

ESCUELA SUPERIOR POLITÉCNICA DEL LITORAL

Facultad de Ingeniería en Electricidad y Computación

Desarrollo de un agente inteligente basado en aprendizaje automático para la mejora en la toma de decisiones estratégicas en la Dirección de Sostenibilidad de ESPOL.

PROYECTO DE TITULACIÓN

Previo la obtención del Título de:

Magister en Ciencias de Datos

Presentado por:

Sandra Isabella Coello Suárez

Alberto Jose Cruz Ochoa

GUAYAQUIL - ECUADOR

Año: 2026

DEDICATORIA

Sandra Coello:

Dedico este proyecto a mis padres, Myrella y Amado por su apoyo incondicional y por inculcarme el valor del conocimiento y la perseverancia, pilares de este logro profesional.

A mis hermanas Diana y Ximena, a mi abuelita, primas, tías y tíos por ser el aliento necesario en los momentos de mayor desafío.

Finalmente, a Nicolás por ser el soporte inquebrantable que me acompañó en cada etapa de este camino.

Alberto Cruz:

Dedico este trabajo a mi familia, por su amor, paciencia y fortaleza en cada etapa de este camino. A mi madre, quien me enseñó el valor del esfuerzo y la educación, y a quien le debo cada logro profesional y personal.

Agradezco también a quienes, desde sus palabras y acciones, me motivaron a seguir adelante durante el periodo académico de la maestría.

AGRADECIMIENTOS

Nuestro más sincero agradecimiento a la Escuela Superior Politécnica del Litoral y a la Facultad de Ingeniería en Electricidad y Computación por habernos brindado la formación académica que hizo posible este trabajo.

Extendemos nuestra gratitud al Ph.D José Córdova, Profesor Tutor, por su invaluable guía, paciencia y mentoría especializada, esenciales para el desarrollo de la arquitectura del Agente Inteligente.

Un especial reconocimiento a la Dirección de Sostenibilidad Institucional de ESPOL, cuyo apoyo y acceso a la plataforma PREC fueron cruciales para obtener los datos necesarios y validar el impacto operativo del proyecto.

DECLARACIÓN EXPRESA

Nosotros Sandra Isabella Coello Suárez y Alberto Jose Cruz Ochoa acordamos y reconocemos que: La titularidad de los derechos patrimoniales de autor (derechos de autor) del proyecto de graduación corresponderá al autor o autores, sin perjuicio de lo cual la ESPOL recibe en este acto una licencia gratuita de plazo indefinido para el uso no comercial y comercial de la obra con facultad de sublicenciar, incluyendo la autorización para su divulgación, así como para la creación y uso de obras derivadas. En el caso de usos comerciales se respetará el porcentaje de participación en beneficios que corresponda a favor del autor o autores. El o los estudiantes deberán procurar en cualquier caso de cesión de sus derechos patrimoniales incluir una cláusula en la cesión que proteja la vigencia de la licencia aquí concedida a la ESPOL.

La titularidad total y exclusiva sobre los derechos patrimoniales de patente de invención, modelo de utilidad, diseño industrial, secreto industrial, secreto empresarial, derechos patrimoniales de autor sobre software o información no divulgada que corresponda o pueda corresponder respecto de cualquier investigación, desarrollo tecnológico o invención realizada nosotros durante el desarrollo del proyecto de graduación, pertenecerán de forma total, exclusiva e indivisible a la ESPOL, sin perjuicio del porcentaje que nos corresponda de los beneficios económicos que la ESPOL reciba por la explotación de nuestra innovación, de ser el caso.

En los casos donde la Oficina de Transferencia de Resultados de Investigación (OTRI) de la ESPOL comunique los autores que existe una innovación potencialmente patentable sobre los resultados del proyecto de graduación, no se realizará publicación o divulgación alguna, sin la autorización expresa y previa de la ESPOL.

Guayaquil, 30 de enero del 2026.

Sandra Isabella Coello Suárez

Alberto Jose Cruz Ochoa

COMITÉ EVALUADOR

José Córdova G., PhD.
PROFESOR TUTOR

Allan Avendaño, MSc.
PROFESOR EVALUADOR

RESUMEN

El Desarrollo de un agente inteligente basado en aprendizaje automático para la mejora en la toma de decisiones estratégicas en la Dirección de Sostenibilidad de la Escuela Superior Politécnica del Litoral aborda la limitación crítica de que el análisis de consumo energético en tiempo real, vital para el cumplimiento de los Objetivos de Desarrollo Sostenible (ODS) y la norma ISO 50001, aún requiere manipulación manual y se basa en criterios intuitivos. Este proyecto presenta la necesidad de una solución automatizada que transforme los datos técnicos de la plataforma Personalized Recommendations for Efficient Consumption (PREC) en recomendaciones estratégicas claras y accionables, minimizando la carga operativa.

Para ello, se diseñó e implementó un agente inteligente conversacional de soporte a la decisión, basado en la arquitectura ReAct y la técnica de Generación Aumentada por Recuperación (RAG). La metodología incluyó la caracterización de patrones de consumo energético mediante modelos de Aprendizaje Automático sobre series de tiempo. El agente utilizó su capacidad de razonamiento para planificar y ejecutar consultas de código sobre la base de datos energética, asegurando que las salidas se fundamentan en datos fácticos.

Como principal resultado, se logró un prototipo funcional que consta de una interfaz conversacional.

En conclusión, el agente inteligente mejora significativamente la eficiencia y la trazabilidad del proceso de toma de decisiones en la gestión energética. El sistema apoya la transición de ESPOL hacia una gobernanza energética más proactiva y basada en datos.

Palabras Clave: Agente Inteligente, Gestión Energética, ISO 50001, RAG, ReAct.

ABSTRACT

The development of an intelligent agent based on machine learning to improve strategic decision-making within the Sustainability Directorate of the Escuela Superior Politécnica del Litoral addresses the critical limitation that real-time energy consumption analysis essential for meeting the Sustainable Development Goals (SDGs) and the ISO 50001 standard still requires manual handling and relies on intuitive criteria. This project highlights the need for an automated solution capable of transforming the technical data from the Personalized Recommendations for Efficient Consumption (PREC) platform into clear and actionable strategic recommendations, thereby minimizing operational workload.

To this end, a conversational intelligent decision-support agent was designed and implemented, based on the ReAct architecture and the Retrieval-Augmented Generation (RAG) technique. The methodology included characterizing energy consumption patterns using Machine Learning models applied to time series data. The agent leveraged its reasoning capabilities to plan and execute code queries on the energy database, ensuring that outputs were grounded in factual data.

As the main result, a functional prototype consisting of a conversational interface was developed.

In conclusion, the intelligent agent significantly enhances the efficiency and traceability of the decision-making process in energy management. The system supports ESPOL's transition toward more proactive and data-driven energy governance.

Keywords: *Intelligent Agent, Energy Management, ISO 50001, RAG, ReAct.*

ÍNDICE GENERAL

COMITÉ EVALUADOR	5
RESUMEN	I
ABSTRACT	II
ÍNDICE GENERAL	III
ABREVIATURAS	VI
SIMBOLOGÍA.....	VIII
ÍNDICE DE FIGURAS	IX
ÍNDICE DE TABLAS	X
CAPÍTULO 1	1
1. Introducción	1
1.1 Descripción del problema	1
1.2 Justificación del problema	3
1.3 Objetivos	6
1.3.1 Objetivo General.....	6
1.3.2 Objetivos Específicos.....	6
1.4 Marco teórico	7
1.4.1 Sistemas de Gestión Energética Inteligente (SGEn) en Campus Universitarios	7
1.4.2 Agentes Inteligentes y Modelos de Lenguaje Grande (LLMs) en la Ciencia de Datos	8
1.4.3 Generación Aumentada por Recuperación (RAG) para la Toma de Decisiones Basada en Datos	9
1.4.4 Arquitecturas de Agentes de Lenguaje y Razonamiento (ReAct).....	10

CAPÍTULO 2	12
2. Metodología.....	12
2.1 Formulación de alternativas de solución.....	12
2.1.1 Contextualización del problema y objetivos de diseño	12
2.1.2 Identificación de Alternativas	12
2.1.3 Criterios de evaluación de las alternativas	13
2.1.4 Selección de la mejor alternativa	13
2.2 Diseño conceptual.....	15
2.2.1 Descripción general de la arquitectura del agente	15
2.2.2 Componentes principales y flujos de información	15
2.2.3 Diagrama de bloques y casos de uso	15
2.3 Metodología de diseño	16
2.3.1 Enfoque de investigación	16
2.3.2 Fases del proceso de diseño	16
2.4 Diseño detallado del producto o servicio	20
2.4.1 Principios técnicos y criterios de diseño.....	20
2.4.2 Selección de recursos.....	22
2.5 Especificaciones técnicas.....	23
2.5.1 Requerimientos funcionales.....	23
2.5.2 Requerimientos no funcionales	23
2.5.3 Arquitectura de software y despliegue	23
2.5.4 Detalle de interfaces y API.....	24
2.5.5 Modelos de datos y protocolos de comunicación	24
2.6 Estrategia de identificación causal	24
2.6.1 Identificación de efectos causales en los datos	24
2.6.2 Tratamiento de datos	24

2.7	Consideraciones éticas y legales	25
2.7.1	Privacidad y protección de datos	25
2.7.2	Transparencia e interpretabilidad de modelos	25
2.7.3	Seguridad de la información	25
2.7.4	Responsabilidad social e impacto institucional	26
CAPÍTULO 3		27
3.	Resultados Y ANÁLISIS	27
3.1	Resultados Generales del Prototipo del Agente Inteligente	27
3.2	Evaluación del Rendimiento Técnico.....	29
3.2.1	Tiempos de Respuesta	29
3.3	Impacto en la Toma de Decisiones	30
3.4	Resultados Específicos del Aporte de Ciencia de Datos	31
3.5	Análisis de Costos.....	31
3.6	Viabilidad Económica y Tecnológica	33
3.7	Discusión y Oportunidades de Mejora.....	33
CAPÍTULO 4		35
4.	Conclusiones Y Recomendaciones	35
4.1	Conclusiones.....	35
4.2	Recomendaciones.....	36
BIBLIOGRAFÍA		39
APÉNDICES		43

ABREVIATURAS

BERT	Bidirectional Encoder Representations from Transformers
CPU	Central Processing Unit
CRISP-DM	Cross-Industry Standard Process for Data Mining
DSS	Sistema de Soporte a la Decisión (Decision Support System)
ESPOL	Escuela Superior Politécnica del Litoral
EUI	Energy Use Intensity
FAISS	Facebook AI Similarity Search
FP	Factor de Potencia
GDPR	Reglamento General de Protección de Datos
GPU	Graphics Processing Unit
IA	Inteligencia Artificial
IoT	Internet of Things
ISO 50001	International Organization for Standardization 50001
KPIs	Key Performance Indicators
LLM	Large Language Model
ML	Machine Learning
MQTT	Message Queuing Telemetry Transport
ODS	Objetivos de Desarrollo Sostenible
ONU	Organización de Naciones Unidas
PNL	Procesamiento de Lenguaje Natural
PREC	Personalized Recommendations for Efficient Consumption
RAG	Retrieval-Augmented Generation
RAM	Random Access Memory
ReAct	Reasoning and Acting
REPL	Read-Eval-Print Loop
ROI	Retorno de la Inversión
SGEn	Sistema de Gestión Energética Inteligente
SSD	Solid State Drive
SQL	Structured Query Language
TCP/IP	Transmission Control Protocol/Internet Protocol

TLS Transport Layer Security
VAE Variational Autoencoders

SIMBOLOGÍA

A	Amperio
Bool	Booleano
Datetime	Fecha y Hora
Hz	Hertzio
kW	Kilovatio
kWh	Kilovatio por hora

ÍNDICE DE FIGURAS

Figura 2.1 Arquitectura del flujo de Generación Aumentada por Recuperación (RAG) con FAISS.	19
Figura 2.2 Flujo de interacción y validación de consultas energéticas.	22
Figura 3.1 Interacción con el Agente conversacional.	28
Figura 3.2 Interacción con el Agente conversacional.	28
Figura 3.3 Tiempo de respuesta de consulta.	29
Figura A.1 Consulta 1.	44
Figura A.2 Consulta 2.	44
Figura A.3 Consulta 3.	45
Figura A.4 Consulta 4.	45
Figura A.5 Consulta 5.	46
Figura B. 1 Interacción con el agente.	47
Figura B. 2 Interacción con el agente.	47
Figura B. 3 Interacción con el agente.	48
Figura B. 4 Interacción con el agente.	48
Figura B. 5 Interacción con el agente.	49
Figura B. 6 Interacción con el agente.	49

ÍNDICE DE TABLAS

Tabla 2.1 Selección de la mejor alternativa.	14
Tabla 2.2 Variables de Datos Tabulares procesados por el Agente Inteligente.	16
Tabla 2.3 Variables de Datos Documentales procesados por el Agente Inteligente.	18
Tabla 3.1 Tiempos de respuesta y Escalabilidad.	30
Tabla 3.2 Análisis de Costos	31

CAPÍTULO 1

1. INTRODUCCIÓN

1.1 Descripción del problema

Las universidades se enfrentan al reto de adaptarse a diversas iniciativas políticas tanto a nivel nacional como internacional, como los Objetivos de Desarrollo Sostenible (ODS) de la Organización de Naciones Unidas (ONU). Además, deben responder a una creciente presión global para actuar frente al cambio climático y promover la sostenibilidad (Comi et al., 2023).

La Escuela Superior Politécnica del Litoral (ESPOL) ha asumido este compromiso mediante múltiples acciones alineadas con los ODS. A través de su programa de Sostenibilidad, la institución ha implementado medidas concretas como la instalación de paneles fotovoltaicos, una planta de tratamiento de aguas residuales, bebederos, ciclovías y la medición anual de la huella de carbono. Estas acciones contribuyen directamente al cumplimiento de los ODS 6 (Agua limpia y saneamiento), 7 (Energía asequible y no contaminante) y 13 (Acción por el clima) (Escuela Superior Politécnica del Litoral (ESPOL), 2021).

En este marco, ESPOL también apuesta por la innovación tecnológica como pilar fundamental para fortalecer su enfoque sostenible (Oliveira & Proença, 2025). Un ejemplo destacado es la plataforma de Personalized Recommendations for Efficient Consumption (PREC), desarrollada para mejorar la gestión energética institucional. Esta herramienta permite monitorear el consumo energético en tiempo real, generar alertas personalizadas, identificar oportunidades de ahorro y mantener un registro histórico del comportamiento energético del campus. Su implementación no solo optimiza el uso de los recursos, sino que también habilita la aplicación de técnicas de análisis de datos y aprendizaje automático, abriendo nuevas posibilidades para una toma de decisiones estratégicas más eficiente y basada en evidencia dentro de la Dirección de Sostenibilidad Institucional (Escuela Superior Politécnica del Litoral, 2021).

La implementación de herramientas como PREC se alinea, además, con estándares internacionales como la norma International Organization for Standardization 50001 (ISO 50001) (Azamat & Schütz, 2023), la cual establece un marco global para los sistemas de gestión de la energía (SGEn), enfocados en la mejora continua del desempeño energético. Estudios recientes destacan la relevancia de estos sistemas en contextos institucionales, donde permiten estructurar procesos de medición, definición de líneas base, identificación de mejoras y monitoreo de avances (Quispe et al., 2025) (Rossi et al., 2022). En este sentido, PREC, en conjunto con los 55 medidores eléctricos inteligentes instalados en el campus, constituyen una plataforma estratégica para avanzar hacia la consolidación de un sistema de gestión energética integral en el ámbito universitario (García-Quilachamin et al., 2023).

No obstante, a pesar de estos avances, aún persisten limitaciones operativas que afectan la toma de decisiones estratégicas dentro de la Dirección de Sostenibilidad Institucional. Actualmente, el uso de la plataforma requiere una manipulación manual frecuente para visualizar los datos, realizar múltiples consultas por medidor y descargar registros para su posterior análisis por parte de un especialista en energía. Este proceso, además de ser demandante en tiempo y recursos humanos, dificulta la comparación ágil de escenarios, la identificación temprana de ineficiencias y la generación de respuestas oportunas.

En consecuencia, muchas decisiones se basan en criterios intuitivos o en presiones inmediatas, más que en un análisis integral y automatizado de los datos históricos y actuales. Esta situación limita la capacidad institucional para anticiparse a eventos críticos, aprovechar oportunidades de ahorro energético y medir con precisión el impacto de las acciones implementadas. La ausencia de un sistema inteligente que interprete datos en tiempo real y sugiera acciones estratégicas concretas representa una barrera para avanzar hacia una gestión energética verdaderamente predictiva, proactiva y basada en evidencia.

Esta necesidad se vuelve aún más crítica en entornos complejos como los campus universitarios, donde coexisten diversos tipos de espacios con demandas energéticas

heterogéneas: aulas, oficinas administrativas, laboratorios, centros de cómputo y zonas comunes. Según (Himeur et al., 2021a), los sistemas tradicionales de gestión energética presentan debilidades estructurales frente a este tipo de contextos multivariados, ya que carecen de la capacidad de adaptarse dinámicamente a patrones de consumo diversos y en constante cambio.

Esta complejidad en el entorno universitario, sumada al volumen creciente de datos generados por los 55 medidores inteligentes distribuidos en diferentes edificios del campus, cuyos perfiles de consumo varían según la actividad académica, administrativa o técnica que allí se desarrolla, así como la necesidad institucional de optimizar recursos y cumplir con compromisos ambientales, hace indispensable el desarrollo de soluciones automatizadas e inteligentes.

En particular, un agente inteligente, concebido como un asistente digital capaz de comprender y aprender de los datos para formular decisiones o recomendaciones, podría no solo detectar comportamientos anómalos, sino también evaluar estrategias, proponer ajustes proactivos y retroalimentarse de los resultados obtenidos para optimizar decisiones futuras en materia de sostenibilidad.

1.2 Justificación del problema

Este proyecto se justifica por la necesidad de trascender las capacidades actuales de monitoreo energético implementadas por ESPOL a través de PREC, avanzando hacia una solución automatizada que integre análisis inteligente, interpretación contextual y recomendaciones en lenguaje natural. A pesar de contar con una infraestructura tecnológica avanzada como la plataforma de PREC, aún persisten limitaciones en la toma de decisiones estratégicas relacionadas con el uso eficiente de la energía.

Actualmente, muchas de estas decisiones se fundamentan en criterios intuitivos, debido a la dificultad de procesar e interpretar en tiempo real los datos generados por los múltiples medidores distribuidos en el campus. Esta situación no solo compromete la efectividad de las acciones sostenibles, sino que también restringe la capacidad

institucional para cumplir con estándares internacionales como la norma ISO 50001 y con los ODS establecidos por la ONU.

De acuerdo con (Lei et al., 2023) (Y. Song et al., 2024), la incorporación de modelos de aprendizaje automático y enfoques basados en inteligencia artificial permite avanzar hacia sistemas autónomos, capaces de operar en tiempo real, adaptarse a contextos cambiantes y maximizar la eficiencia en el uso de los recursos.

A pesar de que los modelos tradicionales de aprendizaje automático pueden detectar patrones o realizar predicciones específicas, presentan limitaciones al momento de interpretar resultados de forma comprensible o proponer acciones contextualizadas en lenguaje natural. Actualmente, no existe en la plataforma PREC un mecanismo que permita interactuar con los datos a través de un agente conversacional o que traduzca información técnica en recomendaciones prácticas para los responsables de sostenibilidad. Esta ausencia dificulta el acceso a la información para usuarios no técnicos y limita la toma de decisiones colaborativas e informadas. En este contexto, se propone el desarrollo de un agente de lenguaje que complementa las capacidades analíticas del sistema con funciones de interpretación y generación de recomendaciones comprensibles, facilitando así una interacción más natural, accesible y basada en evidencia con los datos energéticos del campus.

Además del impacto operativo en la gestión institucional, este proyecto representa una contribución académica significativa al campo de la ciencia de datos aplicada a la sostenibilidad energética. La construcción de un agente inteligente que opere en un entorno real como un campus universitario, integrando datos multivariados en tiempo real, constituye un caso valioso de estudio sobre la aplicabilidad de técnicas de aprendizaje automático en escenarios complejos. Su diseño y validación pueden servir como modelo para otras instituciones educativas que enfrentan desafíos similares, aportando tanto a la literatura como a la práctica profesional en áreas de transformación digital y sostenibilidad.

Un desafío clave en este tipo de entornos es la ausencia de etiquetas manuales o clasificaciones previas que indiquen qué comportamientos corresponden a situaciones normales o anómalas e inclusive problemas de datos faltantes. Esta limitación dificulta la aplicación de enfoques supervisados y exige técnicas que puedan aprender directamente de los datos sin depender de estructuras predefinidas. (Kuang et al., 2025) proponen un enfoque no supervisado para la imputación de datos basado en autoencoders variacionales que permitirá que el agente inteligente se adapte de forma autónoma a la diversidad de patrones de consumo presentes en los distintos espacios del campus, identificando desviaciones relevantes sin necesidad de reglas explícitas.

La capacidad de identificar comportamientos atípicos de forma automática representa también una fuente valiosa de evidencia objetiva para los procesos de mejora continua requeridos por la norma ISO 50001. (Grimaccia et al., 2023) desarrollan métodos basados en datos alineados con la norma ISO 50001 para mejorar la eficiencia energética, aunque esta norma no prescribe tecnologías específicas, sí enfatiza la necesidad de contar con datos objetivos y mecanismos de monitoreo confiables para respaldar auditorías internas, establecer líneas base energéticas y verificar el impacto de las acciones implementadas.

Además, al tratarse de una propuesta desarrollada en un entorno real como el campus universitario de ESPOL, este proyecto fortalece la vinculación entre investigación aplicada, sostenibilidad institucional y transformación digital, alineándose con los ejes estratégicos de innovación académica de la universidad.

Finalmente, esta iniciativa se alinea con las tendencias globales hacia el desarrollo de campus inteligentes, donde la gestión energética basada en inteligencia artificial es un componente clave para lograr sostenibilidad operativa. La solución propuesta promueve una cultura institucional de toma de decisiones basadas en evidencia y orientadas al uso estratégico de los datos. Desde el punto de vista metodológico, la arquitectura de la agente inteligente desarrollada será innovadora y adaptable, permitiendo además la evaluación cuantitativa del impacto de las acciones energéticas, lo que fortalecerá los procesos de mejora continua dentro de la institución.

A futuro, esta arquitectura podría ser escalable o replicable en otras instituciones educativas o entornos públicos que enfrenten desafíos similares de eficiencia energética, convirtiéndose así en un modelo de referencia tanto en el ámbito académico como profesional.

1.3 Objetivos

1.3.1 Objetivo General

Implementar un agente inteligente conversacional, basado en procesamiento de lenguaje natural, que interactúe con los datos energéticos del campus de ESPOL para la mejora en la toma de decisiones estratégicas en la Dirección de Sostenibilidad Institucional, optimizando la eficiencia energética y el cumplimiento de los objetivos de sostenibilidad.

1.3.2 Objetivos Específicos

Analizar los datos históricos de consumo energético institucional y la caracterización de sus patrones, con el fin de la alimentación en el diseño del agente inteligente y la definición de sus capacidades de comprensión contextual.

Implementar un prototipo funcional del agente inteligente conversacional que combine visualización dinámica, análisis automatizado para la mejora de la gestión energética dentro del campus universitario.

Evaluar la efectividad y usabilidad del agente conversacional mediante pruebas de validación con usuarios expertos de la Dirección de Sostenibilidad, para la determinación de su impacto en la agilidad y precisión de la toma de decisiones estratégicas.

1.4 Marco teórico

1.4.1 Sistemas de Gestión Energética Inteligente (SGEn) en Campus Universitarios

La gestión energética en los campus universitarios ha evolucionado de un proceso pasivo de medición a un sistema dinámico y estratégico conocido como Sistema de Gestión Energética Inteligente (SGEn). Este cambio es impulsado por la adopción de normativas internacionales, como la ISO 50001, y el compromiso con los Objetivos de Desarrollo Sostenible (ODS) de la Agenda 2030, particularmente el ODS 7 (Energía asequible y no contaminante) y el ODS 13 (Acción por el clima) (Seraj et al., 2024) (Zhou et al., 2023).

Un SGEn en el entorno universitario se caracteriza por la recopilación masiva de datos de series de tiempo provenientes de medidores inteligentes (Introna et al., 2024). La complejidad de estos datos, a menudo multivariados y con heterogeneidad temporal, exige el uso de Inteligencia Artificial (IA) para generar valor. Mientras que los sistemas de monitoreo iniciales se enfocaron en la visualización en tiempo real, la mejora en la toma de decisiones estratégicas requiere superar el análisis meramente descriptivo.

El reto fundamental en este contexto es transformar grandes volúmenes de datos técnicos en información accionable que la dirección pueda utilizar para implementar medidas de eficiencia, como la renegociación de contratos energéticos, la programación óptima de equipos o la identificación de desviaciones significativas (Rossi et al., 2022).

Estudios recientes confirman que la integración de modelos de Aprendizaje Automático (ML), incluyendo enfoques de clustering para la caracterización de patrones de consumo y modelos de forecasting para la optimización de la demanda, es indispensable para que las universidades alcancen la certificación ISO 50001 de manera efectiva. Sin embargo, persiste una brecha crítica en la interfaz humana, donde la salida técnica de los modelos ML no se traduce inmediatamente en un lenguaje claro y recomendaciones estratégicas para los usuarios finales, limitando el impacto real en la gobernanza energética (Zhou et al., 2023).

1.4.2 Agentes Inteligentes y Modelos de Lenguaje Grande (LLMs) en la Ciencia de Datos

La implementación de sistemas SGEN requiere una capa de interacción que traduzca la complejidad del análisis de datos en acciones ejecutables para el usuario final (Min et al., 2024). En este contexto, el Agente Inteligente Conversacional se posiciona como el elemento clave para superar la barrera técnica de los dashboards tradicionales. Un agente inteligente es un programa computacional capaz de percibir su entorno, tomar decisiones que maximicen su probabilidad de éxito y generar respuestas coherentes en lenguaje natural (Handler et al., 2024).

El desarrollo de estos agentes ha sido revolucionado por la aparición de los Modelos de Lenguaje Grande (LLMs), que constituyen el núcleo de procesamiento del lenguaje natural (PNL) de próxima generación. Los LLMs no solo permiten la comprensión y generación fluida del lenguaje, sino que también poseen capacidades emergentes de razonamiento complejo y zero-shot learning (aprendizaje con cero ejemplos) (Munson et al., 2025).

En el ámbito de la Ciencia de Datos, el LLM se transforma en un Agente de Razonamiento Aumentado que opera bajo un patrón de pensamiento-y-acción, donde el agente es capaz de razonar sobre la intención del usuario y la información disponible, y genera una respuesta estratégica.

Esta arquitectura de agente permite al sistema ir más allá de una simple conversación, facilitando un Sistema de Soporte a la Decisión (DSS) que interactúa dinámicamente con los datos de series de tiempo. Para que un agente sea efectivo en un dominio técnico como la gestión energética, debe ser "orientado a tareas" (Task-Oriented) y "refinado" (Refined), lo que implica un ajuste fino (R-Tuning) o una configuración especializada que lo conecte de manera fiable con la base de conocimiento específica del campus ESPOL (Anisuzzaman et al., 2025).

1.4.3 Generación Aumentada por Recuperación (RAG) para la Toma de Decisiones Basada en Datos

Para que un Agente Inteligente basado en Modelos de Lenguaje Grande (LLMs) sea efectivo en un entorno técnico de gestión energética (SGEn), es fundamental que sus recomendaciones se basen en la información operacional y actualizada del sistema, y no únicamente en el conocimiento genérico de su entrenamiento (Chen et al., 2023). La técnica de Generación Aumentada por Recuperación (Retrieval-Augmented Generation, RAG) emerge como la solución arquitectónica para conectar la capacidad de razonamiento del LLM con la base de datos propietaria del campus ESPOL (Lewis et al., 2021).

RAG es un paradigma que supera la limitación de la ventana de contexto del LLM y, crucialmente, mitiga el fenómeno de la "alucinación" al obligar al modelo a fundamentar sus respuestas en hechos verificables extraídos de una fuente de conocimiento externa (Gao et al., 2024). El uso de RAG en este proyecto garantiza que la recomendación estratégica no sea una inferencia probabilística genérica, sino un razonamiento contextualizado basado en la serie de tiempo energético real.

El proceso de RAG en la toma de decisiones estratégicas se enfoca en la traducción de insights de datos en recomendaciones prácticas y se compone de tres etapas esenciales en el contexto de la gestión energética:

1. Recuperación (Retrieval): Cuando el usuario solicita una acción o justificación estratégica (p. ej., "¿Cuál es el patrón de consumo predominante del Edificio 5 y por qué se recomienda una intervención?"), el agente utiliza el query para buscar y recuperar los resultados técnicos. Esto incluye las caracterizaciones de patrones de consumo, las alertas estratégicas predefinidas y los datos de series de tiempo ya pre-procesados.
2. Aumento (Augmentation): Los fragmentos de información recuperados (e.g., "Patrón predominante identificado para el Edificio 5: Consumo base inesperadamente alto en horas pico de la mañana"), son inyectados como

contexto fáctico en el prompt de entrada del LLM, junto con la pregunta original del usuario.

3. **Generación (Generation):** El LLM utiliza los datos fácticos recuperados para sintetizar una respuesta estratégica en lenguaje natural, garantizando que la recomendación esté ligada directamente al análisis científico subyacente. Esto asegura que el agente cumpla su función de Sistema de Soporte a la Decisión (DSS) (Arguello & Villalta, 2024).

La implementación de RAG garantiza que la salida del agente sea oportuna y confiable, lo cual es esencial cuando las recomendaciones impactan directamente la toma de decisiones estratégicas, el cumplimiento normativo (ISO 50001) y la eficiencia operacional de la Dirección de Sostenibilidad.

1.4.4 Arquitecturas de Agentes de Lenguaje y Razonamiento (ReAct)

El Agente Inteligente propuesto en este proyecto no se limita a ser un chatbot, sino que debe funcionar como un Sistema de Soporte a la Decisión (DSS), capaz de ejecutar código y realizar cálculos para interactuar con los datos energéticos. Esta funcionalidad requiere una arquitectura específica que integra el lenguaje y la acción, conocida como Reasoning and Acting (ReAct) (T. Song et al., 2024).

ReAct es un patrón de diseño que habilita a los Modelos de Lenguaje Grande (LLMs) para generar tanto trazas de razonamiento (Thought) como acciones específicas (Action) (Yao et al., 2023). En lugar de generar una respuesta directa e inventada, el agente utiliza su capacidad de lenguaje para:

- **Pensar (Thought):** Analizar la consulta del usuario e internamente planificar los pasos necesarios para resolverla.
- **Actuar (Action):** Generar y ejecutar código, como una consulta SQL contra la base de datos InfluxDB v2 o una operación en Pandas para calcular un indicador clave de rendimiento (KPI).

- Observar (Observation): Procesar el resultado tabular de la ejecución del código.
- Generar Respuesta (Response): Utilizar el resultado técnico como contexto fáctico para sintetizar la respuesta final en lenguaje natural.

Esta arquitectura es crucial porque permite que el agente realice un razonamiento basado en código que es verificable y preciso, un requisito indispensable para el análisis técnico de series de tiempo. El patrón ReAct es el pilar que transforma el LLM en una herramienta capaz de manipular y analizar la información del consumo energético en tiempo real, superando las limitaciones de los sistemas estáticos.

CAPÍTULO 2

2. METODOLOGÍA

2.1 Formulación de alternativas de solución

2.1.1 Contextualización del problema y objetivos de diseño

En el contexto de la gestión energética institucional, ESPOL había implementado la Plataforma de Eficiencia Energética del Campus (PREC), la cual permitía la visualización y almacenamiento de datos de consumo energético en tiempo real. Sin embargo, el sistema carecía de mecanismos automatizados de análisis e interpretación, lo que obligaba a los usuarios institucionales a realizar consultas manuales y análisis técnicos para tomar decisiones estratégicas (Domínguez-Bolaño et al., 2024). A partir de esta limitación, se planteó el diseño de un agente inteligente que integra capacidades de procesamiento de lenguaje natural y aprendizaje automático para facilitar el acceso a información energética, mediante consultas conversacionales.

2.1.2 Identificación de Alternativas

2.1.2.1 Alternativa A: Agente basado en reglas

La primera alternativa correspondía a un agente conversacional tradicional basado en reglas estáticas. Esta opción implicaba programar manualmente árboles de decisión que respondieron a un conjunto limitado de preguntas predefinidas. Aunque su implementación resultaba sencilla y no demandaba grandes recursos computacionales, presentaba una baja capacidad de generalización y adaptación ante nuevas consultas.

Según un estudio reciente (Ojha et al., 2024), este tipo de agentes suele fracasar en entornos dinámicos con vocabulario abierto, evidenciado por una caída de precisión a alrededor de 68 % con entradas ambiguas, y con desafíos de escalabilidad al manejar muchas reglas.

2.1.2.2 Alternativa B: Prototipo con LLM estático

La segunda alternativa consistió en desarrollar un agente conversacional con un modelo de lenguaje pre entrenado (LLM) estático, como GPT-J o LLaMA2, capaz de interpretar

preguntas en lenguaje natural. Esta opción mejoraba la comprensión semántica frente al enfoque anterior, pero no estaba conectada directamente a una fuente de datos en tiempo real. Como señalan (Jin et al., 2024), los modelos estáticos son útiles para generación de texto general, pero no están diseñados para responder preguntas actualizadas sobre datos en bases temporales específicas como InfluxDB.

2.1.2.3 Alternativa C: Agente conversacional con GPT 5 y RAG

La tercera alternativa integró un enfoque de generación aumentada por recuperación (RAG) con un LLM, lo cual permitía acceder a los datos energéticos almacenados en InfluxDB y generar respuestas personalizadas a través de una capa de razonamiento con pandas. Plataformas como RAG, basadas en sistemas de recuperación de pasajes con modelos generativos (Lewis et al., 2021) ya habían demostrado que esta combinación era efectiva para democratizar el acceso a datos técnicos en lenguaje natural. Además, la modularidad del enfoque RAG permitía la implementación de filtros, visualizaciones automáticas y respuestas multilingües, lo que lo convertía en una alternativa escalable y adaptable.

2.1.3 Criterios de evaluación de las alternativas

Las alternativas fueron evaluadas con base en cinco criterios principales: (1) adaptabilidad a nuevas consultas, (2) integración con datos energéticos en tiempo real, (3) facilidad de mantenimiento, (4) requerimientos computacionales y (5) nivel de autonomía en la generación de respuestas. Cada criterio fue ponderado mediante juicio de expertos y simulaciones preliminares sobre datos históricos de la plataforma PREC.

2.1.4 Selección de la mejor alternativa

Tras el análisis comparativo mostrado en la Tabla 2.1, la Alternativa C fue seleccionada como la solución óptima. Esta opción permitió resolver las limitaciones del sistema actual, integrando modelos de lenguaje de última generación con mecanismos de recuperación y ejecución de código en tiempo real. Investigaciones recientes como las de (T. Song et al., 2024) demostraron que GPT 5 ofrecía un rendimiento superior en tareas técnicas de análisis energético cuando se integraba con frameworks tipo RAG. Así, la arquitectura

basada en LLM + RAG proporcionó un balance entre precisión, flexibilidad y eficiencia computacional, constituyéndose en la base para el diseño conceptual detallado del agente propuesto.

Tabla 2.1 Selección de la mejor alternativa.

Criterio de Evaluación	Alternativa A: Agente Basado en Reglas	Alternativa B: Prototipo con LLM Estático	Alternativa C: Agente con GPT 5 y RAG
(1) Adaptabilidad a Nuevas Consultas	Baja (Limitado a reglas predefinidas)	Media-Alta (Buena comprensión semántica, pero limitada por el <i>corpus</i> de entrenamiento)	Alta (Extensible por medio de la recuperación de contexto RAG)
(2) Integración con Datos en Tiempo Real	Baja (Requiere actualización manual de reglas/datos)	Baja (No diseñado para consultar bases temporales como InfluxDB)	Alta (Conexión directa a InfluxDB y ejecución de código Pandas)
(3) Facilidad de Mantenimiento	Media (Mantenimiento difícil a gran escala debido a la complejidad de las reglas)	Media (Requiere menos mantenimiento que A, pero no puede actualizar conocimiento)	Media-Alta (Modularidad RAG que permite actualizar datos y modelos de forma independiente)
(4) Requerimientos Computacionales	Bajo (Implementación sencilla)	Medio-Alto (Requiere hardware potente para LLM local)	Medio (Requiere hardware para LLM y orquestación RAG/Pandas)
(5) Nivel de Autonomía en Respuestas	Bajo (Respuestas determinísticas y rígidas)	Medio (Generación de texto general)	Alto (Generación de respuestas personalizadas basadas en datos y razonamiento)

2.2 Diseño conceptual

2.2.1 Descripción general de la arquitectura del agente

El diseño conceptual del agente inteligente se estructuró a partir de una arquitectura modular, compuesta por tres capas principales: (1) interfaz conversacional, (2) motor de interpretación y (3) capa de acceso a datos. La interfaz fue responsable de captar las consultas del usuario en lenguaje natural; el motor de interpretación, basado en GPT 5, clasificaba la intención del usuario y generaba prompts o consultas; y la capa de acceso se encargaba de interactuar con la base de datos InfluxDB v2 y realizar los cálculos necesarios mediante pandas.

2.2.2 Componentes principales y flujos de información

El agente se componía de los siguientes módulos funcionales: (i) un generador de prompts que adaptaba la entrada del usuario al formato requerido por el LLM, (ii) un ejecutor de código que permitía el uso de pandas para operaciones como agrupaciones, filtrados o cálculos de indicadores, (iii) un generador de respuestas finales en lenguaje natural, y (iv) un generador de gráficos. El flujo de información se iniciaba con la entrada del usuario, seguida por el procesamiento de intención, la ejecución del código asociado y la formulación de una respuesta contextualizada.

2.2.3 Diagrama de bloques y casos de uso

El diagrama de bloques mostraba la interacción entre los componentes mencionados, destacando el rol del LLM como núcleo del sistema de razonamiento. Los casos de uso considerados incluyeron: Consulta y reporte detallado del consumo energético histórico, desglosado por campus, edificios específicos o facultades en rangos temporales horarios, diarios o mensuales y generación de visualizaciones automáticas. Estos escenarios fueron validados a través de un conjunto de datos históricos proporcionado por la Dirección de Sostenibilidad de ESPOL.

2.3 Metodología de diseño

2.3.1 Enfoque de investigación

El enfoque metodológico adoptado para el desarrollo del agente fue de tipo aplicado y descriptivo-experimental. Se utilizó una metodología basada en el ciclo Cross-Industry Standard Process for Data Mining (CRISP-DM), adaptada al contexto del procesamiento de lenguaje natural y manejo de datos energéticos. Esto facilitó iteraciones controladas entre la comprensión del dominio, la preparación de datos, el modelado, la evaluación y el despliegue del prototipo (Elkabalawy et al., 2024).

2.3.2 Fases del proceso de diseño

2.3.2.1 *Recolección y preparación de datos*

Se trabajó con una base de datos recopilada por la plataforma PREC desde el año 2023, con registros de consumo energético de edificios del campus, recolectados a intervalos de 15 segundos.

En la Tabla 2.2 se presentan las principales variables extraídas de los medidores inteligentes, indicando el tipo de dato, la naturaleza de la variable, ejemplos representativos y unidad.

Tabla 2.2 Variables de Datos Tabulares procesados por el Agente Inteligente.

Variable	Tipo de Dato	Tipo de Variable	Ejemplo	Unidad
timestamp	Fecha-Hora	Cuantitativa temporal	2024-10-07 00:00:00	Datetime
corriente	Decimal	Cuantitativa continua	71.68	A
frecuencia	Decimal	Cuantitativa continua	59.95	Hz
FP	Decimal	Cuantitativa continua	0.5949	NA

potencia	Decimal	Cuantitativa continua	16.5	kW
energía	Decimal	Cuantitativa continua	0.07	kWh

El preprocesamiento se realizó en Python con la biblioteca pandas de acuerdo con metodologías recomendadas por (Seraj et al., 2024).

Además, se considerarán los documentos institucionales que incluyen informes de avance sobre los Objetivos de Desarrollo Sostenible (ODS), políticas internas, auditorías energéticas, y reportes relacionados con la implementación de la norma ISO 50001. Esta información será indexada en una base de datos vectorial mediante FAISS, facilitando búsquedas semánticas y consultas contextuales desde el agente.

En la Tabla 2.3 se detallan las principales variables que se manejan en el proceso de desarrollo del modelo de agente inteligente. Estas variables corresponden a los datos documentales procesados por el agente, considerando tanto identificadores únicos, metadatos del archivo y el contenido textual relevante.

Tabla 2.3 Variables de Datos Documentales procesados por el Agente Inteligente.

Variable	Tipo de Dato	Tipo de Variable	Ejemplo
id_faiss	Entero	Cuantitativa discreta	0
nombre_archivo	Texto	Cualitativa nominal	Informe-Avance-ODS-2021.pdf
pagina	Entero	Cuantitativa discreta	1
texto	Texto	Cualitativa estructurada	no "Informe de avance del cumplimiento..."

2.3.2.2 Implementación de Búsqueda Semántica mediante FAISS y RAG.

Para habilitar la Generación Aumentada por Recuperación (RAG), la información documental (informes ISO 50001, políticas, etc.), se estructurará en una base de datos vectorial utilizando FAISS (Facebook AI Similarity Search). (Douze et al., 2025) presentan la biblioteca Faiss como una herramienta fundamental para la búsqueda de similitud de vectores y el procesamiento de grandes colecciones de embeddings. De esta manera, FAISS actuó como el motor de búsqueda semántica, permitiendo al agente recuperar pasajes de texto con el contexto más relevante para la consulta del usuario, asegurando respuestas fundamentadas y libres de alucinaciones.

En la Figura 2.1, se muestra el flujo de integración de documentos a partir de fuentes vectorizadas y cómo el agente realiza la recuperación de contexto relevante a partir de consultas específicas. El esquema también ilustra el uso de FAISS para la búsqueda semántica y la obtención de respuestas precisas.

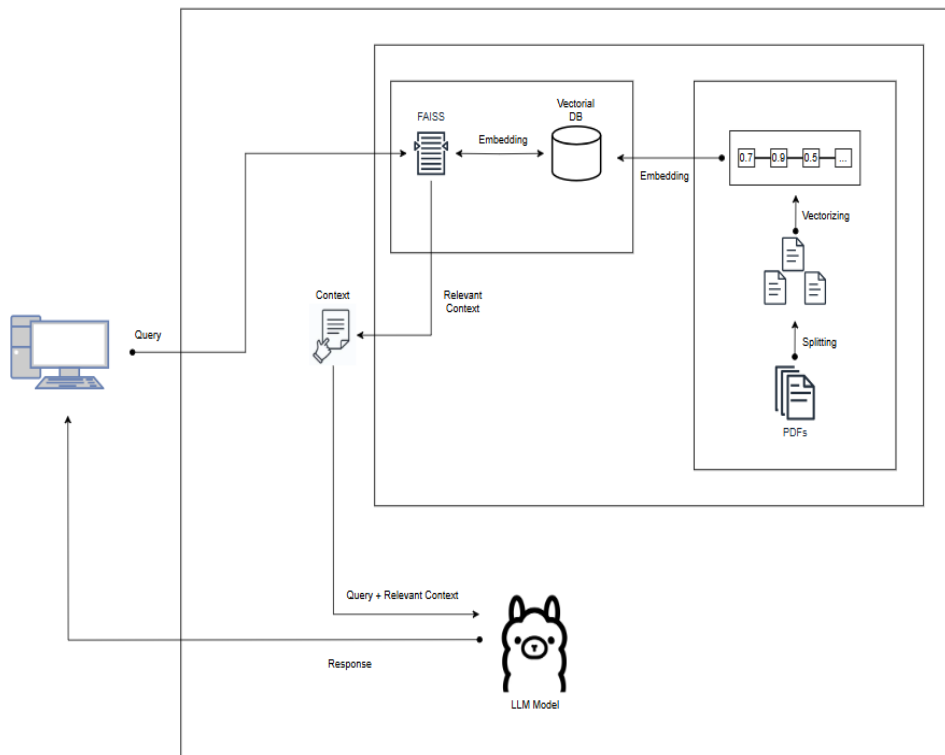


Figura 2.1 Arquitectura del flujo de Generación Aumentada por Recuperación (RAG) con FAISS.

2.3.2.3 Integración con InfluxDB v2 y pandas

El sistema se conectó con la base de datos InfluxDB v2 a través de consultas en el lenguaje funcional Flux. Los datos recuperados fueron transformados directamente a DataFrames para su análisis mediante pandas. Esta arquitectura permite realizar operaciones avanzadas como agregaciones, filtrado temporal y comparaciones entre edificios o zonas de manera eficiente en el servidor. Estudios comparativos de rendimiento muestran que InfluxDB, junto con el motor de consultas Flux, es altamente eficaz para flujos de datos en tiempo real en entornos con altos volúmenes de escritura y lectura (Shah et al., 2022).

2.3.2.4 *Desarrollo del agente conversacional (LangChain, Python REPL)*

Se utilizó OpenAI como marco de orquestación para integrar el LLM, el entorno de ejecución de código (Python REPL) y la base de datos. El agente tenía capacidad de interpretar la intención, extraer la información necesaria mediante pandas y generar una respuesta en lenguaje natural contextualizado. Esta metodología RAG (Retrieval-Augmented Generation) fue inspirada en trabajos como los de (Lewis et al., 2020) quienes introdujeron este enfoque para mejorar la precisión de modelos LLM en tareas basadas en hechos.

2.4 *Diseño detallado del producto o servicio*

2.4.1 *Principios técnicos y criterios de diseño*

El diseño del agente se fundamentó en principios de modularidad, escalabilidad y mantenibilidad. Se priorizó la arquitectura desacoplada mediante microservicios y la integración por interfaces estandarizadas como API REST y FluxQL. Uno de los principales criterios de diseño fue la interpretabilidad del sistema, para garantizar que los usuarios comprendieran no sólo el resultado, sino también el razonamiento subyacente (Doshi-Velez & Kim, 2017). Además, se buscó un equilibrio entre eficiencia computacional y flexibilidad en las consultas, seleccionando componentes ligeros pero potentes como pandas para el análisis local de los datos.

2.4.1.1 *Usabilidad y accesibilidad de la interfaz*

La interfaz del sistema fue diseñada con principios de usabilidad centrados en el usuario, facilitando la formulación de preguntas en lenguaje natural. Se emplearon buenas prácticas de diseño UX/UI recomendadas para entornos institucionales (Nielsen, 2020) incluyendo retroalimentación visual, validación de entradas y mensajes de ayuda contextual.

2.4.1.2 Escalabilidad y rendimiento

El sistema fue concebido para escalar horizontalmente, aprovechando la arquitectura basada en contenedores (Docker) y el uso de consultas optimizadas en la capa de base de datos. Se establecieron políticas de control de carga y cacheo local de resultados frecuentes, siguiendo recomendaciones de diseño para agentes conversacionales en contextos con alto volumen de datos (Mechkaroska Daniela and Domazet, 2024).

2.4.1.3 Interoperabilidad y modularidad

Se aseguró la interoperabilidad con otros sistemas de la institución mediante el uso de estándares abiertos como JSON y MQTT, lo cual permitió futuras integraciones con dashboards energéticos o sistemas de notificación. Cada módulo del agente fue construido como componente reutilizable, facilitando su mantenimiento y extensión.

2.4.1.4 Diseño del flujo de interacción

Se diseñó un flujo lógico de operación que permitió al agente responder entre consultas sobre documentos (textuales) y preguntas sobre datos energéticos (tabulares). Este diseño se inspira en el modelo ReAct (Reasoning and Acting) (Aksitov et al., 2023) habilitando tanto el razonamiento como la acción. Esta fase responde al segundo objetivo específico, al estructurar la lógica de interacción del agente.

La Figura 2.2 representa el flujo de interacción cuando el usuario realiza una consulta energética. El agente primero verifica la validez de la consulta usando un modelo LLM como validador de FluxQL. Si la consulta es correcta, se envía al motor de base de datos InfluxDB para su ejecución. El resultado obtenido se procesa y se presenta en un formato comprensible para el usuario.

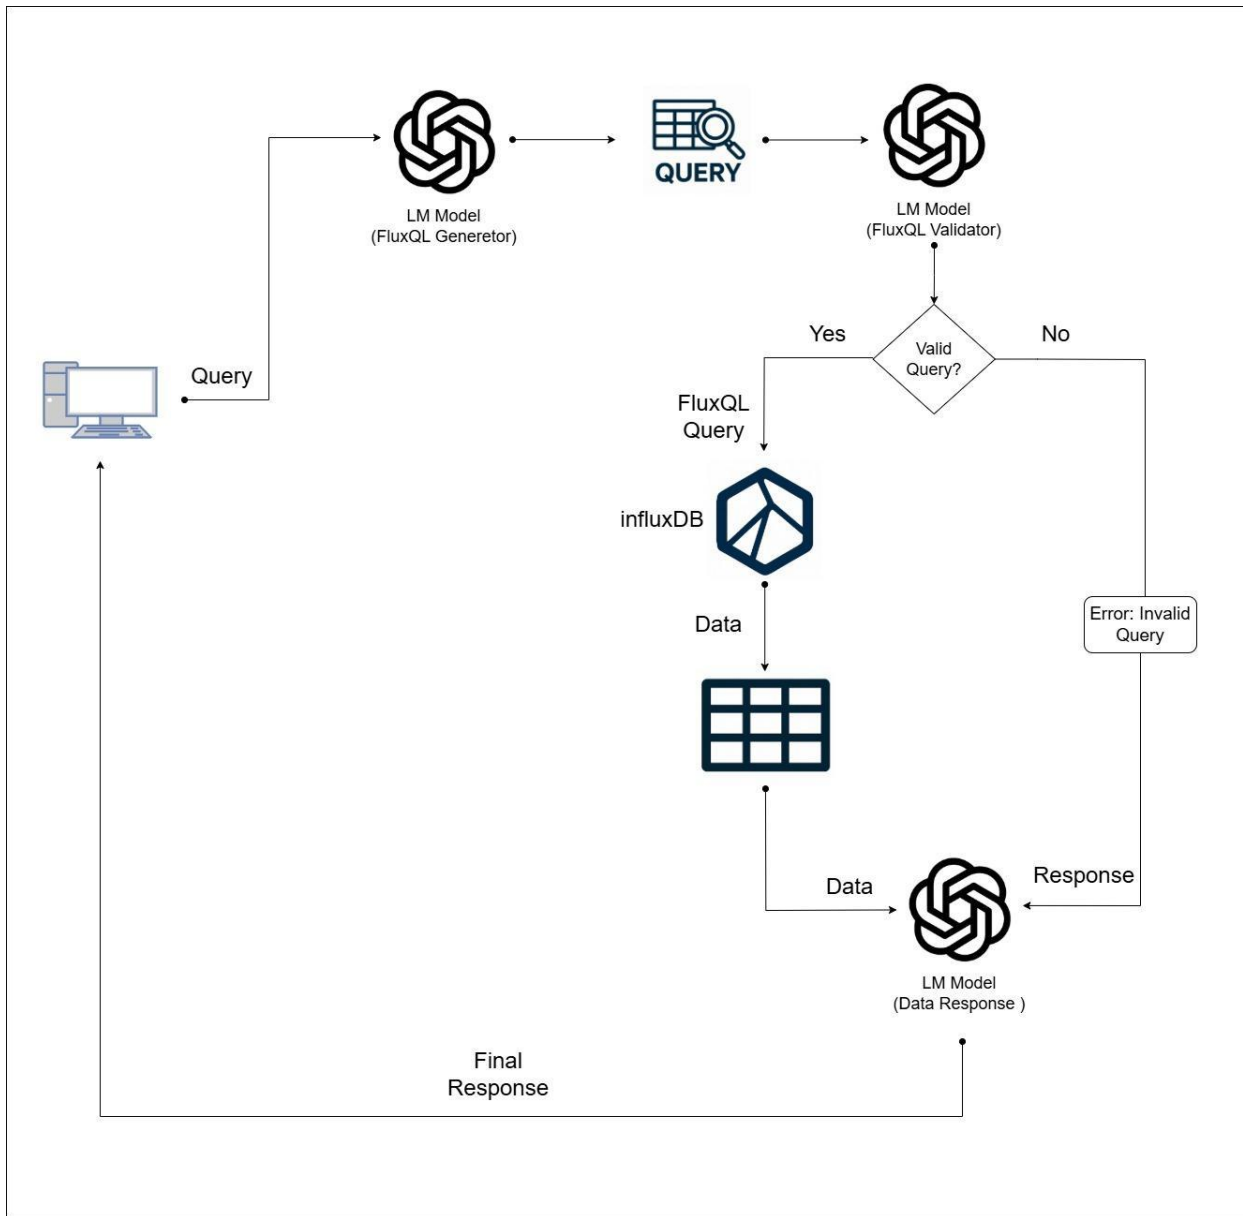


Figura 2.2 Flujo de interacción y validación de consultas energéticas.

2.4.2 Selección de recursos

2.4.2.1 Hardware

El sistema fue desplegado en un servidor local con CPU de 8 núcleos, 32 GB de GPU, 32 GB de RAM y almacenamiento SSD de 2 TB, con posibilidad de escalamiento hacia infraestructura cloud si se requería mayor disponibilidad. Los datos provenían de medidores inteligentes trifásicos, previamente integrados a la red institucional mediante Modbus TCP/IP.

2.4.2.2 Software

Se utilizó Python como lenguaje principal, con librerías como pandas, scikit-learn, langchain, sqlalchemy e influxdb-client. Para el entorno de ejecución se emplearon contenedores Docker, y para el almacenamiento y consulta de datos energéticos se utilizó InfluxDB v2. El modelo GPT 5 fue ejecutado mediante OpenAI, asegurando privacidad y bajo costo operativo.

2.5 Especificaciones técnicas

2.5.1 Requerimientos funcionales

El agente inteligente fue diseñado para cumplir con una serie de requerimientos funcionales, entre los cuales se incluyeron: (i) interpretar preguntas en lenguaje natural relacionadas con el consumo energético; (ii) generar consultas FluxQL o expresiones en pandas; (iii) ejecutar dichas consultas en InfluxDB v2; y (iv) entregar una respuesta textual clara, con una visualización gráfica.

2.5.2 Requerimientos no funcionales

Dentro de los requerimientos no funcionales, se establecieron criterios como: (i) tiempo de respuesta rápida en el 95% de las consultas; (ii) disponibilidad del sistema 24/7; (iii) portabilidad en entornos Docker.

2.5.3 Arquitectura de software y despliegue

La arquitectura del sistema fue concebida como una solución distribuida y modular, estructurada en microservicios. Cada componente principal (generador de consultas, motor de ejecución, generador de respuestas e imágenes) se desplegó como contenedor independiente. El despliegue se realizó mediante Docker Compose, asegurando su replicabilidad en otros entornos. La base de datos InfluxDB v2 fue configurada con soporte para FluxQL, y el modelo GPT 5 corrió sobre OpenAI.

2.5.4 Detalle de interfaces y API

Se implementaron dos interfaces principales: una interfaz web conversacional desarrollada con REACT y una API REST implementada en nodeJS. Las funciones principales disponibles a través de la API permiten la comunicación entre el usuario de la interfaz web y el modelo.

2.5.5 Modelos de datos y protocolos de comunicación

Los datos se almacenaron en InfluxDB v2 utilizando un motor de almacenamiento optimizado para series temporales basado en TSM (Time-Structured Merge Tree). La estructura de datos se organizó en buckets, siguiendo un modelo de series de tiempo compuesto por mediciones (measurements), etiquetas (tags) para metadatos y campos (fields) para variables como potencia y energía. La comunicación con la base de datos y entre servicios se realizó mediante la API REST de InfluxDB a través de HTTP/1.1, empleando protocolos seguros (HTTPS y TLS) para garantizar la integridad y privacidad en las transferencias de datos.

2.6 Estrategia de identificación causal

2.6.1 Identificación de efectos causales en los datos

Para identificar relaciones causales en los datos de consumo energético, se partió del supuesto de que las variaciones de consumo están influenciadas por factores operativos como tipo de edificio, carga instalada, condiciones ambientales y horarios de funcionamiento. Se aplicaron técnicas de análisis exploratorio de datos (EDA) para detectar patrones temporales y anomalías en el comportamiento energético. Este proceso fue guiado por la hipótesis de que los edificios con características similares presentan perfiles de consumo comparables (Chen et al., 2022).

2.6.2 Tratamiento de datos

El tratamiento de los datos energéticos incluyó varios pasos críticos: detección de valores atípicos, imputación de datos faltantes y eliminación de registros duplicados. Se

aplicaron reglas de control de calidad basadas en umbrales definidos por expertos, y se implementaron mecanismos automáticos para alertar sobre posibles errores en la transmisión o recolección de datos. Estas prácticas garantizan la confiabilidad de los datos utilizados para inferencia causal (Himeur et al., 2021).

2.7 Consideraciones éticas y legales

2.7.1 Privacidad y protección de datos

El desarrollo del agente inteligente implicó el uso de datos energéticos generados en tiempo real por medidores instalados en edificios del campus universitario. Se aplicó restricciones de acceso a los datos para cumplir con los principios establecidos por la (Ley Orgánica de Protección de Datos Personales Del Ecuador, 2021) y el Reglamento General de Protección de Datos (GDPR) de la Unión Europea. Todo acceso a los datos fue auditado y limitado a personal autorizado.

2.7.2 Transparencia e interpretabilidad de modelos

Dado que el sistema incluía componentes de inteligencia artificial, se prioriza la interpretabilidad de los modelos involucrados. Se generaron explicaciones visuales para facilitar su comprensión por parte de usuarios no técnicos. Este enfoque sigue las recomendaciones de (Ribeiro et al., 2016) sobre la importancia de modelos aplicables para garantizar la confianza en sistemas automatizados.

2.7.3 Seguridad de la información

El sistema fue desarrollado siguiendo buenas prácticas de ciberseguridad, incluyendo el uso de protocolos de comunicación cifrados (HTTPS, TLS), autenticación mediante tokens para el acceso a la API y control de versiones en entornos aislados.

2.7.4 Responsabilidad social e impacto institucional

El agente fue diseñado para apoyar a la Dirección de Sostenibilidad en la toma de decisiones informadas, promoviendo una cultura de eficiencia energética dentro de la institución. Además, se promovió la capacitación de usuarios y técnicos en el uso responsable de la herramienta, con el fin de fortalecer la autonomía institucional en la gestión de su infraestructura energética. Finalmente, se realizó una encuesta dirigida al analista eléctrico con el fin de validar el impacto de la solución y cuantificar el tiempo de trabajo manual y la necesidad. (Ver Apéndice D)

CAPÍTULO 3

3. RESULTADOS Y ANÁLISIS

3.1 Resultados Generales del Prototipo del Agente Inteligente

Al finalizar la etapa de desarrollo, se obtuvo un prototipo funcional que integró la comprensión del lenguaje natural con el análisis de series temporales. El sistema desarrolló una interfaz conversacional en español que permitió a los usuarios interactuar sin necesidad de conocimientos técnicos avanzados. La solución central se basó en un motor de interpretación que utilizó GPT 5 y la arquitectura RAG (Retrieval-Augmented Generation), lo que habilitó la generación de respuestas contextuales.

El prototipo logró una integración estable con los 5 medidores inteligentes del campus, como vemos en la Figura 3.1 y 3.2 permitiendo la consulta de datos en tiempo real e histórico de potencia, corriente, voltaje, energía y factor de potencia por edificios. Además, se integró un generador de visualizaciones que produjo automáticamente gráficos de consumo y tendencias, los cuales fueron insertados dentro de las respuestas conversacionales para facilitar la interpretación.

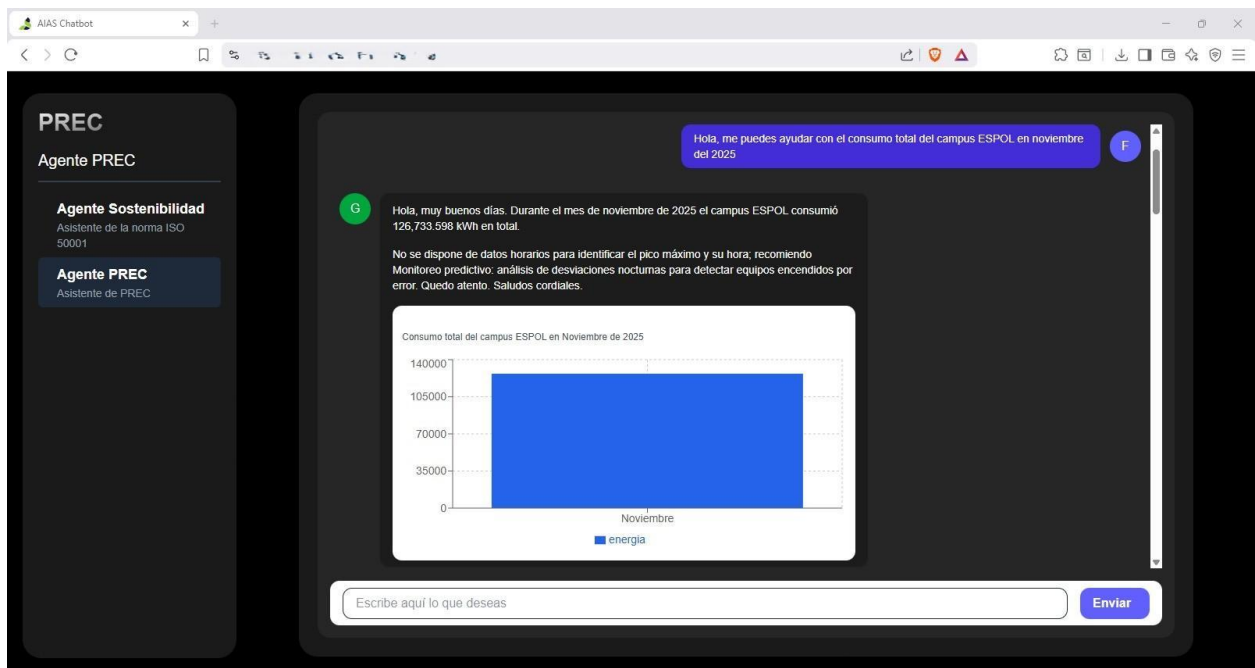


Figura 3.1 Interacción con el Agente conversacional.

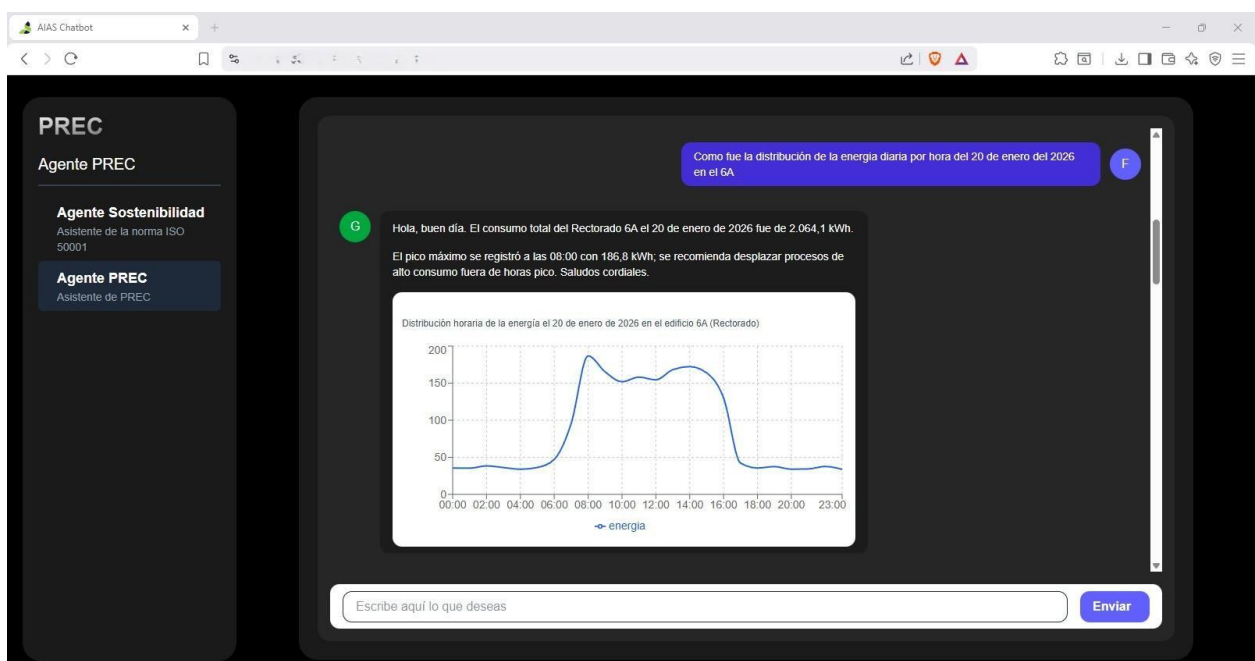


Figura 3.2 Interacción con el Agente conversacional.

El rendimiento del sistema presentó un retraso promedio inferior a 2 minutos en consultas. Como se puede observar en la Figura 3.3, en donde se realizó una consulta

Aunque el procesamiento en GPU optimiza la generación de texto, la latencia total del sistema oscila entre los 54.76 y 92.16 segundos. Este tiempo de respuesta se atribuye a la complejidad intrínseca del mapeo de intenciones hacia consultas InfluxDB y al tiempo de ejecución de las sentencias Flux en la base de datos. La arquitectura basada en microservicios y contenedores Docker permitió gestionar la concurrencia de las peticiones sin degradación significativa, demostrando que el sistema es robusto bajo demanda, aunque el rendimiento podría optimizarse aún más mediante la reducción del overhead en la comunicación entre servicios.

Tabla 3.1 Tiempos de respuesta y Escalabilidad.

Pruebas	Tiempo de Respuesta [min:seg]	Tiempo de Respuesta [seg]
Simultaneas		
Prueba 1	1 min 13.92 seg	73.92 seg
Prueba 2	1 min 19.69 seg	79.69 seg
Prueba 3	1 min 32.16 seg	92.16 seg
Prueba 4	0 min 55.28 seg	55.28 seg
Prueba 5	0 min 54.76 seg	54.76 seg

3.3 Impacto en la Toma de Decisiones

Las pruebas de usuario realizadas con personal de la Dirección de Sostenibilidad demostraron una optimización crítica en la gestión de datos. El tiempo requerido para obtener un reporte energético específico, como la generación de consultas métricas y visualizaciones, se redujo drásticamente de un promedio de 30 minutos en el proceso manual a tan solo 1.18 minutos (71.16 segundos) en promedio utilizando el agente.

Entre los impactos directos observados, destaca la capacidad de comparación instantánea de consumos entre edificios con características similares y la generación de un ranking de inmuebles con mayor demanda mensual. Al integrar estas métricas con recomendaciones específicas para el ajuste de horarios de operación, el agente se consolida como una herramienta estratégica que optimiza la toma de decisiones y la eficiencia energética del campus.

3.4 Resultados Específicos del Aporte de Ciencia de Datos

Desde el enfoque de Ciencia de Datos, uno de los principales logros del proyecto fue la mejora sustancial en la calidad de los datos utilizados para el entrenamiento y operación del agente.

Un aporte relevante fue la generación automática de visualizaciones dinámicas que acompañan las respuestas del agente. Estas representaciones gráficas incluyen tendencias horarias, perfiles de carga diarios y comparaciones mensuales entre edificios, lo que facilita la comprensión de los datos y agiliza el análisis por parte de los responsables de la gestión energética.

Finalmente, se incorporó la traducción automática de hallazgos técnicos a un lenguaje natural comprensible para usuarios no expertos. Este mecanismo permitió presentar los resultados y recomendaciones de manera clara y accesible, fomentando una mayor adopción del sistema por parte del personal de la Dirección de Sostenibilidad y fortaleciendo la toma de decisiones basadas en evidencia.

3.5 Análisis de Costos

En la Tabla 3.2, se muestra el análisis de costos, el cual consideró recursos de hardware, software, personal técnico y mantenimiento.

Tabla 3.2 Análisis de Costos

Categoría	Detalle	Costo aproximado (USD)
Hardware	Servidor local CPU 8 núcleos, 32 GB RAM, SSD 2 TB	2,500
Medidores inteligentes	Ya existentes en la infraestructura	0
Software	Python, librerías, InfluxDB v2 (versión community)	10
Desarrollo	2 desarrolladores por 4 meses (20 h/semana, \$15/h)	9,600
Capacitación de usuarios	Talleres y manual de uso	500

Mantenimiento anual	Actualización de modelos y soporte técnico	1,200
Total de inversión inicial		12,610

Actualmente, el proceso manual de análisis energético para generar un solo gráfico o reporte con indicadores clave toma aproximadamente 30 minutos a un analista eléctrico. Con un costo horario del especialista de \$7/hora, el costo operativo manual anual por esta carga de trabajo se estima en \$3,407.25.

Con la implementación del agente inteligente, y aprovechando la optimización de inferencia del LLM en la GPU, el tiempo promedio para generar el mismo análisis se reduce de forma drástica a solo 1.18 minutos (71.16 segundos). Esta reducción de tiempo proyecta un ahorro anual estimado de \$3,272.50

Dado que la inversión inicial total del proyecto asciende a \$12,610, este ahorro proyectado implica un periodo de recuperación de la inversión (ROI) de aproximadamente 3.85 años.

El análisis de las respuestas obtenidas de la encuesta aplicada al analista eléctrico valida y contextualiza las premisas utilizadas en la proyección de la Viabilidad Económica y Operativa (Ver Anexo D). Las respuestas confirman la alta dedicación de tiempo en tareas manuales, con un tiempo promedio para la generación de un reporte que se sitúa en el rango de 30 a 45 minutos, lo que confirma que el umbral de 30 minutos utilizado en el cálculo del ROI es un valor representativo del proceso manual.

La encuesta también valida la necesidad de la solución propuesta. El especialista califica con un nivel alto (4/5) la dificultad para traducir los datos técnicos y los gráficos en recomendaciones estratégicas claras y accionables para los directivos. Adicionalmente, la funcionalidad más valorada fue la presentación del análisis y las recomendaciones de forma contextualizada y narrada, lo cual justifica la implementación de los módulos de PNL y RAG (Generación Aumentada por Recuperación) como la solución de mayor impacto estratégico. Finalmente, la confirmación del analista sobre la necesidad de una justificación detallada de las fuentes de datos y cálculos refuerza la robustez de la arquitectura ReAct, donde la respuesta del agente se basa en código y datos rastreables.

3.6 Viabilidad Económica y Tecnológica

El proyecto presenta una alta viabilidad económica, sustentada en el uso de software de código abierto que no requiere licencias comerciales, así como en el aprovechamiento de la infraestructura ya existente, incluyendo medidores inteligentes y la red institucional. Además, se proyecta un retorno de la inversión en menos de cinco años y una reducción sostenida de los costos operativos a largo plazo.

En cuanto a la viabilidad tecnológica, la solución cuenta con una arquitectura modular y escalable que permite la integración futura de funcionalidades avanzadas, como la predicción de demanda y el control automatizado. El despliegue en contenedores Docker facilita su replicabilidad en otros campus o entornos similares, mientras que la independencia de servicios en la nube asegura su implementación en instituciones con políticas estrictas de privacidad y manejo de datos.

3.7 Discusión y Oportunidades de Mejora

Entre los principales factores que facilitaron el éxito del proyecto se encuentra la existencia de datos históricos bien estructurados provenientes de la plataforma PREC, así como la disponibilidad de una infraestructura de medición inteligente previamente instalada. A esto se suma la colaboración directa con el equipo de Sostenibilidad, lo que permitió definir casos de uso reales y alineados con las necesidades operativas de la institución.

Sin embargo, durante el desarrollo se identificaron ciertos retos. La heterogeneidad y el ruido presentes en los datos históricos exigieron un proceso exhaustivo de limpieza y normalización. Asimismo, se presentaron limitaciones de hardware para la inferencia del modelo LLM en consultas particularmente complejas, y fue necesaria una fase de capacitación inicial para los usuarios no familiarizados con el funcionamiento de agentes conversacionales.

De cara al futuro, se identifican oportunidades de mejora, como la incorporación de un módulo de predicción de consumo con horizonte de 24 a 48 horas para anticipar

sobrecargas, la extensión del agente a otros dominios de sostenibilidad como agua y climatización, y la implementación de mecanismos de aprendizaje continuo a partir del feedback de los usuarios, con el fin de perfeccionar tanto las respuestas como las recomendaciones generadas por el sistema.

CAPÍTULO 4

4. CONCLUSIONES Y RECOMENDACIONES

4.1 Conclusiones

El proyecto permitió el diseño y desarrollo de un agente inteligente conversacional basado en procesamiento de lenguaje natural, orientado a la mejora de la toma de decisiones estratégicas en la Dirección de Sostenibilidad Institucional de ESPOL.

Uno de los aportes más relevantes radica en la reducción significativa de los tiempos de consulta y análisis de información, que pasaron de procesos manuales de varios minutos a respuestas automatizadas en pocos segundos. Este avance marca un cambio en la cultura institucional, al favorecer la toma de decisiones basadas en evidencia a partir de datos confiables y recomendaciones contextualizadas. El proyecto también aporta al campo académico, al demostrar la aplicabilidad de enfoques de generación aumentada por recuperación en escenarios reales de consumo energético en campus universitarios.

En el ámbito de la interacción conversacional, la integración de GPT 5 con un enfoque de generación aumentada por recuperación permitió responder consultas de manera precisa y contextualizada, acompañadas de visualizaciones automáticas que facilitan la comprensión de los resultados. Esta característica amplía el acceso a la información al personal no especializado, democratizando el análisis energético y fortaleciendo la adopción del sistema en la institución. De esta manera, la solución propuesta supera enfoques tradicionales que se limitan al monitoreo manual o a modelos predictivos aislados, al ofrecer una herramienta integral que combina análisis, interpretación y comunicación en lenguaje natural.

Entre las principales fortalezas del prototipo se destacan la utilización de la infraestructura existente, como la Plataforma de Eficiencia Energética del Campus (PREC) y los medidores inteligentes, lo que favoreció la integración sin requerir grandes inversiones adicionales. La arquitectura modular y escalable desplegada en contenedores demuestra potencial de replicabilidad en otros contextos similares, garantizando sostenibilidad tecnológica. La viabilidad económica también resulta

evidente, pues el uso de software de código abierto y la reducción de la carga laboral proyectan un retorno de inversión en menos de cuatro años, consolidando la pertinencia de la solución en términos financieros y operativos.

Sin embargo, el desarrollo también evidenció limitaciones importantes. Algunas consultas complejas requieren mayores recursos computacionales, lo que señala la necesidad de optimizar el hardware o migrar a esquemas híbridos que combinen infraestructura local con servicios en la nube. La heterogeneidad de los datos históricos representó un reto significativo, obligando a implementar procesos exhaustivos de normalización y limpieza. A nivel de usuarios, la adopción inicial requirió un proceso de capacitación que evidencia la importancia de acompañar la innovación tecnológica con estrategias de formación continua.

En conjunto, los resultados obtenidos muestran que la integración de un agente inteligente conversacional en la gestión energética no solo es técnicamente viable, sino también beneficiosa en términos de eficiencia, accesibilidad y sostenibilidad. El proyecto aporta un modelo innovador que puede servir de referencia para otras instituciones, alineándose con las tendencias globales hacia campus inteligentes y decisiones basadas en evidencia.

4.2 Recomendaciones

Los hallazgos alcanzados permiten establecer recomendaciones que orienten la consolidación del prototipo y su evolución hacia etapas futuras. Desde un punto de vista técnico, se recomienda fortalecer la infraestructura computacional mediante soluciones híbridas que combinen servidores locales con servicios en la nube, de modo que se reduzcan los tiempos de respuesta en consultas de mayor complejidad. Igualmente, resulta pertinente ampliar las funcionalidades del agente incorporando módulos de predicción de consumo energético con horizontes de 24 a 48 horas, lo cual permitiría anticiparse a posibles sobrecargas y planificar la operación con un enfoque más preventivo. Otra línea de mejora consiste en habilitar mecanismos de aprendizaje continuo que integren la retroalimentación de los usuarios, logrando que el sistema evolucione y ajuste sus recomendaciones de manera dinámica.

También se sugiere explorar la incorporación de datos multimodales provenientes de sensores ambientales, sistemas de climatización y consumo de agua, de forma que el agente amplíe su cobertura hacia una sostenibilidad integral. Esta evolución permitiría no solo optimizar la gestión energética, sino también avanzar en la gestión del recurso hídrico y en la planificación de estrategias ambientales más amplias.

Adicionalmente, resulta imperativo priorizar la optimización de la latencia de respuesta, la cual actualmente promedia los 71.16 segundos bajo aceleración por GPU. Para lograr una experiencia de usuario en tiempo real, se recomienda implementar técnicas de cuantización de modelos y el uso de motores de inferencia optimizados (como vLLM o TensorRT-LLM), que permitan reducir el tiempo de procesamiento de tokens. Asimismo, la migración hacia arquitecturas de modelos de lenguaje más ligeros o especializados en tareas técnicas específicas podría disminuir significativamente el overhead computacional sin comprometer la precisión en la generación de consultas Flux.

A nivel institucional, es recomendable establecer programas de capacitación continua que acompañen la adopción del sistema, asegurando que tanto personal técnico como administrativo puedan aprovechar al máximo las funcionalidades desarrolladas. La implementación de políticas de datos abiertos internos contribuiría a fomentar la transparencia y a fortalecer la investigación aplicada, al tiempo que permitiría a la comunidad académica aprovechar la información energética como base para nuevos proyectos. Asimismo, la definición de indicadores de desempeño alineados con los Objetivos de Desarrollo Sostenible garantizará un monitoreo permanente del impacto alcanzado por la solución en términos de eficiencia, ahorro y sostenibilidad.

De cara al futuro, resulta conveniente impulsar colaboraciones internacionales que permitan validar el modelo en contextos diversos y enriquecer su diseño a partir de la experiencia de instituciones afines. Una línea adicional de investigación se centra en la integración de agentes cognitivos más avanzados, capaces de combinar razonamiento simbólico con modelos generativos de última generación, incrementando así la interpretabilidad y autonomía en la toma de decisiones. Finalmente, se vislumbra la

posibilidad de escalar la solución a nivel nacional, adaptándola a instituciones públicas y privadas interesadas en fortalecer su gestión energética en concordancia con la norma ISO 50001 y los compromisos globales en sostenibilidad.

En síntesis, las conclusiones obtenidas y las recomendaciones formuladas permiten proyectar este trabajo como un referente tanto académico como institucional, confirmando que la aplicación de inteligencia artificial y procesamiento de lenguaje natural en la gestión energética representa una vía concreta para avanzar hacia la transformación digital sostenible en el ámbito universitario y más allá.

BIBLIOGRAFÍA

- Aksitov, R., Miryoosefi, S., Li, Z., Li, D., Babayan, S., Kopparapu, K., Fisher, Z., Guo, R., Prakash, S., Srinivasan, P., Zaheer, M., Yu, F., & Kumar, S. (2023). *ReST meets ReAct: Self-Improvement for Multi-Step Reasoning LLM Agent*. <https://arxiv.org/abs/2312.10003>
- Anisuzzaman, D. M., Malins, J. G., Friedman, P. A., & Attia, Z. I. (2025). Fine-Tuning Large Language Models for Specialized Use Cases. *Mayo Clinic Proceedings: Digital Health*, 3(1), 100184. <https://doi.org/https://doi.org/10.1016/j.mcpdig.2024.11.005>
- Arguello, D., & Villalta, M. (2024). *RAG aplicado a business intelligence para la gestión eficiente de insights dentro de una institución financiera ecuatoriana*. .
- Azamat, M., & Schütz, J. (2023). *An integrated approach for energy management optimizations in customer premises*. 3699–3703.
- Chen, X., Abualdenien, J., Singh, M. M., Borrmann, A., & Geyer, P. (2022). Introducing causal inference in the energy-efficient building design process. *Energy and Buildings*, 277, 112583. <https://doi.org/https://doi.org/10.1016/j.enbuild.2022.112583>
- Comi, A., Danchuk, V., Gruenwald, N., & Kunytska, O. (2023). How cities and universities approach the sustainable development goals. In *Handbook of Sustainability Science in the Future* (pp. 699–719).
- Domínguez-Bolaño, T., Barral, V., Escudero, C. J., & García-Naya, J. A. (2024). An IoT system for a smart campus: Challenges and solutions illustrated over several real-world use cases. *Internet of Things*, 25, 101099. <https://doi.org/10.1016/j.iot.2024.101099>
- Doshi-Velez, F., & Kim, B. (2017). *Towards A Rigorous Science of Interpretable Machine Learning*. <https://arxiv.org/abs/1702.08608>
- Douze, M., Guzhva, A., Deng, C., Johnson, J., Szilvasy, G., Mazaré, P.-E., Lomeli, M., Hosseini, L., & Jégou, H. (2025). *The Faiss library*. <https://arxiv.org/abs/2401.08281>
- Elkabalawy, M., Al-Sakkaf, A., Mohammed Abdelkader, E., & Alfalah, G. (2024). CRISP-DM-Based Data-Driven Approach for Building Energy Prediction Utilizing Indoor and Environmental Factors. *Sustainability*, 16(17). <https://doi.org/10.3390/su16177249>
- Escuela Superior Politécnica del Litoral. (2021, June 14). *Politécnicos crean plataforma de eficiencia energética para el campus de la ESPOL*.

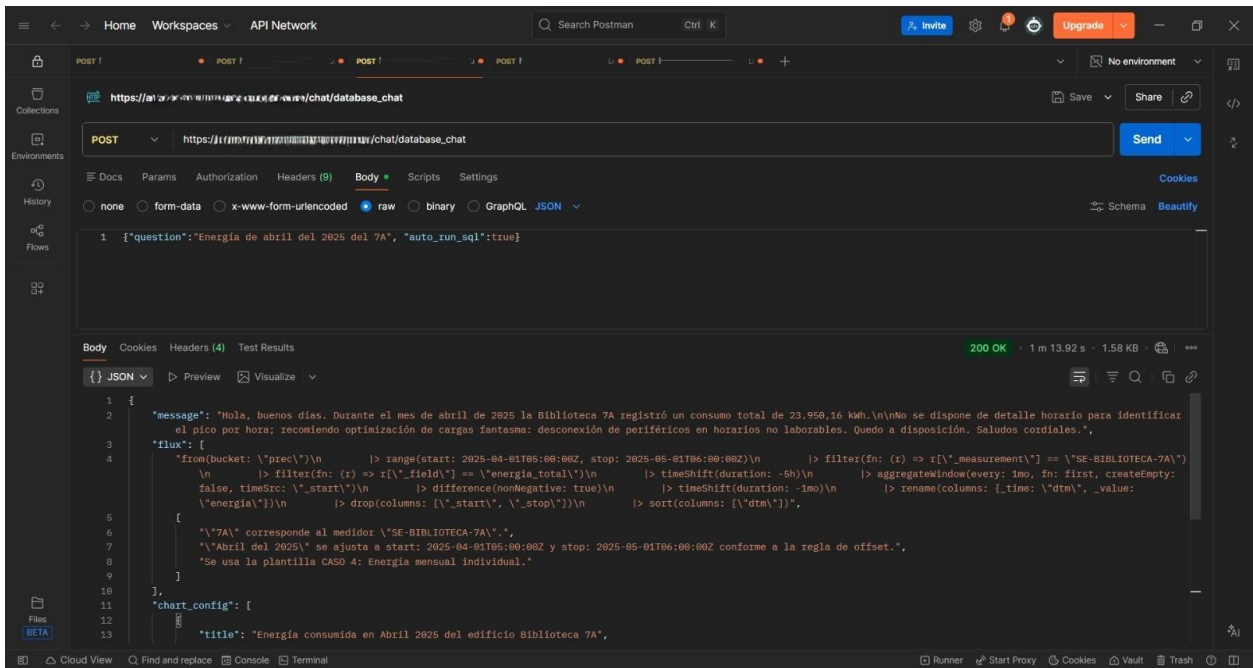
- Escuela Superior Politécnica del Litoral (ESPOL). (2021). *ODS y Sostenibilidad en ESPOL*. Dirección de Sostenibilidad.
- Gao, Y., Xiong, Y., Gao, X., Jia, K., Pan, J., Dai, Y., Sun, J., Wang, M., & Wang, H. (2024). *Retrieval-Augmented Generation for Large Language Models: A Survey*.
- García-Quilachamín, W., Atencia-Fuentes, K., Ante-Moreno, J., Herrera-Tapia, J., Ulloa-Herrera, F., & Coronel-Suárez, M. (2023). Design of an integrated system for the measurement and monitoring of electrical parameters under ISO 50001: A case study. In *Smart Technologies, Systems and Applications* (Vol. 1705, pp. 400–413). Springer.
- Grimaccia, F., Niccolai, A., Mussetta, M., & D'Alessandro, G. (2023). ISO 50001 Data Driven Methods for Energy Efficiency Analysis of Thermal Power Plants. *Applied Sciences*, 13(3). <https://doi.org/10.3390/app13031368>
- Handler, A., Larsen, K. R., & Hackathorn, R. (2024). Large language models present new questions for decision support. *International Journal of Information Management*, 79, 102811. <https://doi.org/https://doi.org/10.1016/j.ijinfomgt.2024.102811>
- Himeur, Y., Ghanem, K., Alsalemi, A., Bensaali, F., & Amira, A. (2021a). Artificial intelligence based anomaly detection of energy consumption in buildings: A review, current trends and new perspectives. *Applied Energy*, 287, 116601. <https://doi.org/10.1016/J.APENERGY.2021.116601>
- Himeur, Y., Ghanem, K., Alsalemi, A., Bensaali, F., & Amira, A. (2021b). Artificial intelligence based anomaly detection of energy consumption in buildings: A review, current trends and new perspectives. *Applied Energy*, 287, 116601. <https://doi.org/10.1016/j.apenergy.2021.116601>
- Introna, V., Santolamazza, A., & Cesarotti, V. (2024). Integrating Industry 4.0 and 5.0 Innovations for Enhanced Energy Management Systems. *Energies*, 17(5). <https://doi.org/10.3390/en17051222>
- Jin, M., Zhang, Y., Chen, W., Zhang, K., Liang, Y., Yang, B., Wang, J., Pan, S., & Wen, Q. (2024). *Position: What Can Large Language Models Tell Us about Time Series Analysis*. <https://arxiv.org/abs/2402.02713>
- Kuang, S., Huang, Y., & Song, J. (2025). Unsupervised data imputation with multiple importance sampling variational autoencoders. *Scientific Reports*, 15(1), 3409. <https://doi.org/10.1038/s41598-025-87641-0>

- Lei, L., Wu, B., Fang, X., Chen, L., Wu, H., & Liu, W. (2023). A dynamic anomaly detection method of building energy consumption based on data mining technology. *Energy*, 263, 125575. <https://doi.org/10.1016/J.ENERGY.2022.125575>
- Lewis, P., Perez, E., Piktus, A., Petroni, F., Karpukhin, V., Goyal, N., Küttler, H., Lewis, M., Yih, W., Rocktäschel, T., Riedel, S., & Kiela, D. (2020). Retrieval-Augmented Generation for Knowledge-Intensive NLP Tasks. In H. Larochelle, M. Ranzato, R. Hadsell, M. F. Balcan, & H. Lin (Eds.), *Advances in Neural Information Processing Systems* (Vol. 33, pp. 9459–9474). Curran Associates, Inc. https://proceedings.neurips.cc/paper_files/paper/2020/file/6b493230205f780e1bc26945df7481e5-Paper.pdf
- Lewis, P., Perez, E., Piktus, A., Petroni, F., Karpukhin, V., Goyal, N., Küttler, H., Lewis, M., Yih, W., Rocktäschel, T., Riedel, S., & Kiela, D. (2021). *Retrieval-Augmented Generation for Knowledge-Intensive NLP Tasks*. <https://arxiv.org/abs/2005.11401>
- Ley Orgánica de Protección de Datos Personales Del Ecuador, Pub. L. No. Registro Oficial Suplemento 459, Registro Oficial (2021).
- Mechkaroska Daniela and Domazet, E. and F. A. and S. U. R. (2024). Architectural Scalability of Conversational Chatbot: The Case of ChatGPT. In K. Arai (Ed.), *Advances in Information and Communication* (pp. 54–71). Springer Nature Switzerland.
- Munson, J., Cuezze, T., Nesar, S., & Zosso, D. (2025). A review of large language models and the recommendation task. *Discover Artificial Intelligence*, 5(1), 203. <https://doi.org/10.1007/s44163-025-00334-5>
- Nielsen, J. (2020). *Usability heuristics for user interface design*. Nielsen Norman Group.
- Ojha, S. K., Kumar, A., Bhole, T., & Naaz, S. (2024). Rule-based A.I. chatbot. *International Journal of Innovative Research in Technology*, 11(5), 639–646.
- Oliveira, M., & Proença, J. (2025). Sustainable campus operations in higher education institutions: A systematic literature review. *Sustainability*, 17(2), 607.
- Quispe, E., Viveros, M., Chamorro, M., Castrillon, R., & Vidal, J. (2025). Energy management systems in higher education institutions' buildings. *Energies*, 18(7), Article 1810.
- Ribeiro, M. T., Singh, S., & Guestrin, C. (2016). “Why Should I Trust You?”: Explaining the Predictions of Any Classifier. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 1135–1144. <https://doi.org/10.1145/2939672.2939778>

- Rossi, G., Cadei, L., Bitetti, M., Gerardi, R., Vaccari, D., Ghetti, M., Forte, M., Collura, L., & Ricci, A. (2022, October 31). *Energy and GHG management of a giant oilfield: A new digital way to face challenge and certify the results.*
- Seraj, H., Bahadori-Jahromi, A., & Amirkhani, S. (2024). Developing a Data-Driven AI Model to Enhance Energy Efficiency in UK Residential Buildings. *Sustainability*, 16(8). <https://doi.org/10.3390/su16083151>
- Shah, B., Jat, P. M., & Sashidhar, K. (2022). *Performance Study of Time Series Databases.* <https://arxiv.org/abs/2208.13982>
- Song, T., Fan, Y., Feng, C., Song, K., Liu, C., & Jiang, D. (2024). *Domain-specific ReAct for physics-integrated iterative modeling: A case study of LLM agents for gas path analysis of gas turbines.* <https://arxiv.org/abs/2406.07572>
- Song, Y., Sennan, K., Huang, J., & Zhang, D. (2024). Unsupervised anomaly detection of industrial building energy consumption. *Energy and Built Environment.* <https://doi.org/10.1016/j.enbenv.2024.12.005>
- Tavares, D., Azevedo, P., Semedo, D., Sousa, R., & Magalhães, J. (2023). *Task Conditioned BERT for Joint Intent Detection and Slot-filling.* <https://arxiv.org/abs/2308.06165>
- Yao, S., Zhao, J., Yu, D., Du, N., Shafran, I., Narasimhan, K., & Cao, Y. (2023). *ReAct: Synergizing Reasoning and Acting in Language Models.* <https://arxiv.org/abs/2210.03629>
- Zhou, S. L., Shah, A. A., Leung, P. K., Zhu, X., & Liao, Q. (2023). A comprehensive review of the applications of machine learning for HVAC. *DeCarbon*, 2, 100023. <https://doi.org/https://doi.org/10.1016/j.decarb.2023.100023>

APÉNDICES

APÉNDICE A. Validación de tiempo de respuestas a consultas simultáneas.



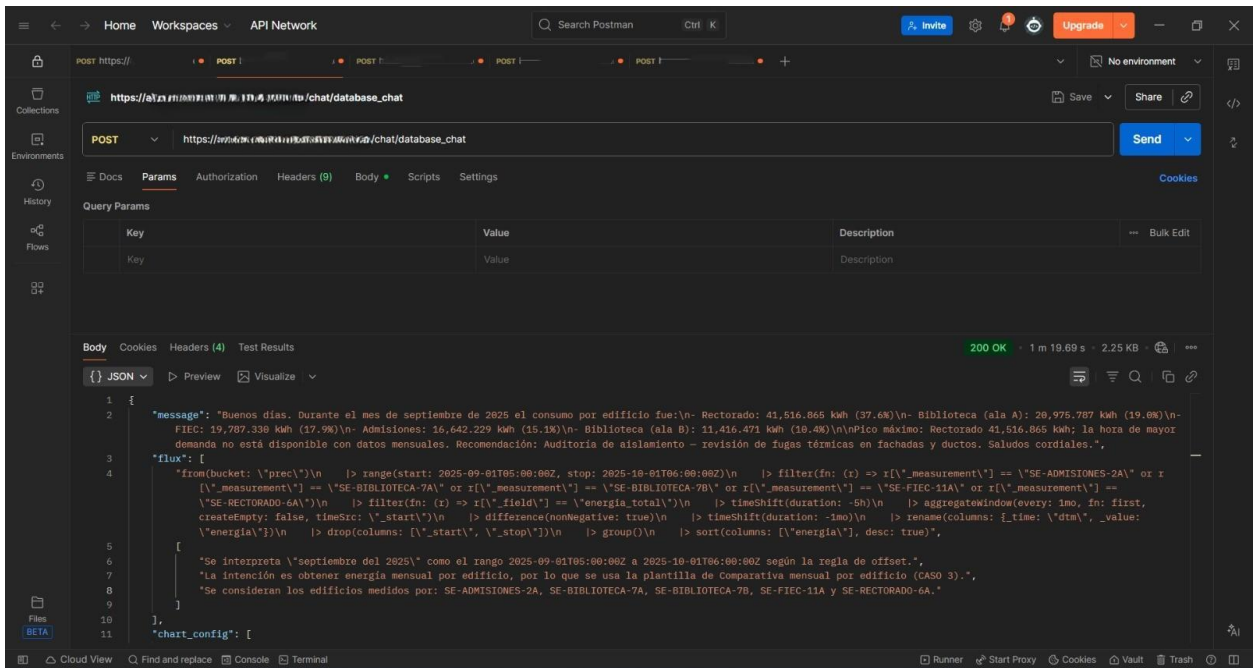
The screenshot shows a Postman interface with a POST request to `https://api.virtuoso.com/chat/database_chat`. The request body is a JSON object:

```
1 { "question": "Energía de abril del 2025 del 7A", "auto_run_sql": true }
```

The response is a 200 OK status with a message and a flux object:

```
1 {
2   "message": "Hola, buenos días. Durante el mes de abril de 2025 la Biblioteca 7A registró un consumo total de 23.950,16 kWh. No se dispone de detalle horario para identificar el pico por hora; recomiendo optimización de cargas fantasma; desconexión de periféricos en horarios no laborables. Quedo a disposición. Saludos cordiales.",
3   "flux": [
4     {
5       "from(bucket: \"prec\")\n        |> range(start: 2025-04-01T05:00:00Z, stop: 2025-05-01T06:00:00Z)\n        |> filter(fn: (r) => r[\"_measurement\"] == \"SE-BIBLIOTECA-7A\")\n        |> filter(fn: (r) => r[\"_field\"] == \"energia_total\")\n        |> timeShift(duration: -5h)\n        |> aggregateWindow(every: 1mo, fn: first, createEmpty: false, timeSrc: \"_start\")\n        |> difference(nonNegative: true)\n        |> timeShift(duration: -1mo)\n        |> rename(columns: { _time: \"dtm\", _value: \"energia\"})\n        |> drop(columns: [\"_start\", \"_stop\"])\n        |> sort(columns: [\"dtm\"])",
6       "SE-7A" corresponde al medidor "SE-BIBLIOTECA-7A".
7       "Abril del 2025" se ajusta a start: 2025-04-01T05:00:00Z y stop: 2025-05-01T06:00:00Z conforme a la regla de offset.
8       "Se usa la plantilla CASO 4: Energía mensual individual."
9     }
10  ],
11  "chart_config": [
12    {
13      "title": "Energía consumida en Abril 2025 del edificio Biblioteca 7A",
14    }
15  ]
16 }
```

Figura A.1 Consulta 1.



The screenshot shows a Postman interface with a POST request to `https://api.virtuoso.com/chat/database_chat`. The request body is a JSON object:

```
1 { "question": "Energía de julio del 2025 de los edificios 2A, 7A, 7B, 11A y 3A", "auto_run_sql": true }
```

The response is a 200 OK status with a message and a flux object:

```
1 {
2   "message": "Buenos días. Durante el mes de julio de 2025 el consumo por edificio fue:\n- Rectorado: 41,516,865 kWh (37.6%)\n- Biblioteca (ala A): 20,975,787 kWh (19.0%)\n- FIEC: 19,787,338 kWh (17.9%)\n- Admisiones: 16,642,229 kWh (15.1%)\n- Biblioteca (ala B): 11,416,471 kWh (10.4%)\n\nPico máximo: Rectorado 41,516,865 kWh; la hora de mayor demanda no está disponible con datos mensuales. Recomendación: Auditoría de aislamiento - revisión de fugas térmicas en fachadas y ductos. Saludos cordiales.",
3   "flux": [
4     {
5       "from(bucket: \"prec\")\n        |> range(start: 2025-07-01T05:00:00Z, stop: 2025-08-01T06:00:00Z)\n        |> filter(fn: (r) => r[\"_measurement\"] == \"SE-ADMISIONES-2A\" or r[\"_measurement\"] == \"SE-BIBLIOTECA-7A\" or r[\"_measurement\"] == \"SE-BIBLIOTECA-7B\" or r[\"_measurement\"] == \"SE-FIEC-11A\" or r[\"_measurement\"] == \"SE-RECTORADO-3A\")\n        |> filter(fn: (r) => r[\"_field\"] == \"energia_total\")\n        |> timeShift(duration: -5h)\n        |> aggregateWindow(every: 1mo, fn: first, createEmpty: false, timeSrc: \"_start\")\n        |> difference(nonNegative: true)\n        |> timeShift(duration: -1mo)\n        |> rename(columns: { _time: \"dtm\", _value: \"energia\"})\n        |> drop(columns: [\"_start\", \"_stop\"])\n        |> group()\n        |> sort(columns: [\"energia\", \"desc\": true])",
6       "Se interpreta \"septiembre del 2025\" como el rango 2025-09-01T05:00:00Z a 2025-10-01T06:00:00Z según la regla de offset.",
7       "La intención es obtener energía mensual por edificio, por lo que se usa la plantilla de Comparativa mensual por edificio (CASO 3).",
8       "Se consideran los edificios medidos por: SE-ADMISIONES-2A, SE-BIBLIOTECA-7A, SE-BIBLIOTECA-7B, SE-FIEC-11A y SE-RECTORADO-3A."
9     }
10  ],
11  "chart_config": [
12    {
13      "title": "Energía consumida en Julio 2025 de los edificios 2A, 7A, 7B, 11A y 3A",
14    }
15  ]
16 }
```

Figura A.2 Consulta 2.

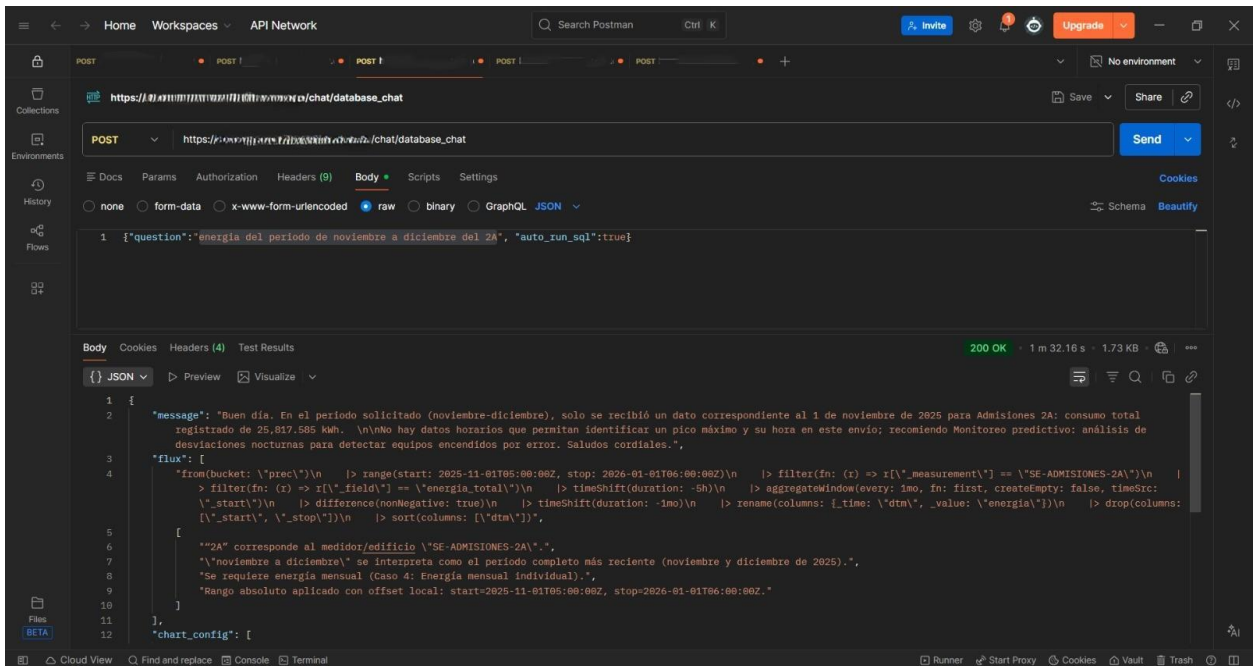


Figura A.3 Consulta 3.

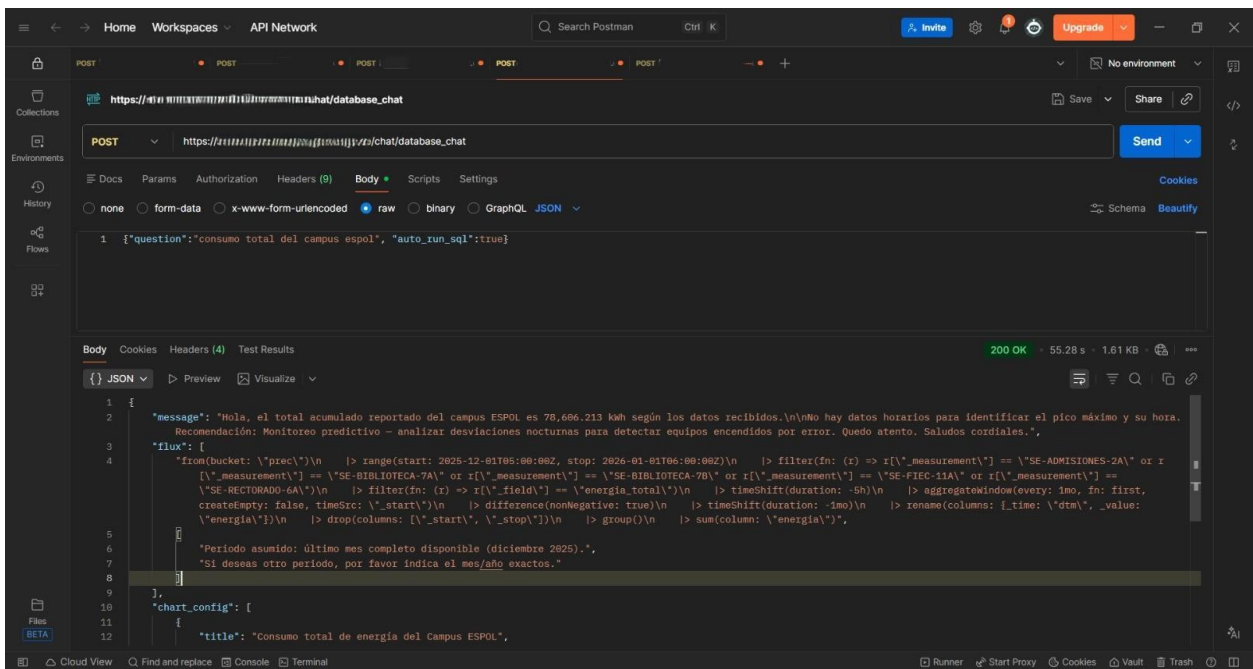


Figura A.4 Consulta 4.

APÉNDICE B. INTERACCIONES CON EL AGENTE

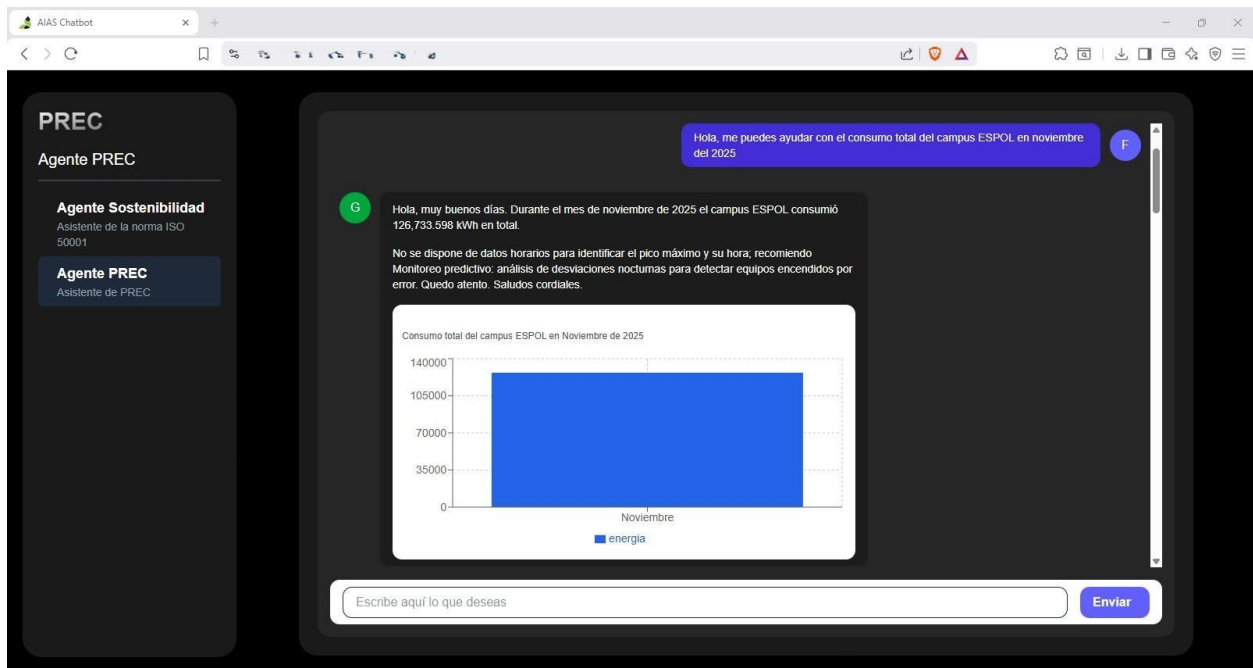


Figura B. 1 Interacción con el agente.

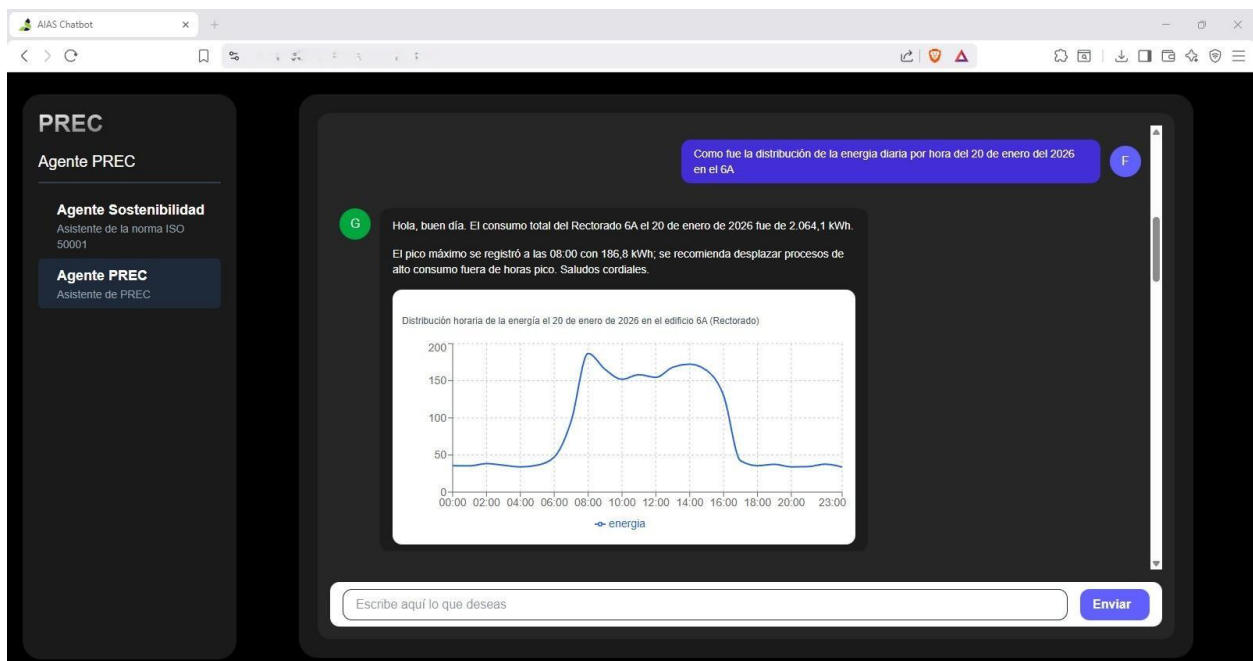


Figura B. 2 Interacción con el agente.

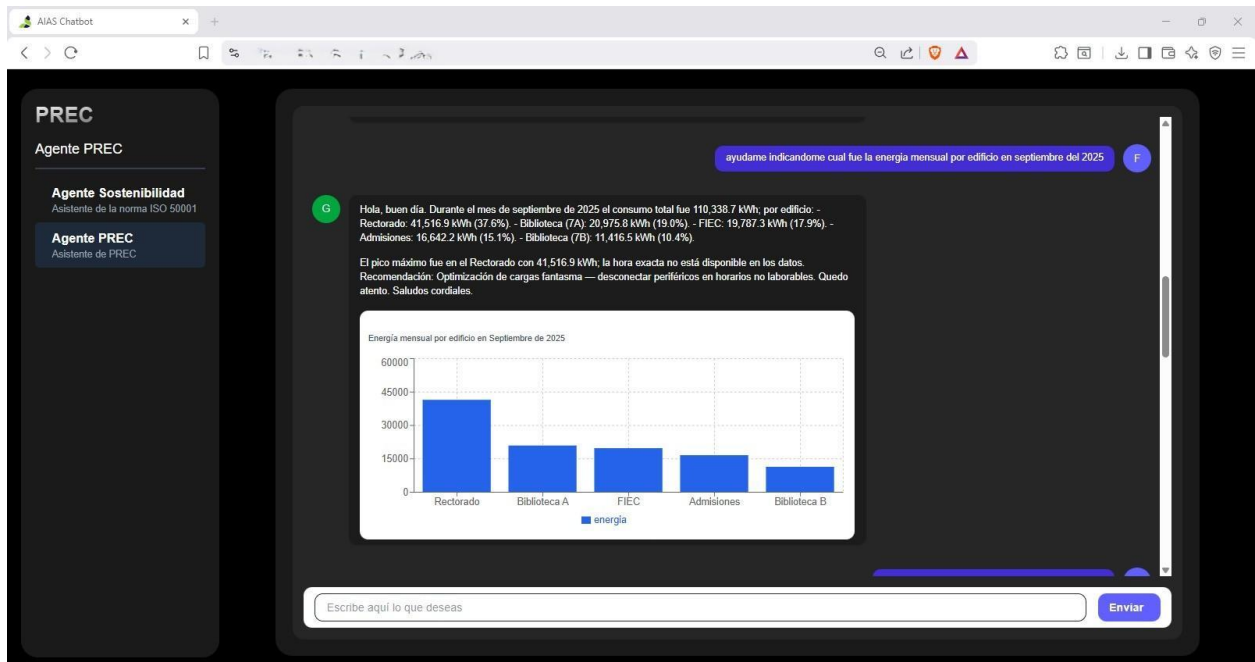


Figura B. 3 Interacción con el agente.

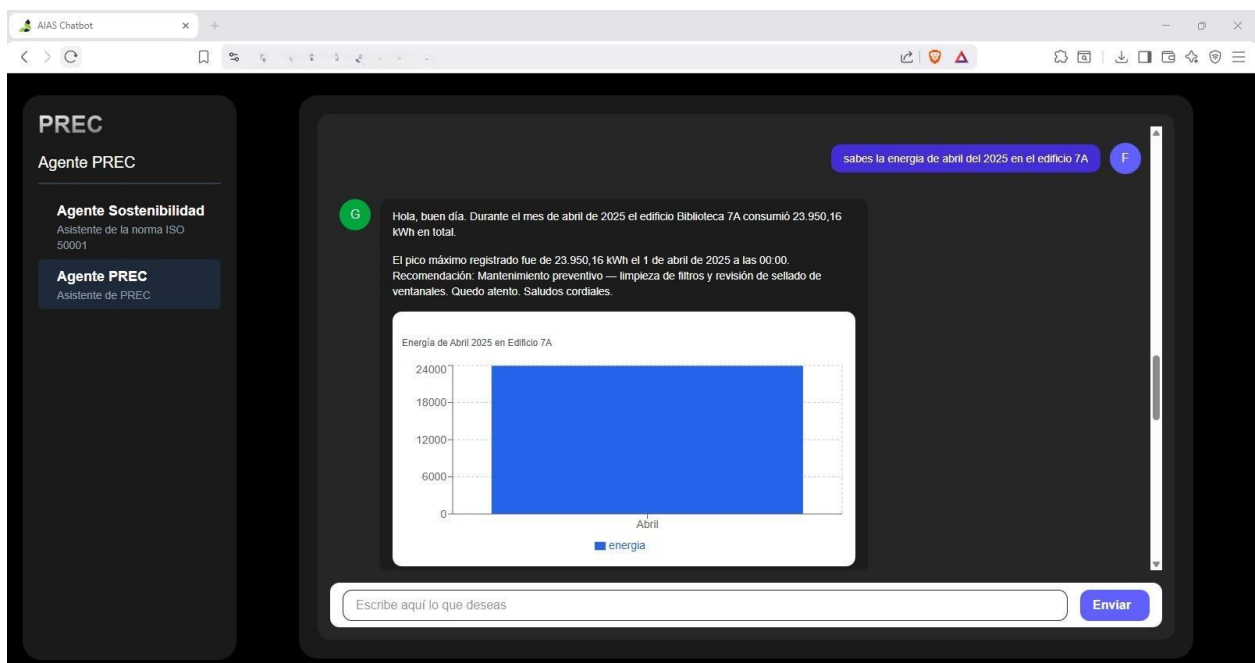


Figura B. 4 Interacción con el agente.

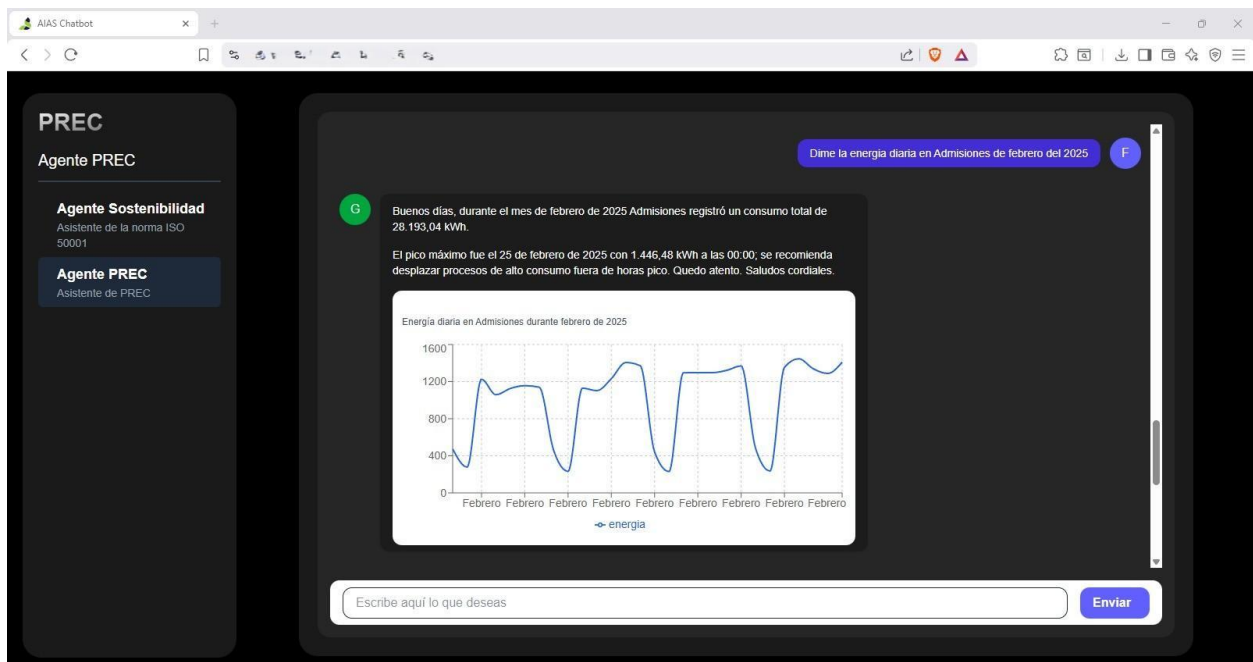


Figura B. 5 Interacción con el agente.

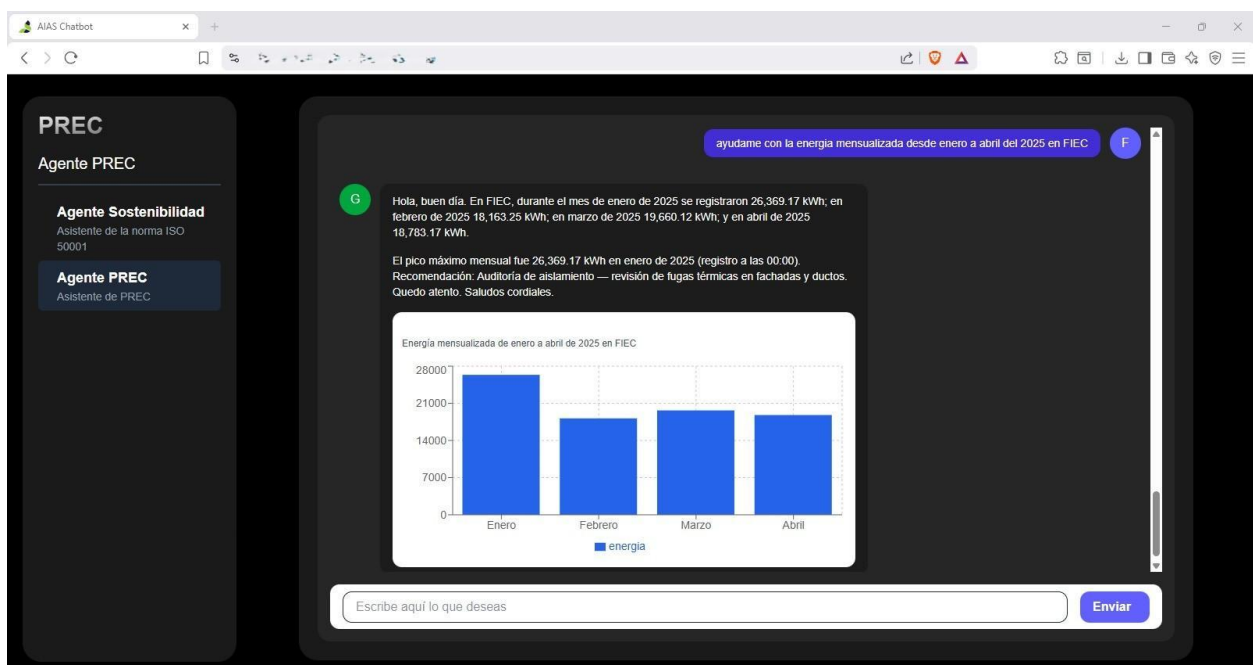


Figura B. 6 Interacción con el agente.

APÉNDICE C. JSON RESPONSE

```
{
  "message": "Hola, buenos días. Durante el mes de abril de 2025 la Biblioteca 7A
registró un consumo total de 23.950,16 kWh.\n\nNo se dispone de detalle horario para
identificar el pico por hora; recomiendo optimización de cargas fantasma: desconexión
de periféricos en horarios no laborables. Quedo a disposición. Saludos cordiales.",
  "flux": [
    "from(bucket: \"prec\")\n    |> range(start: 2025-04-01T05:00:00Z, stop: 2025-05-
01T06:00:00Z)\n    |> filter(fn: (r) => r[\"_measurement\"] == \"SE-BIBLIOTECA-7A\")\n
|> filter(fn: (r) => r[\"_field\"] == \"energia_total\")\n    |> timeShift(duration: -5h)\n    |>
aggregateWindow(every: 1mo, fn: first, createEmpty: false, timeSrc: \"_start\")\n    |>
difference(nonNegative: true)\n    |> timeShift(duration: -1mo)\n    |> rename(columns:
{ _time: \"dtm\", _value: \"energia\"})\n    |> drop(columns: [\"_start\", \"_stop\"])\n    |>
sort(columns: [\"dtm\"])",
    [
      "\"7A\" corresponde al medidor \"SE-BIBLIOTECA-7A\".",
      "\"Abril del 2025\" se ajusta a start: 2025-04-01T05:00:00Z y stop: 2025-05-
01T06:00:00Z conforme a la regla de offset.",
      "Se usa la plantilla CASO 4: Energía mensual individual."
    ]
  ],
  "chart_config": [
    {
      "title": "Energía consumida en Abril 2025 del edificio Biblioteca 7A",
      "chartType": "bar",
      "description": "Energía consumida en Abril 2025 del edificio Biblioteca 7A",
      "data": [
        {
          "dtm": "Abril",
          "energia": 23950.16
        }
      ]
    }
  ],
}
```

```

    "dataKeys": [
      "energia"
    ],
    "xAxisKey": "dtm",
    "xAxisLabelAngle": 0,
    "alertas": []
  }
]
}

```

```

{
  "message": "Buenos días. Durante el mes de septiembre de 2025 el consumo por edificio fue:\n- Rectorado: 41,516.865 kWh (37.6%)\n- Biblioteca (ala A): 20,975.787 kWh (19.0%)\n- FIEC: 19,787.330 kWh (17.9%)\n- Admisiones: 16,642.229 kWh (15.1%)\n- Biblioteca (ala B): 11,416.471 kWh (10.4%)\n\nPico máximo: Rectorado 41,516.865 kWh; la hora de mayor demanda no está disponible con datos mensuales. Recomendación: Auditoría de aislamiento — revisión de fugas térmicas en fachadas y ductos. Saludos cordiales.",

```

```

  "flux": [
    "from(bucket: \"prec\")\n  |> range(start: 2025-09-01T05:00:00Z, stop: 2025-10-01T06:00:00Z)\n  |> filter(fn: (r) => r[\"_measurement\"] == \"SE-ADMISIONES-2A\" or r[\"_measurement\"] == \"SE-BIBLIOTECA-7A\" or r[\"_measurement\"] == \"SE-BIBLIOTECA-7B\" or r[\"_measurement\"] == \"SE-FIEC-11A\" or r[\"_measurement\"] == \"SE-RECTORADO-6A\")\n  |> filter(fn: (r) => r[\"_field\"] == \"energia_total\")\n  |> timeShift(duration: -5h)\n  |> aggregateWindow(every: 1mo, fn: first, createEmpty: false, timeSrc: \"_start\")\n  |> difference(nonNegative: true)\n  |> timeShift(duration: -1mo)\n  |> rename(columns: { _time: \"dtm\", _value: \"energia\"})\n  |> drop(columns: [\"_start\", \"_stop\"])\n  |> group()\n  |> sort(columns: [\"energia\"], desc: true)",
    [

```

```

      "Se interpreta \"septiembre del 2025\" como el rango 2025-09-01T05:00:00Z a 2025-10-01T06:00:00Z según la regla de offset.",

```

"La intención es obtener energía mensual por edificio, por lo que se usa la plantilla de Comparativa mensual por edificio (CASO 3).",

"Se consideran los edificios medidos por: SE-ADMISIONES-2A, SE-BIBLIOTECA-7A, SE-BIBLIOTECA-7B, SE-FIEC-11A y SE-RECTORADO-6A."

```
]
],
"chart_config": [
  {
    "title": "Energía mensual por edificio en septiembre de 2025",
    "chartType": "bar",
    "description": "Energía mensual por edificio en septiembre de 2025",
    "data": [
      {
        "edificio": "Rectorado",
        "energia": 41516.86
      },
      {
        "edificio": "Biblioteca 7A",
        "energia": 20975.79
      },
      {
        "edificio": "FIEC",
        "energia": 19787.33
      },
      {
        "edificio": "Admisiones",
        "energia": 16642.23
      },
      {
        "edificio": "Biblioteca 7B",
        "energia": 11416.47
      }
    ]
  }
]
```

```

    ],
    "dataKeys": [
      "energia"
    ],
    "xAxisKey": "edificio",
    "xAxisLabelAngle": -45,
    "alertas": []
  }
]
}

```

```

{
  "message": "Buen día. En el periodo solicitado (noviembre-diciembre), solo se recibió un dato correspondiente al 1 de noviembre de 2025 para Admisiones 2A: consumo total registrado de 25,817.585 kWh. \n\nNo hay datos horarios que permitan identificar un pico máximo y su hora en este envío; recomiendo Monitoreo predictivo: análisis de desviaciones nocturnas para detectar equipos encendidos por error. Saludos cordiales.",

```

```

  "flux": [
    "from(bucket: \"prec\")\n  |> range(start: 2025-11-01T05:00:00Z, stop: 2026-01-01T06:00:00Z)\n  |> filter(fn: (r) => r[\"_measurement\"] == \"SE-ADMISIONES-2A\")\n  |> filter(fn: (r) => r[\"_field\"] == \"energia_total\")\n  |> timeShift(duration: -5h)\n  |> aggregateWindow(every: 1mo, fn: first, createEmpty: false, timeSrc: \"_start\")\n  |> difference(nonNegative: true)\n  |> timeShift(duration: -1mo)\n  |> rename(columns: {_time: \"dtm\", _value: \"energia\"})\n  |> drop(columns: [\"_start\", \"_stop\"])\n  |> sort(columns: [\"dtm\"])",

```

```

    [
      "\"2A\" corresponde al medidor/edificio \"SE-ADMISIONES-2A\".",
      "\"noviembre a diciembre\" se interpreta como el periodo completo más reciente (noviembre y diciembre de 2025).",

```

```

      "Se requiere energía mensual (Caso 4: Energía mensual individual).",

```

```
    "Rango absoluto aplicado con offset local: start=2025-11-01T05:00:00Z,
stop=2026-01-01T06:00:00Z."
```

```
  ]
],
"chart_config": [
  {
    "title": "Energía de noviembre a diciembre para Admisiones 2A",
    "chartType": "bar",
    "description": "Energía de noviembre a diciembre para Admisiones 2A",
    "data": [
      {
        "dtm": "Noviembre",
        "energia": 25817.58
      }
    ],
    "dataKeys": [
      "energia"
    ],
    "xAxisKey": "dtm",
    "xAxisLabelAngle": 0,
    "alertas": []
  }
]
}
```

```
{
  "message": "Hola, el total acumulado reportado del campus ESPOL es 78,606.213
kWh según los datos recibidos.\n\nNo hay datos horarios para identificar el pico máximo
y su hora. Recomendación: Monitoreo predictivo — analizar desviaciones nocturnas para
detectar equipos encendidos por error. Quedo atento. Saludos cordiales.",
  "flux": [
```

```
"from(bucket: \"prec\")\n  |> range(start: 2025-12-01T05:00:00Z, stop: 2026-01-01T06:00:00Z)\n  |> filter(fn: (r) => r[\"_measurement\"] == \"SE-ADMISIONES-2A\" or r[\"_measurement\"] == \"SE-BIBLIOTECA-7A\" or r[\"_measurement\"] == \"SE-BIBLIOTECA-7B\" or r[\"_measurement\"] == \"SE-FIEC-11A\" or r[\"_measurement\"] == \"SE-RECTORADO-6A\")\n  |> filter(fn: (r) => r[\"_field\"] == \"energia_total\")\n  |> timeShift(duration: -5h)\n  |> aggregateWindow(every: 1mo, fn: first, createEmpty: false, timeSrc: \"_start\")\n  |> difference(nonNegative: true)\n  |> timeShift(duration: -1mo)\n  |> rename(columns: { _time: \"dtm\", _value: \"energia\"})\n  |> drop(columns: [\"_start\", \"_stop\"])\n  |> group()\n  |> sum(column: \"energia\"),
```

```
[
```

```
  \"Periodo asumido: último mes completo disponible (diciembre 2025).\",
```

```
  \"Si deseas otro periodo, por favor indica el mes/año exactos.\"
```

```
]
```

```
],
```

```
\"chart_config\": [
```

```
{
```

```
  \"title\": \"Consumo total de energía del Campus ESPOL\",
```

```
  \"chartType\": \"bar\",
```

```
  \"description\": \"Consumo total de energía del Campus ESPOL\",
```

```
  \"data\": [
```

```
    {
```

```
      \"edificio\": \"Campus ESPOL\",
```

```
      \"energia\": 78606.21
```

```
    }
```

```
  ],
```

```
  \"dataKeys\": [
```

```
    \"energia\"
```

```
  ],
```

```
  \"xAxisKey\": \"edificio\",
```

```
  \"xAxisLabelAngle\": 0,
```

```
  \"alertas\": []
```

```
}
```

```

]
}

{
  "message": "Buenos días, el campus ESPOL consumió un total de 78.606,21 kWh durante el mes de diciembre de 2025.\n\nPico horario: no disponible en este resumen; recomiendo Monitoreo predictivo: análisis de desviaciones nocturnas para detectar equipos encendidos por error. Quedo atento. Saludos cordiales.",
  "flux": [
    "from(bucket: \"prec\")\n  |> range(start: 2025-12-01T05:00:00Z, stop: 2026-01-01T06:00:00Z)\n  |> filter(fn: (r) => r[\"_measurement\"] == \"SE-ADMISIONES-2A\" or r[\"_measurement\"] == \"SE-BIBLIOTECA-7A\" or r[\"_measurement\"] == \"SE-BIBLIOTECA-7B\" or r[\"_measurement\"] == \"SE-FIEC-11A\" or r[\"_measurement\"] == \"SE-RECTORADO-6A\")\n  |> filter(fn: (r) => r[\"_field\"] == \"energia_total\")\n  |> timeShift(duration: -5h)\n  |> aggregateWindow(every: 1mo, fn: first, createEmpty: false, timeSrc: \"_start\")\n  |> difference(nonNegative: true)\n  |> timeShift(duration: -1mo)\n  |> rename(columns: { _time: \"dtm\", _value: \"energia\"})\n  |> drop(columns: [\"_start\", \"_stop\"])\n  |> group()\n  |> sum(column: \"energia\"),
    [
      "\"Mes pasado\" se interpretó respecto a la fecha actual (2026-01-21) como diciembre de 2025.",
      "Se aplicó la regla de offset: start=2025-12-01T05:00:00Z y stop=2026-01-01T06:00:00Z.",
      "Se utilizaron los medidores definidos para consumo total del campus: SE-ADMISIONES-2A, SE-BIBLIOTECA-7A, SE-BIBLIOTECA-7B, SE-FIEC-11A, SE-RECTORADO-6A."
    ]
  ],
  "chart_config": [
    {
      "title": "Consumo total del Campus ESPOL en Diciembre",
      "chartType": "bar",

```

```
"description": "Consumo total del Campus ESPOL en Diciembre",
"data": [
  {
    "dtm": "Diciembre",
    "energia": 78606.21
  }
],
"dataKeys": [
  "energia"
],
"xAxisKey": "dtm",
"xAxisLabelAngle": 0,
>alertas": []
}
]
}
```

APÉNDICE D. Formato de encuesta realizada a personal del área de Sostenibilidad

Impacto Agente Inteligente Conversacional

El objetivo de esta encuesta es cuantificar la carga laboral manual y los desafíos de la toma de decisiones que resuelve el Agente Inteligente para la validación del proyecto previo a la obtención del título de Magister en Ciencias de Datos con el tema "Desarrollo de un agente inteligente basado en aprendizaje automático para la mejora en la toma de decisiones estratégicas en la Dirección de Sostenibilidad de ESPOL".

nnsarmor@gmail.com [Cambiar cuenta](#)



No compartido

* Indica que la pregunta es obligatoria

En promedio, ¿cuánto tiempo le toma completar todo el proceso, desde la extracción de datos hasta la generación de un **reporte de consumo con gráfico de análisis** (ej. Consumo mensual por edificio)? *

Tu respuesta

De ese tiempo total, ¿cuál es el porcentaje (%) que dedica a la **preparación y limpieza de los datos** (datos faltantes, errores, conversiones) antes de iniciar el análisis? *

Tu respuesta

¿Con qué frecuencia (Escala 1 al 5, siendo 5 muy frecuente) se ve obligado a realizar **múltiples consultas manuales** a la base de datos para obtener toda la información necesaria para un solo reporte? *

- 1
- 2
- 3
- 4
- 5

[Siguiete](#)

[Borrar formulario](#)

Sección B: Toma de Decisiones y Necesidad

¿Cuál es el nivel de dificultad (Escala 1 al 5, siendo 5 muy difícil) para traducir los datos y gráficos técnicos en **recomendaciones estratégicas claras y accionables** para los directivos? *

- | | | | | |
|-----------------------|-----------------------|-----------------------|-----------------------|-----------------------|
| 1 | 2 | 3 | 4 | 5 |
| <input type="radio"/> | <input type="radio"/> | <input type="radio"/> | <input type="radio"/> | <input type="radio"/> |

¿Con qué frecuencia la demora en la obtención de reportes (ej. más de un día) ha afectado negativamente la **oportunidad** de implementar una acción de ahorro o detectar una ineficiencia crítica? *

- 1
- 2
- 3
- 4
- 5

[Atrás](#)

[Siguiete](#)

[Borrar formulario](#)

Sección C: Trazabilidad y Confianza

Quando presenta una recomendación, ¿requiere el directivo una **justificación detallada** de las fuentes de datos y los cálculos utilizados? *

- Si
- No

¿Cuál de las siguientes funcionalidades sería la más valiosa para mejorar la **eficiencia y la trazabilidad** del proceso? (Seleccione una) *

- Generación automatizada del ranking de consumo (Top 5).
- Integración de la consulta de datos en lenguaje natural.
- Presentación del análisis y las recomendaciones de forma contextualizada y narrada.

Atrás

Enviar

Borrar formulario

APÉNDICE D. Respuesta de encuesta realizada a personal del área de Sostenibilidad

En promedio, ¿cuánto tiempo le toma completar todo el proceso, desde la extracción de * / 0
datos hasta la generación de un **reporte de consumo con gráfico de análisis** (ej.
Consumo mensual por edificio)?

45 min

Añadir comentarios a una respuesta individual

De ese tiempo total, ¿cuál es el porcentaje (%) que dedica a la **preparación y limpieza** * / 0
de los datos (datos faltantes, errores, conversiones) antes de iniciar el análisis?

10 minutos

Añadir comentarios a una respuesta individual

¿Con qué frecuencia (Escala 1 al 5, siendo 5 muy frecuente) se ve obligado a realizar * / 0
múltiples consultas manuales a la base de datos para obtener toda la información
necesaria para un solo reporte?

- 1
- 2
- 3
- 4
- 5

Añadir comentarios a una respuesta individual

¿Cuál es el nivel de dificultad (Escala 1 al 5, siendo 5 muy difícil) para traducir los datos * / 0
y gráficos técnicos en **recomendaciones estratégicas claras y accionables** para los
directivos?

1

2

3

4

5

Añadir comentarios a una respuesta individual

¿Con qué frecuencia la demora en la obtención de reportes (ej. más de un día) ha
afectado negativamente la **oportunidad** de implementar una acción de ahorro o
detectar una ineficiencia crítica? * / 0

 1 2 3 4 5

Añadir comentarios a una respuesta individual

Quando presenta una recomendación, ¿requiere el directivo una **justificación detallada** * _____ / 0 de las fuentes de datos y los cálculos utilizados?

- Sí
- No

Añadir comentarios a una respuesta individual

¿Cuál de las siguientes funcionalidades sería la más valiosa para mejorar la **eficiencia** * _____ / 0 **y la trazabilidad** del proceso? (Seleccione una)

- Generación automatizada del ranking de consumo (Top 5).
- Integración de la consulta de datos en lenguaje natural.
- Presentación del análisis y las recomendaciones de forma contextualizada y narrada.

Añadir comentarios a una respuesta individual