad y recopilar el feedback de los usuarios para poder hacer respectivas mejoras y/o arreglos de bugs, esta herramienta toma los datos desde un CSV. Este archivo contiene los datos de cada pregunta, respuesta, query, clasificación de la pregunta, tiempo de respuesta y calificación proporcionada por el usuario ("Me gusta" o "No me gusta"), para luego cargarlos a un PowerBI que tiene una interfaz que permite ver el tiempo promedio de respuesta durante la sesión, la cantidad de preguntas correctamente evaluadas y su porcentaje. Además, se organizan reuniones cada dos semanas con usuarios para que puedan poner a prueba al chatbot realizando preguntas. Estas pruebas son cruciales para evaluar el desempeño y obtener feedback directo. Después de cada sesión de prueba, se realiza un levantamiento que compila y analiza el feedback recibido. Se identifican áreas de mejora y se priorizan las acciones a tomar.
- **Etapa 9: "Mejora continua"**. Las mejoras se realizan continuamente en base al feedback. Esto incluye ajustar los prompts, modificar las queries de ejemplo, y refinar el código para mejorar el rendimiento y la precisión del chatbot, además de añadir nuevas funciones, como que entregara datos en tablas o agregar nuevas bases de datos a pedido de los usuarios.

Capítulo 9: Resultados

9.1. Etapas de POC

- **Etapa 1:** “Comprensión del negocio”. Como resultado del conocimiento más profundo del problema del usuario, se arma el flujo de Ilustración 3 (Pérez, 2023). Se observa que el proceso más demorado es el del analista, que generalmente para responder al requerimiento necesita descargar la base de datos desde SAP y luego de eso aplicar filtros necesarios para poder encontrar la información que el Gerente requiere.

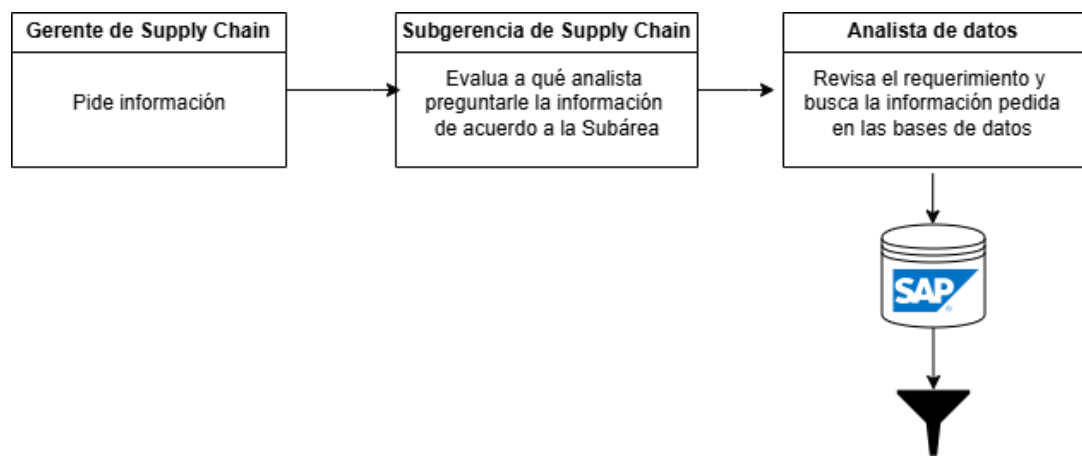


Ilustración 3: Flujo de consultas en altos ejecutivos

- **Etapa 2:** “Comprensión de los datos”. Se realiza la metadata de varias bases de datos, proporcionando detalles específicos de cada una. La base ME5A contiene 46 columnas, la base OC tiene 45 columnas, la base Activacion consta de 33 columnas y la base OTIF 25 columnas. Todos estos detalles se registran en un archivo Word que está disponible para todo el equipo. Se muestra una página de la metadata de la base activación en anexo E.1.
- **Etapa 3:** “Preparación de los datos”. Se muestran algunos de los cambios realizados a los datos en anexo E.3, se puede ver que se realizaron cambios de nombre, formato de columnas y se agregaron filtros pedidos por los stakeholders.
- **Etapa 4:** “Despliegue”. La base ME5A se reduce a 9 columnas, la base OC a 24 columnas, la base Activacion a 11 columnas y la base OTIF a 20 columnas. Se pueden ver los campos que resultan en anexo E.4.

9.2. Etapas de MVP

- **Etapa 5: “Planificación”**. Se define flujo de chatbot que se ve en la Ilustración 4 (elaboración propia). Inicialmente, se emplea Langchain, y posteriormente se integrará Streamlit para el frontend, seguido por Vanna.AI para refinar las consultas SQL.

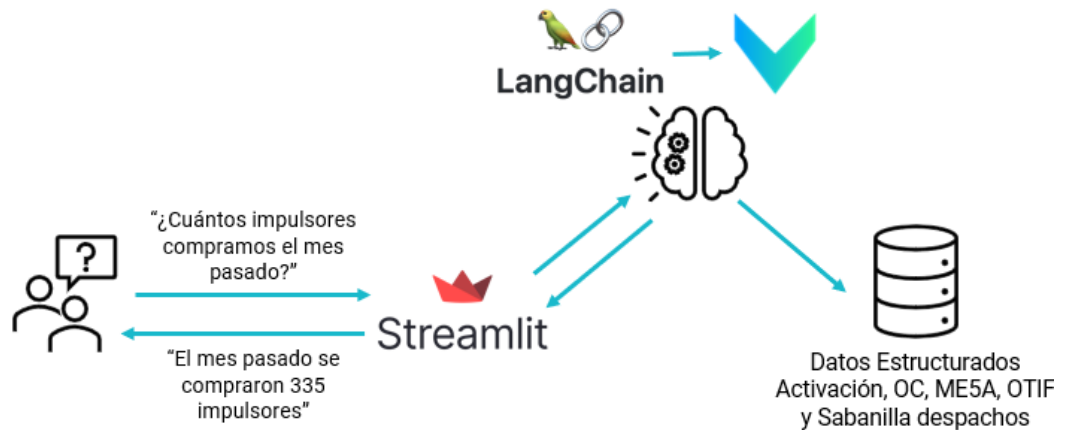


Ilustración 4: Flujo de chatbot

- **Etapa 6.1: “Desarrollo de chatbot” (backend)**. Se muestra el flujo del prompt chaining en la Ilustración 5 (elaboración propia). Además, se adjunta una imagen de algunas queries de ejemplo en anexo E.2.

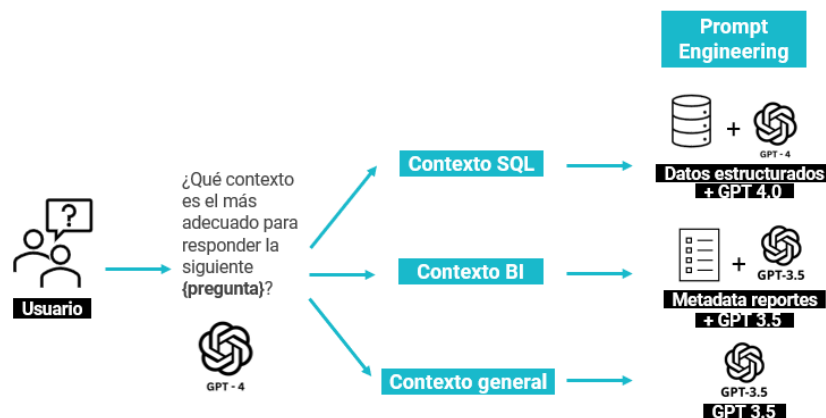


Ilustración 5: Flujo de Prompt Chaining

- **Etapa 6.2: “Desarrollo de chatbot” (frontend)**. En particular, el indicador de "cargando respuesta" ha sido bien recibido por los usuarios, ya que les proporciona una sensación de certeza durante la espera. Además, la inclusión de una página de preguntas frecuentes (FAQ) ha sido útil para orientar las consultas de los usuarios, lo que ha contribuido a mejorar la precisión y relevancia de las respuestas del chatbot. En anexo E.5, se muestra la página de bienvenida y la información

que se muestra en la sección FAQ. En la Ilustración 6 se puede ver la interfaz del chatbot actual, donde se indica la pregunta, respuesta del chatbot y query utilizada.

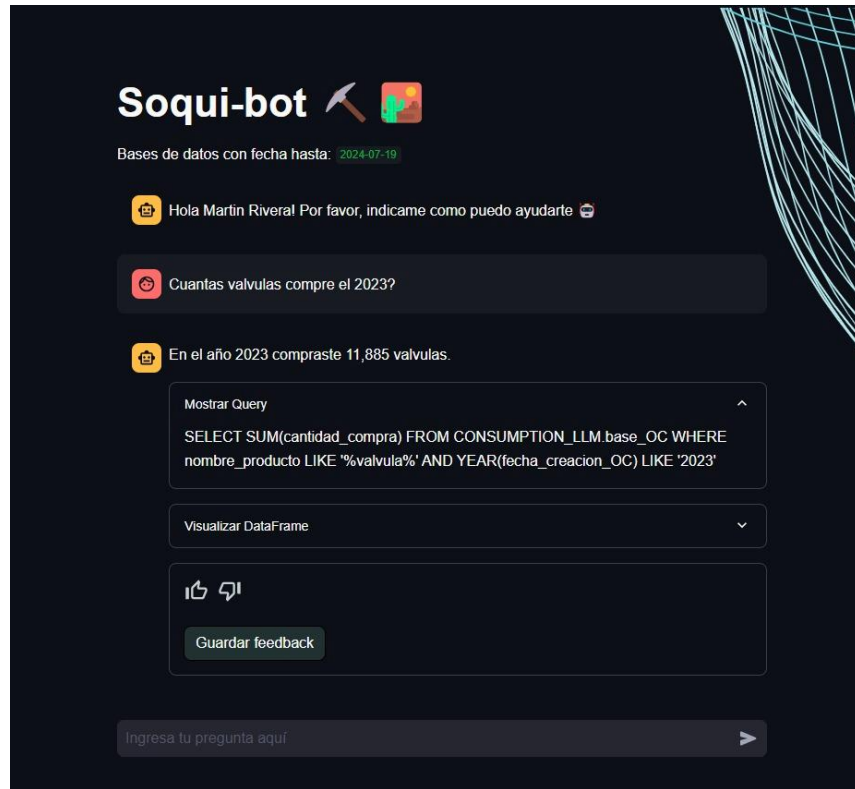


Ilustración 6: Interfaz de chatbot

- **Etapa 7:** “Integración continua”. Se muestra el flujo de GIT para la creación de ramas en anexo E.6.
- **Etapa 8:** “Monitoreo y feedback”. Se muestra la imagen de la herramienta Termómetro LLM en anexo E.8, la cual permite evaluar rápidamente como fue el desempeño de una prueba de usabilidad con algún usuario.
- **Etapa 9:** “Mejora continua”. Se observa una lista de funcionalidades que se agregan y bugs que son arreglados como resultado de los feedback de usuarios (anexo E.9). Se puede notar que ha mejorado el desempeño del chatbot desde la demo 1 a la demo final (anexo E.7). Actualmente el chatbot está contestando con un promedio de tiempo de 15 segundos con las preguntas con queries.

Capítulo 10: Discusiones

10.1. Análisis crítico de objetivos

Los objetivos planteados inicialmente fueron claros y ambiciosos, centrados en mejorar el acceso a la información y facilitar la toma de decisiones mediante un chatbot. Sin embargo, la estudiante ve necesario cuestionar si estos objetivos cubren todas las necesidades críticas de la empresa. Por ejemplo, se podría considerar si el chatbot debe incluir funciones de análisis predictivo para anticipar problemas de abastecimiento. Una posible alternativa es incorporar análisis predictivos dentro del chat, esto implicaría costos significativos y complejidades técnicas, ya que requiere la recopilación y limpieza de datos históricos, el desarrollo de algoritmos de machine learning y la contratación de expertos en datos.

10.2. Análisis crítico de alcances

Ambas partes (empresa y estudiante) cuestionan la decisión de no agregar más bases de datos de otras subáreas, ya que se dedica mucho tiempo a afinar los datos de compras, OTIF y despachos. Una alternativa podría haber sido aumentar el equipo, permitiendo que una parte de éste se enfocara en los datos existentes mientras la otra parte trabajaba en la incorporación de nuevas bases de datos. Aunque esto habría incrementado los costos debido a la necesidad de más personal y recursos, el beneficio habría sido significativo: el chatbot podría haber servido a una mayor parte de las subáreas de Supply Chain, proporcionando un acceso más amplio y completo a la información crítica.

10.3. Análisis crítico de resultados

Una mayor colaboración con los usuarios desde el inicio podría haber identificado necesidades adicionales y ajustado los objetivos del chatbot de manera más precisa. Esto ocurre debido a comunicación insuficiente con los usuarios. Una alternativa hubiera sido realizar encuestas a los altos cargos, lo que habría permitido una recolección continua de feedback y necesidades de los usuarios, permitiendo ajustes más precisos.

La estudiante cuestiona que no se pudo medir objetivamente el desempeño del chatbot, ya que la evaluación fue principalmente manual debido a la falta de tiempo para investigar e implementar herramientas adecuadas. Como alternativa, se podría haber utilizado inteligencia artificial para evaluar automáticamente si las respuestas del chatbot estaban bien formuladas o no. Esta alternativa habría requerido más tiempo para el

desarrollo y capacidades técnicas más avanzadas en los miembros del equipo, pero habría proporcionado una evaluación más precisa y continua del rendimiento del chatbot, mejorando su calidad y fiabilidad a largo plazo.

Las queries de ejemplo se desarrollaron en base a las preguntas que el personal del área de ABO consideraba importantes. Sin embargo, estas queries no se validaron ni se ampliaron con aportes de la gerencia. Dado que el desempeño del chatbot depende en gran medida de la calidad de estas queries de ejemplo, la falta de validación con usuarios de alto nivel fue una limitante significativa. Realizar más demostraciones y obtener feedback directo de los gerentes habría garantizado un conjunto de queries de entrenamiento más robusto y relevante.

En cuanto a la investigación de herramientas de Large Language Models (LLM), inicialmente se utilizó Langchain, pero se observó que no ofrecía respuestas adecuadas al momento de interactuar con bases de datos, lo que llevó a tomar la decisión de continuar con el framework que ofrece Vanna. Una investigación más exhaustiva y temprana sobre las diferentes herramientas disponibles podría haber identificado la opción más adecuada desde el principio, ahorrando tiempo y recursos valiosos.

Uno de los desafíos actuales es la reducción de alucinaciones, es decir, respuestas incorrectas generadas por el chatbot. Para que sea realmente confiable, es crucial minimizar estos errores. Esto exige mejorar continuamente la calidad de los datos, las queries de ejemplo y la tecnología subyacente. Evaluar nuevos modelos de lenguaje e implementar mejores prácticas en la ingeniería de prompts son pasos necesarios, aunque requieren tiempo adicional y pueden aumentar los costos. Esto es esencial para que la Gerencia de SQM utilice el chatbot de manera efectiva en situaciones que demanden información precisa y rápida para los clientes.

Capítulo 11: Conclusiones

El proyecto desarrollado en Brain Food demuestra una concordancia entre los objetivos planteados y los resultados obtenidos. Se logra crear un chatbot capaz de manejar consultas complejas y proporcionar respuestas rápidas.

En el cumplimiento de los objetivos específicos, se logra analizar detalladamente las bases de datos ME5A, OC, Activación y OTIF, identificando patrones y anomalías, lo cual resulta en un archivo con metadata que documenta cada campo.

El proceso ETL se lleva a cabo con éxito, generando nuevas bases de datos con una estructura optimizada y más accesible, facilitando su uso por parte del chatbot. Se desarrollaron y se implementaron prompts específicos para mejorar la interacción del modelo LLM con las bases de datos, resultando en prompts efectivos que permiten al chatbot comprender y responder con precisión.

La implementación de un frontend intuitivo y funcional, construido en Streamlit, garantiza una interfaz amigable para los usuarios, permitiendo una interacción eficiente. Asimismo, se diseña un marco de evaluación para medir el rendimiento del chatbot, proporcionando una herramienta llamada "Termómetro LLM", que permite analizar la precisión y eficiencia del sistema. Se realiza un exhaustivo análisis de usabilidad, recopilando feedback de los usuarios para identificar y corregir áreas de mejora, resultando en una lista de ajustes y la posterior optimización del chatbot y las bases de datos.

La implementación exitosa del chatbot hará más eficiente la gestión de datos y la interacción con los usuarios, lo que se traducirá en una mayor satisfacción del cliente y una ventaja competitiva en el mercado. Cuando el chatbot esté completamente operativo, permitirá a los altos cargos de SQM obtener respuestas rápidas a sus consultas, agilizando la toma de decisiones y optimizando los procesos del área de Supply Chain.

El proyecto establece un marco robusto para futuras expansiones y mejoras, asegurando que el chatbot pueda adaptarse a nuevas necesidades y manejar una creciente cantidad de datos de manera eficaz. Cuando termine la participación de la estudiante, se entregará un chatbot listo para facilitar la forma en que se accede y se utiliza la información en la empresa, creando un impacto duradero en la eficiencia y la innovación de SQM.

El proyecto se encuentra en una etapa inicial con un enfoque en la creación de un producto mínimo viable (MVP). Aunque el chatbot ya muestra una mejora notable en la eficiencia y precisión en la gestión de datos, su funcionalidad podría ampliarse con la incorporación de más bases de datos y capacidades analíticas avanzadas. La dependencia de la calidad de los datos y la necesidad de mantenimiento continuo representan desafíos que deben ser abordados para garantizar la longevidad y efectividad del sistema.

Para el éxito del chatbot es necesario brindarle información al equipo de Supply Chain sobre el uso del chatbot y sus funcionalidades. Así se podría minimizar el margen de error al hacer preguntas en un lenguaje comprensible, teniendo conocimiento de las preguntas que es capaz de contestar y redactando las preguntas de una forma lo más entendible posible para el chatbot.

Desde un punto de vista académico, se puede continuar investigando cómo mejorar los algoritmos de procesamiento del lenguaje natural (NLP) y la integración de técnicas de inteligencia artificial (IA) más avanzadas para el chatbot. Profesionalmente, el trabajo puede ampliarse para incluir más subáreas de Supply Chain o a más áreas dentro de la empresa, como ventas y finanzas, proporcionando una herramienta integral que abarque todas las áreas críticas de SQM. Es crucial establecer un sistema de retroalimentación robusto que permita recoger y analizar continuamente las opiniones de los usuarios para iterar y mejorar el chatbot de manera constante. Además, realizar estudios periódicos para evaluar el impacto del chatbot en la eficiencia operativa y la toma de decisiones permitirá ajustar las estrategias según los resultados obtenidos, asegurando un impacto duradero y positivo en la empresa.

Así mismo, se establece que la introducción del chatbot responde a la necesidad de optimizar la eficiencia operativa y acelerar el acceso a datos relevantes, aspectos críticos en la industria minera. Desde una perspectiva de gestión del cambio, esta herramienta facilita una transición gradual hacia prácticas más digitales y automatizadas, promoviendo una cultura de innovación y adaptación tecnológica en la organización. Además de modernizar los procesos, el chatbot reduce la resistencia al cambio gracias a su interfaz intuitiva y centrada en el usuario, lo que mejora la aceptación y el uso continuo por parte del personal. Sin embargo, para garantizar su éxito, es crucial que se implementen estrategias efectivas de formación y comunicación, asegurando que todos los involucrados comprendan los beneficios y el funcionamiento del chatbot, lo que refuerza su papel como un catalizador en la evolución digital de la empresa.

Para finalizar, se dan las siguientes recomendaciones para la empresa:

- **Funcionalidades Interactivas:** Una posible extensión del proyecto es la incorporación de más funcionalidades interactivas. Esto incluye la capacidad de generar gráficos e imágenes en las respuestas del chatbot, proporcionando una visualización más clara y comprensible de los datos. Además, se podría implementar que el botón de "Me gusta" y "No me gusta" guarde las preguntas y respuestas en el training data del chatbot, mejorando su capacidad de aprendizaje y ajuste basado en la retroalimentación del usuario. También, un botón que explique la query utilizada por Vanna para responder permitiría a los usuarios comprender mejor cómo se generan las respuestas, aumentando la transparencia y confianza en el sistema.

- **Optimización del Tiempo de Respuesta:** El tiempo de respuesta del chatbot podría mejorarse aún más utilizando GPT-4 Turbo, una versión optimizada del modelo de lenguaje que promete tiempos de respuesta más rápidos sin comprometer la calidad de las respuestas. Esta actualización tecnológica podría hacer que el chatbot sea más eficiente y conveniente para los usuarios.
- **Expansión de Bases de Datos:** Otra extensión significativa sería agregar más bases de datos al chatbot. Queda pendiente integrar las bases de datos de las subáreas de Supply Chain de Control de Operaciones y Abastecimiento (COyA) y Abastecimiento estratégico (ABE).
- **Ampliación de Queries:** Más queries permitirían al sistema manejar una mayor variedad de preguntas y contextos, asegurando que pueda proporcionar respuestas precisas y relevantes en más situaciones.
- **Mejora de Metadata y RAG de Vanna:** Mejorar la metadata de las tablas y el sistema de Recuperación y Generación Automática (RAG) de Vanna haría que la información que el chatbot puede acceder sea más precisa y relevante, mejorando la calidad de las respuestas generadas
- **Evaluación de Otros Frameworks de LLM:** Se podría considerar la evaluación de otros frameworks de modelos de lenguaje, como volver a Langchain pero con un agente propio, utilizar Data Herald, o desarrollar un chatbot basado exclusivamente en prompt engineering. Estas alternativas podrían ofrecer diferentes ventajas y características que podrían ser beneficiosas para el proyecto, permitiendo una mayor flexibilidad y capacidad de adaptación a las necesidades específicas de la empresa.

Capítulo 12: Bibliografía

- Abdelhalim, L. (2023). Artificial Intelligence And Competitive Advantage In Algerian Companies: The Need To Understand The Relationship. *EBSCO*, 6, 141-157.
- Algabil, D. (enero de 2024). Inducción Brain Food.
- AWS. (s.f.). *¿Qué es LangChain?* Recuperado el mayo de 2024, de <https://aws.amazon.com/es/what-is/langchain/>
- botpress. (31 de agosto de 2023). *¿Qué es el encadenamiento de peticiones de AI?* Obtenido de <https://botpress.com/es/blog/what-is-ai-prompt-chaining>
- Botpress. (31 de agosto de 2023). *¿Qué es el encadenamiento de peticiones de AI?* Obtenido de <https://botpress.com/es/blog/what-is-ai-prompt-chaining>
- Brain Food. (s.f.). *Brain Food*. Recuperado el marzo de 2024, de <https://www.linkedin.com/company/brain-food-spa/mycompany/>
- Brain Food. (s.f.). *Servicios*. Recuperado el marzo de 2024, de <https://brainfood.cl/areas-de-servicios/>
- Brain Food. (s.f.). *Somos // Brain Food*. Recuperado el marzo de 2024, de <https://brainfood.cl/somos/>
- CBInsights. (27 de febrero de 2024). *The generative AI boom*. Recuperado el mayo de 2024, de <https://www.cbinsights.com/research/generative-ai-funding-top-startups-investors-2023/>
- Cipolla, A. I. (2021). *La importancia del análisis de datos en las empresas*. Obtenido de <https://openwebinars.net/blog/la-importancia-del-analisis-de-datos-en-las-empresas/>
- Cochilco. (2021). *El mercado de litio*.
- Datalized. (s.f.). *Datalized*. Recuperado el marzo de 2024, de <https://www.linkedin.com/company/datalized/about/>
- García, F. (5 de abril de 2023). *Metodología DevOps: qué es y para qué sirve*. Obtenido de <https://www.arsys.es/blog/metodologia-devops>
- Gillis, A. S. (febrero de 2024). *Natural Language Processing (NLP)*. Obtenido de [https://www.techtarget.com/searchenterpriseai/definition/natural-language-processing-NLP#:~:text=Natural%20language%20processing%20\(NLP\)%20is,in%20the%20field%20of%20linguistics.](https://www.techtarget.com/searchenterpriseai/definition/natural-language-processing-NLP#:~:text=Natural%20language%20processing%20(NLP)%20is,in%20the%20field%20of%20linguistics.)

- Google Cloud. (s.f.). *¿Qué es el procesamiento del lenguaje natural?* Recuperado el mayo de 2024, de [https://cloud.google.com/learn/what-is-natural-language-processing?hl=es#:~:text=El%20procesamiento%20del%20lenguaje%20natural%20\(PLN\)%2C%20como%20rama%20de,natural%20son%20tipos%20de%20PLN.](https://cloud.google.com/learn/what-is-natural-language-processing?hl=es#:~:text=El%20procesamiento%20del%20lenguaje%20natural%20(PLN)%2C%20como%20rama%20de,natural%20son%20tipos%20de%20PLN.)
- IEA. (Mayo de 2021). *The Role of Critical Minerals in Clean Energy Transitions*. Obtenido de <https://www.iea.org/reports/the-role-of-critical-minerals-in-clean-energy-transitions>
- Jeong, G., Han, M., Kim, S., Lee, Y., Lee, J., Park, S., & Kim, H. (2023). Improving Text-to-SQL with a Hybrid Decoding Method. *EBSCO*, 25, 513.
- Langchain. (s.f.). *Components*. Recuperado el mayo de 2024, de <https://python.langchain.com/v0.1/docs/modules/>
- MAS Analytics. (s.f.). *MAS Analytics*. Recuperado el marzo de 2024, de <https://www.linkedin.com/company/mas-analytics/>
- Microsoft. (s.f.). *Azure Synapse Analytics*. Recuperado el 28 de junio de 2024, de <https://azure.microsoft.com/es-es/products/synapse-analytics>
- Mordor Intelligence. (s.f.). *Tamaño del mercado de servicios de consultoría y análisis de participación tendencias de crecimiento y pronósticos (2024-2029)*. Recuperado el 22 de julio de 2024
- Nicula, B., Dascalu, M., Arner, T., Balyan, R., & McNamara, D. (2023). Automated Assessment of Comprehension Strategies from Self-Explanations Using LLMs. *EBSCO*, 14, 567.
- Olavsrud, T. (10 de marzo de 2023). *Unilever leverages GPT API to deliver business value*. Obtenido de <https://www.cio.com/article/464190/unilever-leverages-chatgpt-to-deliver-business-value.html>
- Pepinosa, J. (24 de octubre de 2023). *Qué es un prompt y por qué es un el elemento clave para utilizar la inteligencia artificial*. Obtenido de <https://www.infobae.com/tecno/2023/10/24/que-es-un-prompt-y-por-que-es-un-el-elemento-clave-para-utilizar-la-inteligencia-artificial/>
- Peredo, I., & Parraguez, C. (2023). *Fundamentos de la consultoría para negocios digitales*.
- Pérez, G. (2023). *Gerente de cadena de suministros*.
- Ranjan, J., & Foropon, C. (2021). Big Data Analytics in Building the Competitive Intelligence of Organizations. *International Journal of Information Management*, 56. <https://doi.org/10.1016/j.ijinfomgt.2020.102231>

- Roberto, C. (6 de mayo de 2022). *Crisp-DM: las 6 etapas de la metodología del futuro*. Obtenido de <https://blog.mbauspesalq.com/es/2022/05/31/crisp-dm-las-6-etapas-de-la-metodologia-del-futuro/>
- Rouse, M. (15 de enero de 2024). *Generative AI*. Obtenido de <https://www.techopedia.com/definition/34633/generative-ai>
- Silverio, M. (17 de mayo de 2024). *ChatGPT: número de usuarios y estadísticas*. Obtenido de <https://www.primeweb.com.mx/chatgpt-usuarios-estadisticas>
- Skuridin, A., & Wynn, M. (2024). Chatbot Design and Implementation: Towards an Operational Model for Chatbots. *EBSCO*, 15, 226.
- SQM. (2022). *Memoria anual 2022*.
- SQM Lithium. (s.f.). <https://www.sqmlithium.com/nosotros/primeros-en-trazabilidad/>. Recuperado el mayo de 2024
- SQM. (s.f.). SOMOS SQM. Recuperado el marzo de 2024, de <https://www.sqm.com/acerca-de-sqm/informacion-corporativa/somos-sqm/>
- Streamlit. (s.f.). *Streamlit documentation*. Recuperado el mayo de 2024, de <https://docs.streamlit.io/>
- USGS. (s.f.). <https://pubs.usgs.gov/periodicals/mcs2023/mcs2023-lithium.pdf>. Recuperado el mayo de 2024
- Vanna.AI. (s.f.). *How Vanna Works*. Recuperado el mayo de 2024, de <https://vanna.ai/docs/>
- Wlodarczak, S. (20 de junio de 2023). *How Generative AI will transform manufacturing*. Obtenido de <https://aws.amazon.com/es/blogs/industries/generative-ai-in-manufacturing/>

ANEXOS


Anexos A

A.1. Perfiles profesionales de Brain Food

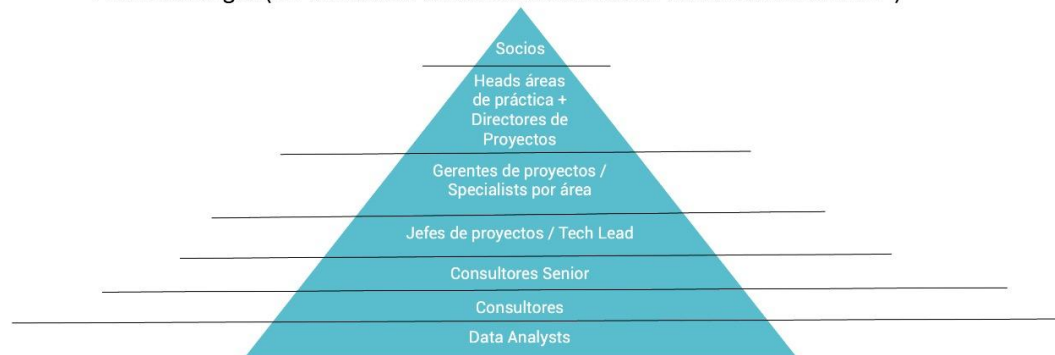
Los perfiles de la compañía quedan configurados de la siguiente manera:

- Negocios: personas que trabajan dando la mirada de negocio en proyectos asociado a la estrategia y transformación digital.
- Data Science: personas expertas en manejo de datos, análisis y extracción de información, construcción de modelos y algoritmos.
- Desarrollo: personas dedicadas al desarrollo de plataformas web y móviles, interfaces gráficas, software, apps, dashboards, entre otros.
- Otros perfiles: personas que dan un soporte interno a la organización, tales como sociólogos, psicólogos, socios o perfiles híbridos.

A.2. Organigrama de Brain Food



Pirámide cargos (sin considerar áreas centralizadas de servicios como RRHH)



Nota: elaboración propia

A.3. Servicios de Brain Food

Brain Food divide sus servicios en cuatro áreas, las cuales interactúan durante los proyectos para desarrollar soluciones integrales. Las áreas y sus descripciones son las que se indican en la Tabla 1 (Brain Food, s.f.).


Tabla 1: Servicios Brain Food

Ciencia de los Datos e IA	Se le da sentido a los datos desarrollando modelos con AI/ML con el fin de comprender, predecir y ejercer influencia en los resultados de la organización.
Estrategia Digital	Transforma la visión de una empresa en resultados reales, ayuda a construir una hoja de ruta efectiva y accionable para navegar la incertidumbre y alcanzar los objetivos del respectivo negocio.
Automatización y BI	Se transforman los datos en insights, liberando tiempo automatizando procesos manuales y repetitivos, mejorando la calidad de la información, dando velocidad y minimizando errores.
Ingeniería de Datos	Se extraen, preparan y se le da sentido a los datos de una organización sin importar el volumen o formato para poder utilizarlos de manera confiable y rápida.

Nota: elaboración propia a partir de información encontrada en la página de Brain Food (<https://brain-food.cl/>)

Anexo B

B.1. Comparación de la demanda de minerales en diversas tecnologías energéticas.




B.2. Organigrama de Supply Chain SQM Lithium



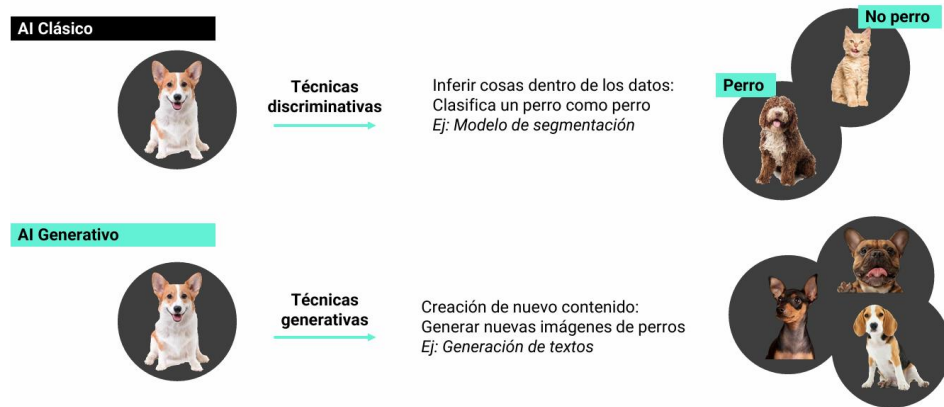
Anexo C

C.1. Inversión en GenAI 2019-2023



Anexo D

D.1. Ejemplo de GenAI



D.2. Benchmark de herramienta LLM

Herramienta	A favor	En contra
Azure OpenAI Service	<ul style="list-style-type: none">Seguridad y control.Integrado a nube Azure.Se puede compartir respuestas con otros, ajustar hiperparámetros, limitar uso.	<ul style="list-style-type: none">Es pagado, por token (4 caracteres en <code>prompt</code>).Es caro en sus modelos más premium.Está en beta, por lo tanto, no tiene conexiones a todas las BD vectoriales posibles.
Power BI	<ul style="list-style-type: none">Visualizador de datos, sencillo de utilizar.Ya está en la empresa.	<ul style="list-style-type: none">Muy limitado en cuanto a inteligencia artificial se refiere.
Langchain	<ul style="list-style-type: none">Versatilidad al máximo. Conectarse a distintos modelos y distintas bases de datos vectoriales.Cada día sale una funcionalidad nueva.Posee una gran comunidad apoyando su desarrollo.	<ul style="list-style-type: none">Requiere mayor conocimiento, tiempo y desarrollo para construir una solución end to end.No queda claro donde se despliega esta solución, podría ser en cualquier lado y eso implica mayores costos de desarrollo.
LLM H ₂ O	<ul style="list-style-type: none">Mayor control del entrenamiento del modelo.Más seguridad en el uso de los datos al usar un modelo privado.	<ul style="list-style-type: none">El modelo es muy grande y requiere una gran cantidad de recursos de procesamiento y memoria.Requiere una gran cantidad de datos de alta calidad y puede ser difícil de entrenar.
Fabric	<ul style="list-style-type: none">Integrado con las soluciones que requieren Power BI.Simplicidad en el uso.Es una solución <code>end-to-end</code> ya que integra desde las fuentes de datos hasta la analítica avanzada.	<ul style="list-style-type: none">Está obligatoriamente conectado con las soluciones de Azure de Microsoft.Es caro.

D.3. Prompt contexto compras

“Estás trabajando con una base de datos de Azure. Las tablas que tienes disponibles son: [CONSUMPTION_LLM].base_activacion, [CONSUMPTION_LLM].base_ME5A, [CONSUMPTION_LLM].base_OC, [CONSUMPTION_LLM].base_OTIF y [CONSUMPTION_LLM].sabanilla_despachos. Debes sí o sí utilizar el esquema [CONSUMPTION_LLM] para hacer la query. Ten cuidado, pueden haber precios y montos netos

iguales a 0, no los consideres. Antes de empezar a hacer queries, estudia el nombre de las columnas, no inventes nombres nuevos, usa los nombres que se encuentran en las tablas. Para cuando se busque información de un nombre o producto, usa OBLIGATORIAMENTE la función LIKE de SQL adjunta al nombre de la forma %nombre%. Cuando se busque información de un producto, usa si o si el nombre del producto en singular. Si la palabra que estás buscando lleva tilde, realiza dos búsquedas, por ejemplo LIKE "valvula" OR LIKE "válvula" considera que todas las fechas presentes en las tablas tienen formato yyyy/mm/dd, realiza las queries de fechas con este formato."

D.4. Prompt clasificación

"Clasificación de la pregunta en base a las siguientes descripciones: 1. Compras, solicitudes de pedido, OTIF (on time in full) y despachos: si para responder la pregunta requiere de información sobre compras de materiales, productos o herramientas. Esta información puede ser ordenes de compra (OC), ordenes de compra aprobadas (activación), solicitudes de pedido (SOLPED), proveedores, fechas de entrega, que producto se compró, las cantidades y el precio, el OTIF de proveedores (base_OTIF) e información general sobre despachos realizados. 2. presupuesto, productos envasados hidroxido, control LiOH, CDDE, producción de carbonato e hidroxido y existencias: si para responder la pregunta se requiere información sobre los presupuesto, productos envasados de hidroxido, control LiOH, CDDE, producción y existencias. 3. General: si la pregunta es más bien general sobre la empresa y no aplica en las clasificaciones previas. Necesito que clasificación sea "1", "2" o "3", es importante que la respuesta tenga solo un caracter Es muy importante que tu respuesta tenga solo 1 caracter."

Anexo E

E.1. Muestra de metadata de base Activación

BASE_ACTIVACION

Filas 55541. Columnas 33

Tiene info sobre las órdenes de compra aprobadas, las que ya están en faena.

Salen filas vacías desde la columna "precio_netopedido" hacia adelante, son aproximadamente 43 filas.

Detalles: Hay muchos valores que tienen tildes o ñ, esto puede generar error. Muchas fechas en un formato no conveniente para consultar. "sociedad" y "nombre_empresa" dicen lo mismo, quizás es mejor dejar una o combinarlas. Al separar "precio_netopedido" con "moneda", puede generar confusión al consultar un precio y que aparezca solo el valor sin la moneda. Hay muchas variables categóricas que son números o palabras raras, quizás sería útil tener un diccionario de esos valores para cambiarlos. Se repiten los valores de "nombre_interlocutor" con "activador".

nombre_func_interlocutor: Formato nvarchar(4000). Resultado único: "Activador". Letras.

nombre_interlocutor: Formato nvarchar(4000). Toma 27 valores categóricos distintos (interlocutores). Indica nombre interlocutor en mayúsculas. Letras. Hay apellidos con Ñ. Interfiere para que la orden llegue a la faena.

documento_compras: Formato nvarchar(4000). Varía de 1000344981 a 9000091629 (no escala de a 1). Números enteros. Documentos de compra.

sociedad: Formato nvarchar(4000). Toma valores categóricos 100 ("SQM S.A."), 400 ("SQM Industrial S.A."), 1800 ("SQM Mag SpA"), 1900 ("SQM Salar S.A."). Números enteros.

nombre_empresa: Formato nvarchar(4000). Toma valores categóricos "SQM S.A.", "SQM Industrial S.A.", "SQM Mag SpA" (aparece poco) y "SQM Salar S.A.". Letras. Nombre de la empresa SQM.

fecha_entrega: Formato nvarchar(4000). Toma valores de 20220718 (18 de julio 2022) a 20250804 (04 de agosto 2025). Números enteros. Al indicar fecha de entrega se recomienda cambiar los números en formato Date. Fecha prevista de entrega de pedido.

nombre_comprador: Formato nvarchar(4000). Toma 42 valores distintos (compradores). En algunos casos nombre_interlocutor coincide con nombre_comprador. Letras. Primera inicial del nombre seguido del primer apellido (esto varía, en algunos casos se deja las dos primeras iniciales o más), todo en mayúsculas.

nombre_proveedor: Formato nvarchar(4000). Letras. Hay palabras con Ñ, ü y tildes, nombres escritos con minúsculas y mayúsculas. Empresa proveedora.

proveedor: Formato nvarchar(4000). Números enteros combinados con letras en algunos casos. Rut de empresa proveedora sin puntos ni guion. Quizás se debería llamar documento_proveedor o algo parecido para que se distinga bien de "nombre_proveedor".

linea: Formato nvarchar(4000). Toma valores de 00010 a 01490, va escalando de 10 en 10. Números enteros. Línea de producción.

E.2. Queries de ejemplo

```
--Dame un promedio de los días transcurridos para las ordenes de compra del 2024, agrupa por comprador
SELECT bo.nombre_comprador, CAST(AVG(bo.dias_generacion_OC) AS DECIMAL(10,2)) AS promedio_dias
FROM CONSUMPTION_LLM.base_OC bo
WHERE YEAR(bo.fecha_creacion_OC) LIKE '2024'
GROUP BY bo.nombre_comprador

--Cuantas líneas con entrega atrasadas pendientes hay al día de hoy?
SELECT COUNT(*) AS lineas_entregas_atrasadas_pendientes
FROM CONSUMPTION_LLM.base_activacion
WHERE cantidad_pendientes_entregar > 0
AND CAST(fecha_prevista_entrega AS DATE) <= CAST(GETDATE() AS DATE);

--Dime la cantidad de líneas de compra generadas el 2024 de material genérico?
SELECT COUNT(*) AS lineas_creadas
FROM CONSUMPTION_LLM.base_OC
WHERE tipo_de_material LIKE '%Material Genérico%' AND YEAR(fecha_creacion_OC) LIKE '2024'

--Muestre la cantidad de líneas por grupo de compradores
SELECT bo.grupo_compras, COUNT(*) as lineas_compradores
FROM CONSUMPTION_LLM.base_OC bo
GROUP BY bo.grupo_compras

--Dame un promedio de los días desde que se genero la OC para las ordenes de compra del 2024
SELECT AVG(CAST(dias_generacion_OC AS FLOAT)) AS promedio_dias
FROM CONSUMPTION_LLM.base_OC
WHERE YEAR(fecha_creacion_OC) LIKE '2024'

--Cuantas solicitudes de pedido hay pendientes hace más de 15 días?
SELECT COUNT(*) AS solicitudes_pendientes
FROM CONSUMPTION_LLM.base_ME5A
WHERE estado_tratamiento_pedido LIKE '%no tratado%'
AND DATEDIFF(DAY, fecha_aprobacion_pedido, GETDATE())>15
```

E.3. Cambios a las bases en Azure Synapse

<input type="checkbox"/>	baseOC's column	▽	Name as
<input type="checkbox"/>	abc documento_compras	▽	documento_compras
<input type="checkbox"/>	abc posicion	▽	linea_compras
<input type="checkbox"/>	abc solicitud_pedido	▽	documento_solicitud_p...
<input type="checkbox"/>	abc pos_solicitud_pedido	▽	linea_solicitud_pedido
<input type="checkbox"/>	abc comprador	▽	nombre_comprador
<input type="checkbox"/>	abc tratamiento_oc	▽	estado_compra
<input type="checkbox"/>	abc tipo_compra	▽	tipo_compra
<input type="checkbox"/>	abc centro_final	▽	centro_despachos
<input type="checkbox"/>	abc material	▽	id_producto
<input type="checkbox"/>	abc tipo_de_material	▽	tipo_de_material
<input type="checkbox"/>	abc texto_breve	▽	nombre_producto
<input type="checkbox"/>	abc grupo_articulos	▽	grupo_articulos
<input type="checkbox"/>	e ^x cantidad_pedido	▽	cantidad_compra
<input type="checkbox"/>	1.2 valor_netto_usd	▽	valor_netto_usd
<input type="checkbox"/>	1.2 valor_netto_clp	▽	valor_netto_clp

Column name *

fecha_creacion_orden_compra

Expression

```
toDate(fecha_creacion_orden_compra, 'yyyyMMdd')
```

<input type="checkbox"/>	Column	Expression
<input type="checkbox"/>	nombre_comprador	lower(nombre_comprador) abc
<input type="checkbox"/>	estado_compra	lower(estado_compra) abc
<input type="checkbox"/>	tipo_compra	lower(tipo_compra) abc
<input type="checkbox"/>	clase_documento_compra	lower(clase_documento_compra) abc
<input type="checkbox"/>	centro_produccion	lower(centro_despachos) abc
<input type="checkbox"/>	nombre_producto	lower(nombre_producto) abc
<input type="checkbox"/>	grupo_articulos	lower(grupo_articulos) abc
<input type="checkbox"/>	nombre_proveedor	lower(nombre_proveedor) abc

Output stream name *

filter1

Description

Filtering rows using expressions on columns 'estado_liberacion, indicador_borrado'

Incoming stream *

minusculas

Filter on *

```
estado_liberacion == "XX" &&  
(indicador_borrado != "L" &&  
indicador_borrado != "S")
```

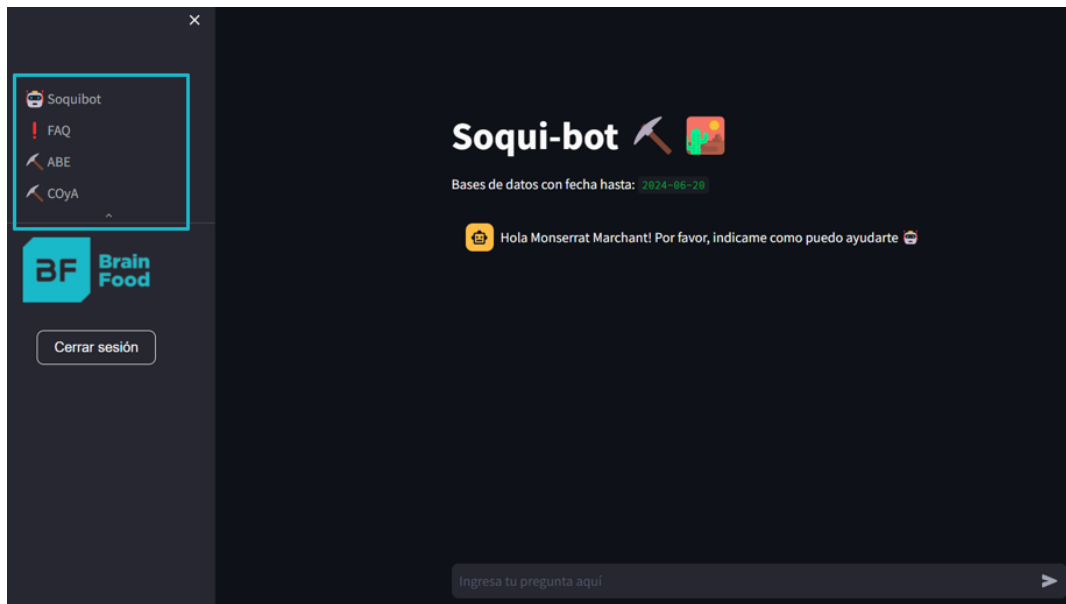
E.4. Campos de bases de datos modificadas

Tabla 2: Campos de bases de datos modificadas

Base OC	Base ME5A	Base Activacion	Base OTIF
id_orden_compra	id_solicitud_pedido	id_orden_aprobada	nombre_proveedor
documento_compras	documento_solicitud_pedido	documento_compras	id_compra
linea_compras	linea	linea_aprobada	documento_compra
id_solicitud_pedido	creador_pedido	nombre_activador	posicion
documento_solicitud_pedido	estado_tratamiento_pedido	nombre_proveedor	tipo_oc
linea_solicitud_pedido	tipo_solicitud_pedido	rut_proveedor	clase_compra
nombre_comprador	cantidad_pedida	tipo_de_proveedor	area
grupo_compras	fecha_creacion_pedido	fecha_prevista_entrega	grupo_compras
estado_compra	fecha_aprobacion_pedido	cantidad_pendientes_entregar	nombre_producto
tipo_compra		dias_atraso_entrega	precio_netos_usd
clase_documento_compra		estado_entrega	cantidad_material_oc
centro_despachos			cantidad_recepcionada_bodega
nombre_proveedor			fecha_pedido
rut_proveedor			fecha_entrega
fecha_creacion_OC			fecha_prevista_entrega
dias_generacion_OC			sociedad
id_producto			centro_despacho
tipo_de_material			grupo_articulo
nombre_producto			infull_proveedor
grupo_articulos			ontime_proveedor
precio_producto_USD			
precio_producto_CLP			
cantidad_compra			
valor_netos_usd			
valor_netos_clp			

E.5. Frontend Chatbot





! FAQ

En este chatbot se están usando distintas bases, entre ellas la ME5A, base OC, base Activacion, base OTIF y sabanilla de despachos.

Aquí abajo podrás previsualizar la forma en que es cada base para poder saber que preguntas hacer!

- Aquí puedes encontrar queries de ejemplo
- Aquí puedes previsualizar la base ME5A
- Aquí puedes previsualizar la base OC
- Aquí puedes previsualizar la base activacion
- Aquí puedes previsualizar la base OTIF
- Aquí puedes previsualizar la base sabanilla_despachos

Soqui-bot 🛠️ 🌱

Bases de datos con fecha hasta: 2024-06-20

👋 Hola Monserrat Marchant! Por favor, indicame como puedo ayudarte 🗨️

🗨️ puedes darme la informacion de presupuestos 2023?

👋 Lo siento, no tengo acceso a la información detallada de presupuestos para el año 2023. Sin embargo, puedo dirigirte a los reportes de Power BI que podrían ser útiles para obtener información financiera actualizada. Te recomiendo revisar el Reporte de Control Presupuestario, que contiene información sobre el presupuesto gastado por Unidad de Negocio y otros indicadores financieros importantes. Puedes acceder a este reporte a través del siguiente enlace: https://app.powerbi.com/Redirect?action=OpenReport&appId=3c0105f-4444-40db-ac7e-ea57c077cbdf&reportObjectId=bcbcf53-330e-4080-8a69-e1298239f6a3&ctid=ee9a0945-3e32-4c74-8986-8e411af80f3c&reportPage=ReportSection&pb_source=appShareLink&portalSessionId=faec3b4d-87b5-45fd-8ffd-c7c78cc654de. Espero que te sea de ayuda.

Mostrar Query ▾

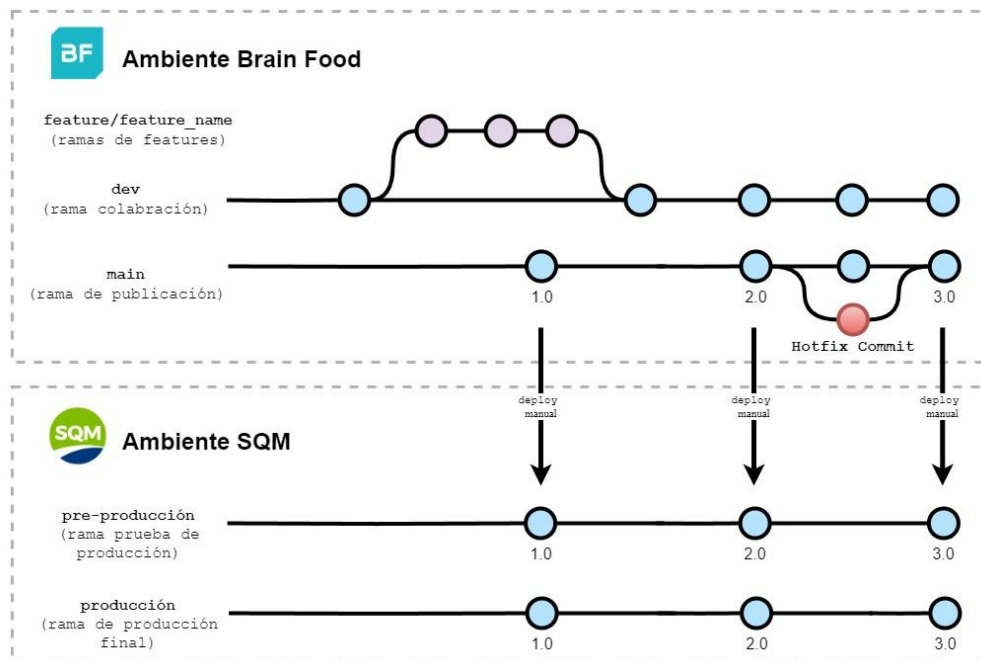
👍 🗨️

Guardar feedback

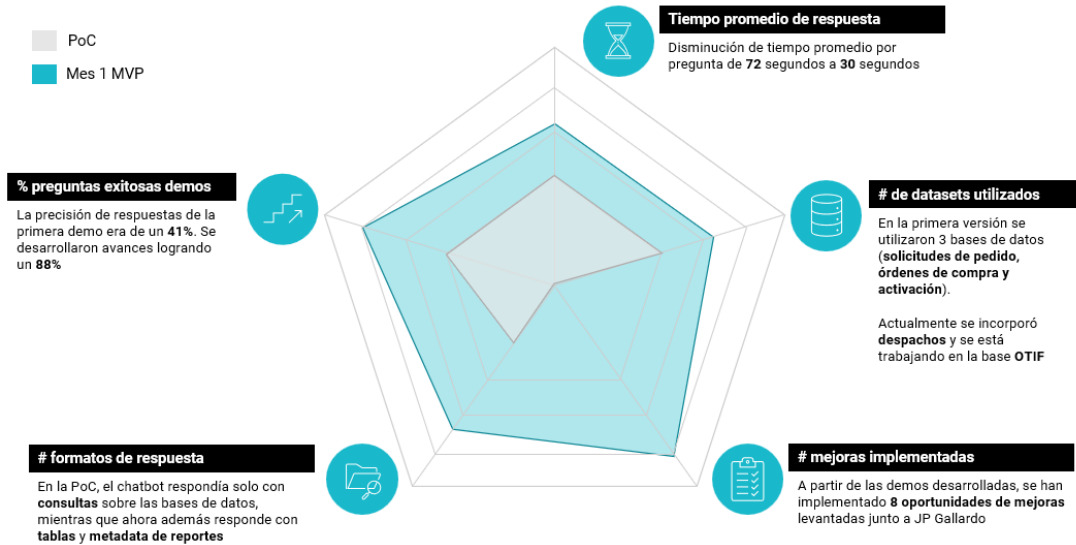
Visualizar DataFrame

Ingresa tu pregunta aquí ➔

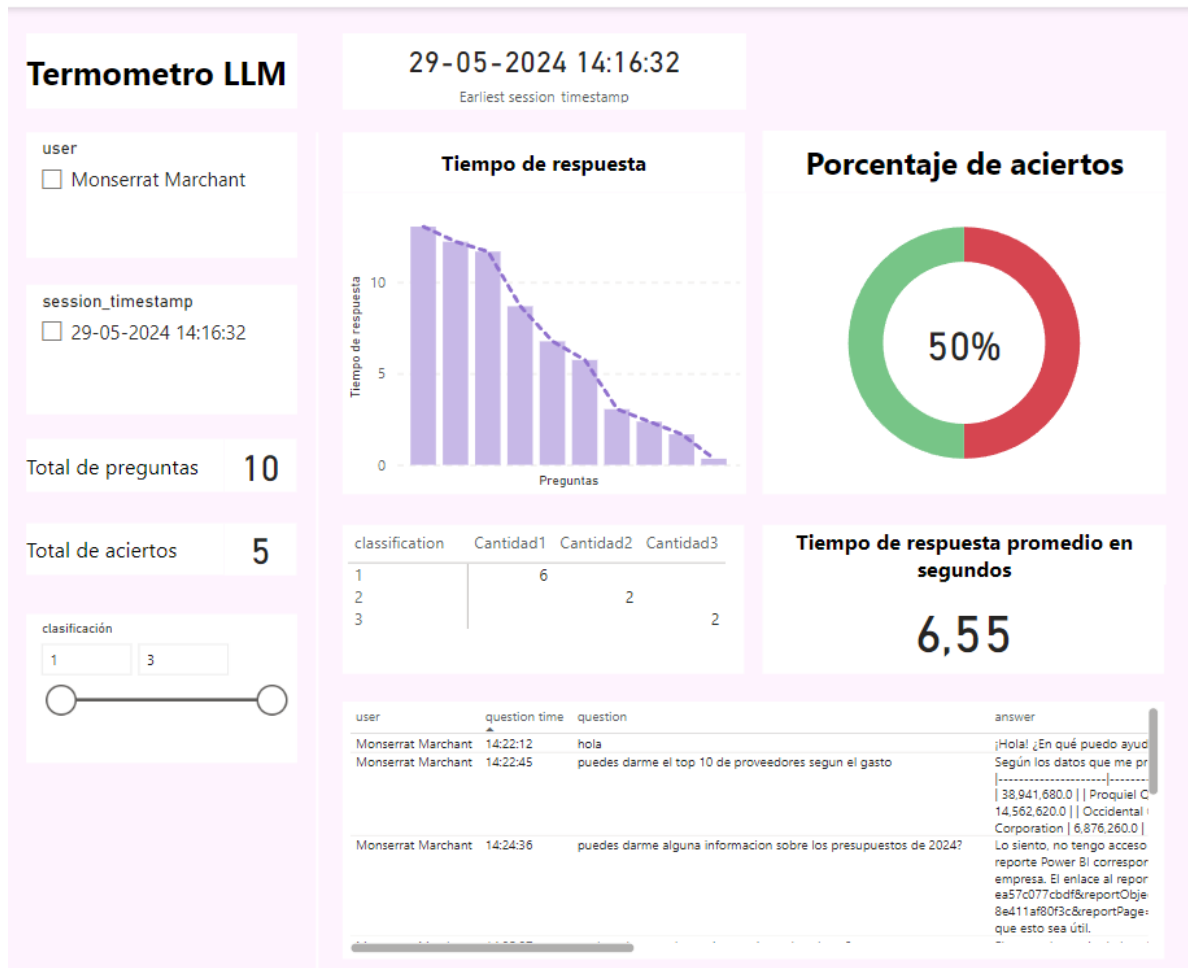
E.6. Gitflow



E.7. Mejora de chatbot actual con respecto a la prueba de concepto



E.8. Prototipo de Termómetro LLM



E.9. Arreglo de bugs y funcionalidades nuevas

Arreglo de bugs	Funcionalidades agregadas
A veces responde en inglés	Botón para ver query
Clasificador se marea	Página de FAQ
Agregar campo backlog	Botón de "me gusta" y "no me gusta"
Agregar campo grupo de compras	Botón para ver dataframe
No tiene memoria	Fecha de última actualización de data
Aplicar filtros	Inicio de sesión