

Pontificia Universidad Javeriana Cali
Facultad de Ingeniería.
Maestría en Ingeniería de Software
Proyecto de Grado.

Prototipo de Arquitectura IoT para Automatización y Optimización Energética de Sistemas HVAC en el Sector Comercial de Bogotá

Edgar Ernesto Castro Gaviria
Pável Nicolás Delgado Dejoy

Director(a): Diego Armando Quintero Quiñones

10 de Marzo de 2025



Santiago de Cali, 10 de Marzo de 2025.

Señores

Pontificia Universidad Javeriana Cali.

Ph.D. Luisa Rincón

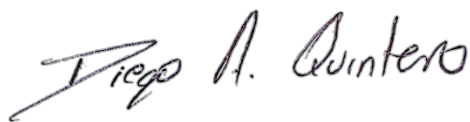
Directora Maestría en Ingeniería de Software.

Cali.

Cordial Saludo.

Por medio de la presente hago constar que en mi calidad de director de trabajo de grado he revisado el proyecto titulado “Prototipo de Arquitectura IoT para Automatización y Optimización Energética de Sistemas HVAC en el Sector Comercial de Bogotá” realizado por el estudiante de Magister en Ingeniería de Software Edgar Ernesto Castro Gaviria (cod: 9009903) , Pável Nicolás Delgado Dejoy (cod: 9009903), el cual se encuentra terminado y considero que cumple con los requisitos para ser sustentado.

Atentamente,



Diego Armando Quintero Quiñones

Santiago de Cali, 10 de Marzo de 2025.

Señores

Pontificia Universidad Javeriana Cali

Ph.D. Luisa Rincón

Directora Maestría en Ingeniería de Software

Cali.

Cordial Saludo.

Nos permitimos presentar a su consideración el proyecto de grado titulado “Prototipo de Arquitectura IoT para Automatización y Optimización Energética de Sistemas HVAC en el Sector Comercial de Bogotá” con el fin de cumplir con los requisitos exigidos por la Universidad y para que sea sometido a revisión del jurado y cumpla su aprobación, para conseguir posteriormente el título de Magister en Ingeniería de Software.

Atentamente,

Edgar Ernesto Castro Gaviria
Código: 9009903

Pável Nicolás Delgado Dejoy
Código: 9013349

Ficha Resumen

Trabajo de Grado Maestría en Ingeniería de Software

TÍTULO: Prototipo de Arquitectura IoT para Automatización y Optimización Energética de Sistemas HVAC en el Sector Comercial de Bogotá

1. Énfasis: Ingeniería de Software
2. Área de trabajo: IoT
3. Tipo de proyecto (Aplicado, Innovación, Investigación): Investigación
4. Estudiante: Pavel Nicolas Delgado Dejoy - Edgar Ernesto Castro Gaviria
5. Correo electrónico: pavelnicolas@javerianacali.edu.co , edgarc91@javerianacali.edu.co
6. Dirección y teléfono: Cali - 3188409695 ; Monteria 3017450236
7. Director: Diego Armando Quintero Quiñonez
8. Vinculación del director(Planta/Cátedra/Externo): Externo
9. Correo electrónico del director: diegoquintero424@hotmail.com
10. Co-Director (Si aplica):
11. Grupo o empresa que lo avala (Si aplica):
12. Otros grupos o empresas:
13. Palabras clave(al menos 5): Eficiencia Energetica , Arquitectura de Software, HVAC , Red Mesh, IoT , SmartMeter
14. ODS que aplica al proyecto (Agenda 2030):
15. Fecha de inicio: Agosto - 2024
16. Resumen: Proyecto de eficiencia energética para sistemas HVAC en el sector comercial colombianos. Investigación y adecuación de una arquitectura para el monitoreo inteligente y control remoto con el fin de optimizar consumo, reducir costos, minimizar impacto ambiental y mejorar confort laboral. Solución adaptada al contexto local, integrando medición y actuación automatizada.

Agradecimientos

Agradecemos primeramente a **Dios**, por guiarnos, fortalecernos y permitirnos culminar esta etapa académica con sabiduría y determinación.

Expresamos nuestra profunda gratitud a nuestras **familias**, quienes con amor, paciencia y apoyo incondicional nos acompañaron durante todo este proceso. Su confianza en nosotros fue la fuente constante de motivación en los momentos de mayor exigencia.

Extendemos un agradecimiento especial a nuestros **docentes y asesores** del programa de Maestría en Ingeniería de Software de la Pontificia Universidad Javeriana Cali, en particular al **director Diego Armando Quintero Quiñones**, por su guía técnica, su dedicación y por creer en el valor de nuestro proyecto desde el inicio. Su acompañamiento fue fundamental para la consolidación de esta propuesta.

Reconocemos también el apoyo de nuestros **compañeros de clase**, con quienes compartimos aprendizajes, desafíos y experiencias que enriquecieron este camino académico.

A todas las personas, profesionales y expertos que aportaron con sus conocimientos, tiempo y disposición, gracias por su generosidad y por ayudar a que este proyecto se fortaleciera desde múltiples perspectivas.

Finalmente, este logro representa más que un cumplimiento académico: es un testimonio del esfuerzo, la colaboración y la pasión por la tecnología puesta al servicio de la sostenibilidad. Cada paso en este camino ha dejado una huella profunda en nuestra formación personal y profesional.

Resumen

Los sistemas HVAC (Calefacción, Ventilación y Aire Acondicionado) en el sector comercial de Bogotá enfrentan problemas de ineficiencia energética debido a la ausencia de monitoreo especializado y gestión automatizada de variables operativas. Esta investigación desarrolló un prototipo de arquitectura IoT para la optimización energética de sistemas HVAC comerciales mediante la integración de tecnologías de monitoreo, procesamiento en la nube, y análisis predictivo.

La metodología implementada combinó datos reales obtenidos de un entorno hospitalario con sistemas HVAC operativos y simulación controlada para generar un dataset de 240 registros distribuidos en 10 medidores virtuales. El sistema desarrollado utiliza una arquitectura distribuida en Amazon Web Services que procesa 40 variables eléctricas, incluyendo distorsión armónica total de corriente y factor de potencia, para detectar anomalías operativas y generar recomendaciones de mantenimiento predictivo.

El modelo de machine learning implementado, basado en el algoritmo XGBoost, alcanzó una precisión del 94.44 % en la detección de anomalías, con una tasa de detección del 82.92 %. El análisis reveló que el 82.91 % de las mediciones evaluadas presentan estados anómalos, evidenciando oportunidades de optimización energética en sistemas HVAC sin monitoreo especializado. El sistema generó clasificaciones de riesgo individualizadas para 12 equipos en estado crítico y desarrolló dashboards especializados en Power BI para la visualización operativa de resultados.

Los resultados validaron la viabilidad técnica de implementar arquitecturas IoT distribuidas para gestión energética HVAC, demostrando capacidad para transformar datos de monitoreo eléctrico en información operativa útil para la toma de decisiones. El prototipo desarrollado proporciona una metodología replicable para la implementación de sistemas de monitoreo automatizado en instalaciones comerciales, contribuyendo al avance del conocimiento técnico en optimización energética mediante tecnologías IoT.

Palabras Clave: Eficiencia Energética, Internet de las Cosas (IoT), Sistemas HVAC, Machine Learning, XGBoost, Monitoreo Energético, AWS, Distorsión Armónica, Mantenimiento Predictivo, Power BI

Abstract

HVAC (Heating, Ventilation, and Air Conditioning) systems in Bogotá's commercial sector face energy inefficiency problems due to the absence of specialized monitoring and automated management of operational variables. This research developed an IoT architecture prototype for energy optimization of commercial HVAC systems through the integration of monitoring technologies, cloud processing, and predictive analytics.

The implemented methodology combined real data obtained from a hospital environment with operational HVAC systems and controlled simulation to generate a dataset of 240 records distributed across 10 virtual meters. The developed system uses a distributed architecture on Amazon Web Services that processes 40 electrical variables, including total harmonic distortion of current and power factor, to detect operational anomalies and generate predictive maintenance recommendations.

The implemented machine learning model, based on the XGBoost algorithm, achieved 94.44 % accuracy in anomaly detection, with a detection rate of 82.92 %. The analysis revealed that 82.91 % of evaluated measurements present anomalous states, evidencing energy optimization opportunities in HVAC systems without specialized monitoring. The system generated individualized risk classifications for 12 equipment units in critical state and developed specialized dashboards in Power BI for operational visualization of results.

Results validated the technical viability of implementing distributed IoT architectures for HVAC energy management, demonstrating capacity to transform electrical monitoring data into useful operational information for decision-making. The developed prototype provides a replicable methodology for implementing automated monitoring systems in commercial facilities, contributing to the advancement of technical knowledge in energy optimization through IoT technologies.

Keywords: Energy Efficiency, Internet of Things (IoT), HVAC Systems, Machine Learning, XGBoost, Energy Monitoring, AWS, Harmonic Distortion, Predictive Maintenance, Power BI

Índice general

Agradecimientos	7
1. Introducción	1
1.1. Definición del problema	2
1.1.1. Planteamiento del problema	2
1.1.2. Formulación del problema	5
1.2. Objetivos del proyecto	6
1.2.1. Objetivo General	6
1.2.2. Objetivos específicos	6
1.3. Delimitaciones y alcances	7
1.4. Justificación del trabajo de grado	8
1.5. Metodología de la investigación	9
1.6. Resultados obtenidos	10
1.6.1. Implementación de Arquitectura IoT Funcional	11
1.6.2. Desarrollo del Modelo de Machine Learning	11
1.6.3. Análisis del Estado Operativo de Sistemas HVAC	11
1.6.4. Dashboards de Visualización Desarrollados	12
1.6.5. Validación de Variables de Monitoreo	12
1.6.6. Funcionalidades del Sistema Implementado	12
2. Marco de referencia	15
2.1. Marco Teórico	15
2.1.1. Eficiencia Energética: Conceptos Fundamentales	15
2.1.2. Sistemas HVAC: Fundamentos y Características	15
2.1.3. Tecnologías IoT y Automatización en Sistemas HVAC	19
2.1.4. Sistemas de Medición Inteligente (AMI)	20
2.1.5. Marco Regulatorio y Normativo	20
2.2. Estado del Arte	21
2.2.1. Introducción	21
2.2.2. Avances Recientes en Automatización de HVAC	21
2.2.3. Soluciones de Medición Inteligente y Análisis de Datos	22
2.2.4. Avances en Tecnologías HVAC	22
2.2.5. Soluciones Específicas para el Contexto de Bogotá	23
2.2.6. Identificación de Brechas y Oportunidades de Investigación	23
2.3. Resumen del capítulo	24

3. Desarrollo del Proyecto	27
3.1. Etapa de Investigación y Contextualización	27
3.1.1. Identificación y Parametrización de Variables Eléctricas	27
3.1.2. Interrelación entre Variables de Entrada y Salida	29
3.1.3. Variables Eléctricas Monitoreadas	29
3.2. Recolección de Datos	30
3.2.1. Procedimiento de Recolección de Datos	30
3.2.2. Fase 2: Generación de Datos de Simulación	32
3.2.3. Procesamiento y Preparación de Datos	33
3.3. Análisis de Requisitos	33
3.3.1. Requisitos Funcionales y No Funcionales	33
3.4. Diseño de la Arquitectura	36
3.4.1. Visión General de la Arquitectura	36
3.4.2. Componentes de la Arquitectura	36
3.4.3. Flujo de Datos en la Arquitectura	40
3.5. Implementación Tecnológica	41
3.5.1. Servicios AWS Implementados	41
3.5.2. Implementación de Modelos de Detección de Anomalías	42
3.6. Restricciones de Arquitectura	44
3.6.1. Restricciones Técnicas	44
3.6.2. Restricciones Económicas	45
3.6.3. Restricciones Organizacionales	45
3.6.4. Restricciones Regulatorias	45
3.6.5. Resumen	45
3.7. Decisiones Arquitectónicas: Uso de Servicios Serverless en AWS	45
3.8. Resultados Preliminares	48
3.8.1. Validación de Componentes Arquitectónicos	48
3.8.2. Desempeño de Módulos de Machine Learning	48
3.8.3. Efectividad del Modelo de Detección de Anomalías	49
3.8.4. Validación de Componentes de Monitoreo y Control	49
3.8.5. Integración de Componentes Hardware	49
3.8.6. Estimación de Viabilidad Operacional	50
3.8.7. Estimación de Costos de Implementación	50
3.9. Desafíos y Soluciones	51
3.9.1. Desafíos en la Recolección y Calidad de Datos	51
3.9.2. Desafíos Arquitectónicos y de Integración	52
3.9.3. Desafíos Específicos del Dominio HVAC	52
3.9.4. Validación y Refinamiento de Soluciones	53
3.10. Resumen del capítulo	53

4. Evaluación	55
4.1. Diseño de la Evaluación	55
4.1.1. Marco Conceptual de la Evaluación	55
4.1.2. Variables y Parámetros de Evaluación	55
4.1.3. Marco Normativo de Evaluación	56
4.1.4. Metodología de Procesamiento y Análisis	56
4.1.5. Herramientas y Plataforma de Visualización	57
4.1.6. Estructura de Evaluación Dual	57
4.1.7. Criterios de Validación Técnica	57
4.2. Resultados de la evaluación	58
4.2.1. Análisis del Estado Base Pre-Implementación	58
4.2.2. Análisis Predictivo y de Mantenimiento Preventivo	63
4.2.3. Conclusiones del Análisis de Resultados	68
5. Conclusiones	71
5.1. Conclusiones	71
5.1.1. Validación de la Metodología de Desarrollo	71
5.1.2. Rendimiento de la Arquitectura Tecnológica Implementada	71
5.1.3. Generación de Conocimiento Operativo	71
5.1.4. Contribución al Avance del Conocimiento Técnico	72
5.1.5. Validación de Hipótesis y Cumplimiento de Objetivos	72
5.1.6. Consideraciones para Implementaciones Futuras	72
5.2. Trabajos futuros	73
5.2.1. Expansión del Modelo de Machine Learning con Variables Adicionales	73
5.2.2. Sistema de Corte y Reconexión Automática	73
5.2.3. Monitoreo Granular de Componentes HVAC Individuales	73
5.2.4. Control Termo-Higrométrico Integrado	74
5.2.5. Implementación de Control Predictivo	74
5.2.6. Dashboards Especializados para Diferentes Usuarios	74
5.3. Lecciones aprendidas	74
5.3.1. Importancia de la Selección de Variables Objetivo	74
5.3.2. Complejidad de la Integración de Tecnologías	75
5.3.3. Relevancia de la Visualización para la Adopción	75
5.3.4. Importancia de la Validación con Datos Reales	75
5.3.5. Necesidad de Consideraciones de Escalabilidad	75
5.3.6. Importancia de la Documentación y Reproducibilidad	75
Bibliografía	77

Índice de figuras

1.1. Esquema general del sistema de gestión y optimización de HVAC	3
1.2. Disposición de componentes en tablero de control HVAC	4
1.3. Diagrama integrado de control y monitoreo HVAC	5
2.1. Plano general de las rutas de un sistema HVAC	17
2.2. Diagrama unifilar de tablero que alimenta una zona	18
3.1. Diagrama de contexto.	36
3.2. Arquitectura general del sistema.	37
4.1. Dashboard del Sistema de Eficiencia Energética HVAC - Estado Base Pre-Implementación	59
4.2. Distribución de estados operativos de sistemas HVAC por nivel de anomalía	60
4.3. Tabla de análisis de variables de calidad energética por medidor	61
4.4. Evolución temporal de la distorsión armónica total de corriente (THDi) con líneas de referencia	62
4.5. Dashboard del Sistema de Eficiencia Energética HVAC - Análisis Predictivo	64
4.6. Distribución de RiskScore por sistema HVAC con segmentación por niveles de anomalía	65
4.7. Tabla de mantenimiento predictivo de sistemas HVAC con clasificación por criticidad	66
4.8. Sistema de filtros por prioridad y tipo de anomalía en el dashboard	67

Índice de cuadros

3.1. Parametrización de variables eléctricas clave para sistemas HVAC	28
3.2. Requisitos funcionales y no funcionales de la arquitectura	35

Introducción

La eficiencia energética ha emergido como un pilar fundamental para el desarrollo sostenible en el siglo XXI, particularmente en el sector comercial donde el consumo energético representa una parte significativa de los costos operativos y contribuye considerablemente al impacto ambiental. En este contexto, los sistemas de Calefacción, Ventilación y Aire Acondicionado (HVAC¹) destacan por su elevado consumo energético. Estudios recientes han demostrado que estos sistemas pueden representar aproximadamente el 50 % del consumo total de energía en edificios comerciales [Garces-Jimenez et al. \(2021\)](#), superando significativamente a otros componentes como iluminación, equipos de oficina y ascensores.

Como expresó William Thomson Kelvin: "lo que no se define no se puede medir, lo que no se puede medir no se puede mejorar, lo que no se mejora se degrada siempre". Esta premisa resulta fundamental para abordar la gestión energética de sistemas HVAC, donde la identificación y medición de variables críticas como las distorsiones armónicas de corriente y voltaje, corrientes, voltajes y potencia activa, así como otras variables de consumo y calidad de la energía, permiten detectar la degradación temprana de componentes y su impacto en la eficiencia energética. Sin la medición adecuada de estos parámetros, los sistemas HVAC operan sin supervisión, experimentando pérdidas de eficiencia progresivas que se traducen en mayor consumo energético y costos operativos elevados [ABB \(2018\)](#).

En el contexto específico de Bogotá, los sistemas HVAC adquieren relevancia debido al alto nivel de ocupación que aumenta la carga térmica en los edificios, lo que ha llevado a que las normativas de seguridad y salud en el trabajo exijan sistemas adecuados de ventilación y recirculación de aire [Martínez Espinal et al. \(2023\)](#). Sin embargo, la gestión eficiente de estos sistemas representa un desafío para las empresas, tanto en términos de costos operativos como de mantenimiento. Los métodos tradicionales de control, basados en programadores horarios mecánicos y operación manual, resultan insuficientes para optimizar el rendimiento de los sistemas HVAC en un entorno empresarial.

El presente trabajo de grado aborda el diseño, implementación y validación de un prototipo de arquitectura IoT distribuida que integra tecnologías de Internet de las Cosas y análisis de variables eléctricas para la optimización energética de sistemas HVAC en el sector comercial de Bogotá. La relevancia de esta investigación se fundamenta en el potencial de las tecnologías IoT y los sistemas de análisis de datos para transformar la gestión energética mediante la detección de anomalías operativas y el análisis predictivo. La integración de estas tecnologías permite el procesamiento de variables eléctricas críticas como distorsión armónica total de corriente y factor

¹HVAC: Heating, Ventilation and Air Conditioning (Calefacción, Ventilación y Aire Acondicionado).

de potencia, facilitando la implementación de estrategias de mantenimiento predictivo que previenen la degradación del sistema y optimizan el consumo energético.

La metodología implementada combinó datos reales obtenidos de sistemas HVAC operativos con simulación controlada para el desarrollo del modelo de detección de anomalías. La implementación incluyó el diseño de una arquitectura distribuida en Amazon Web Services, la aplicación de algoritmos de machine learning para análisis predictivo, y el desarrollo de dashboards especializados para la visualización operativa de resultados. La evaluación del sistema se realizó mediante el procesamiento de datos que representan el comportamiento de múltiples medidores distribuidos en diferentes tableros eléctricos, validando la capacidad del sistema para detectar condiciones anómalas y generar recomendaciones de mantenimiento.

Los resultados de esta investigación demuestran la viabilidad técnica de implementar arquitecturas IoT distribuidas para la gestión energética de sistemas HVAC comerciales. El prototipo desarrollado mostró capacidad para detectar anomalías operativas, identificando oportunidades de optimización energética mediante sistemas de monitoreo automatizado. La investigación contribuye al avance del conocimiento técnico en la aplicación de tecnologías IoT para gestión energética, proporcionando una metodología replicable para la implementación de sistemas de monitoreo automatizado en instalaciones comerciales. Además, esta investigación se alinea con las políticas nacionales e internacionales de eficiencia energética, como la Ley 1715 de 2014 de la República de Colombia (2014) y estándares como la ISO 50001 ISO (2018), aportando una solución tecnológica adaptada al contexto local que responde tanto a desafíos técnicos como a objetivos más amplios de sostenibilidad y desarrollo económico en el contexto colombiano.

1.1. Definición del problema

1.1.1. Planteamiento del problema

La eficiencia energética constituye uno de los mayores desafíos para la sostenibilidad urbana, especialmente en sectores comerciales de economías emergentes. Como señala la Agencia Internacional de Energía (IEA), la eficiencia energética implica una "gestión estratégica de recursos que simultáneamente reduce el consumo, disminuye costos y mitiga impactos ambientales" IEA (2023). En este contexto, optimizar el rendimiento energético de edificaciones comerciales resulta prioritario debido a su huella ecológica e impacto financiero. Los sistemas HVAC (Heating, Ventilation and Air Conditioning) presentan un consumo energético elevado dentro de la matriz de consumo de edificios comerciales, pudiendo absorber aproximadamente el 50 % del total de energía consumida en instalaciones comerciales Garces-Jimenez et al. (2021).

En Colombia, el sector comercial representa cerca del 6 % de la demanda energética nacional, con un 66,2 % abastecido por energía eléctrica UPME (2015). En Bogotá, el incremento en la implementación de sistemas HVAC responde tanto a condiciones climáticas como a normativas de seguridad laboral que exigen adecuada ventilación Martínez Espinal et al. (2023). Aunque diversas empresas han desarrollado soluciones innovadoras, como Excelec con sus medidores AMI Excelec (2024) o Telemetrik con soluciones IoT Telemetrik (2024), persiste una brecha en el mercado: la

ausencia de soluciones integrales para automatización de tableros HVAC adaptadas al contexto bogotano.

La ineficiencia energética en sistemas HVAC del sector comercial tiene múltiples causas: consumo energético entre 60 % y 70 % del total en edificios [Balbis-Morejón et al. \(2021\)](#), falta de monitoreo adecuado [Jana et al. \(2020\)](#), prácticas operativas ineficientes [Gowrishankar et al. \(2023\)](#) y ausencia de plataformas unificadas [Du et al. \(2023\)](#). A pesar de normativas como ISO 50001 [BSI \(2018\)](#) y Ley 1715 de 2014 [de Colombia \(2014\)](#), existe poca conciencia sobre el potencial de ahorro entre propietarios y administradores.

Para abordar esta problemática, Geo Technologies propone una arquitectura que adapta las capacidades de sistemas de medición inteligente hacia la gestión y control automatizado de sistemas HVAC. Como se ilustra en la Figura 1.1, la solución implementa una arquitectura jerárquica distribuida con dispositivos de medición y control, gestión local, y procesamiento en la nube.

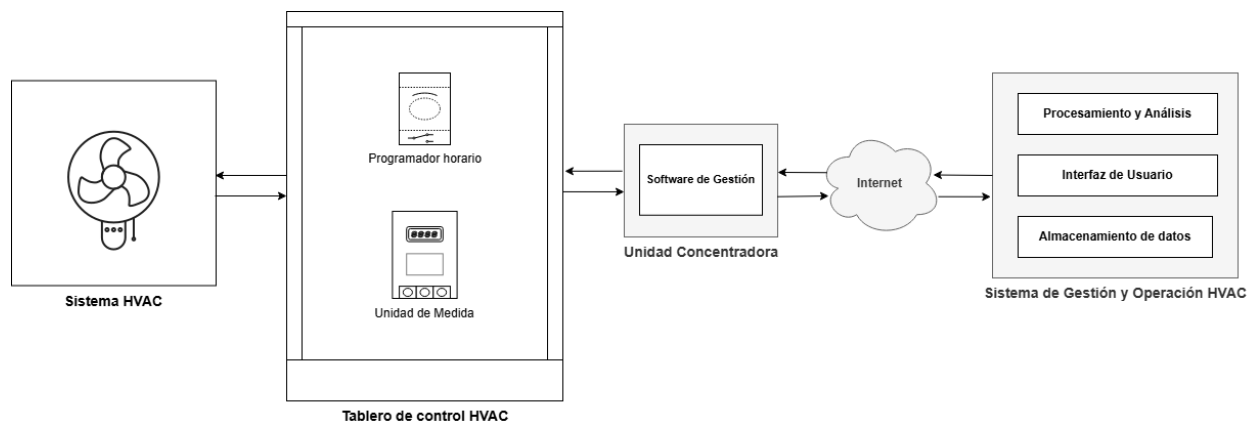


Figura 1.1: Esquema general del sistema de gestión y optimización de HVAC

El diseño se estructura en niveles jerárquicos, desde tableros de control HVAC hasta una unidad concentradora local y servicios en la nube. Un aspecto crítico es la medición de variables de calidad energética como voltajes, corrientes, potencias y distorsión armónica total (THD). Esta última resulta crucial pues, como indica ABB, niveles elevados de THD causan sobrecalentamiento y fallos prematuros en equipos [ABB \(2018\)](#). El monitoreo permite implementar estrategias proactivas como la instalación de filtros cuando los parámetros exceden límites establecidos.

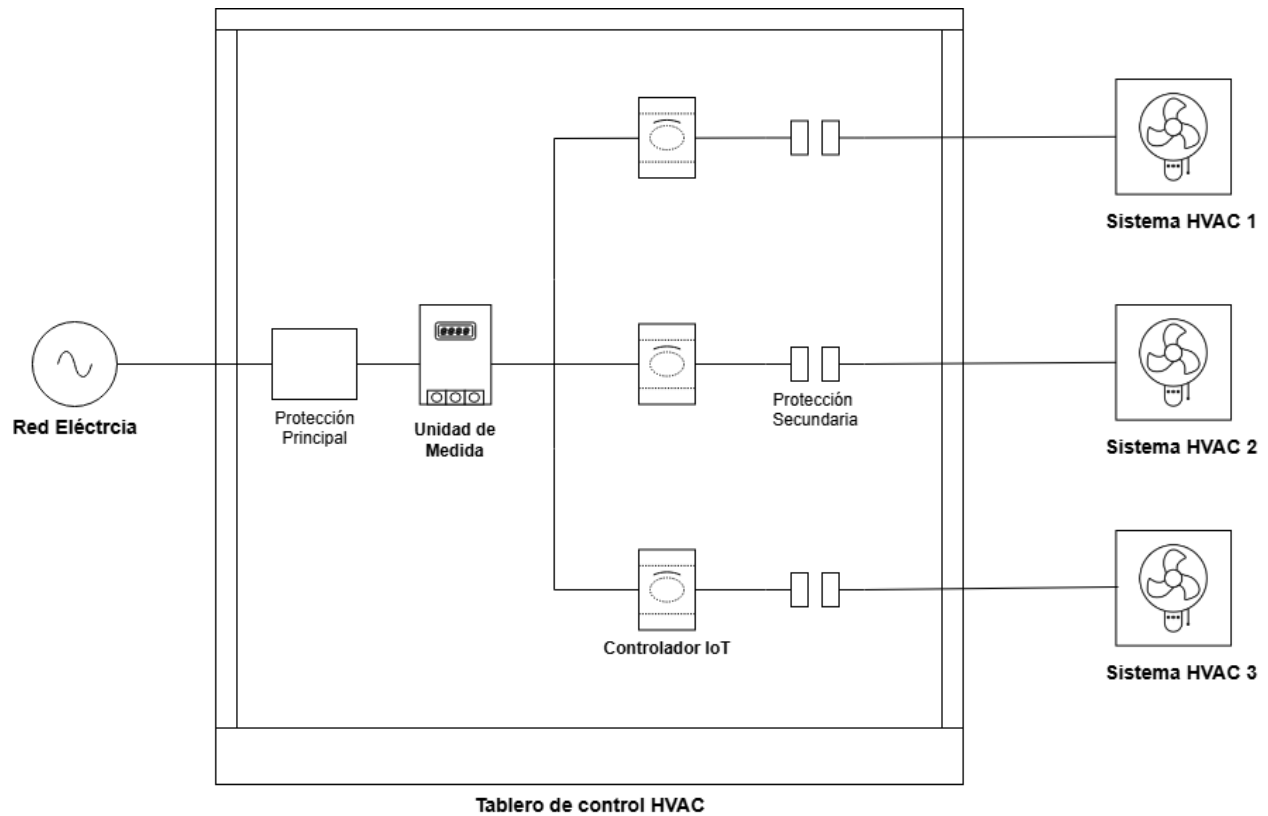


Figura 1.2: Disposición de componentes en tablero de control HVAC

Como se observa en la Figura 1.2, la arquitectura tradicional incluye un medidor inteligente en la protección principal y programadores horarios básicos en cada circuito. La propuesta contempla reemplazar estos programadores por controladores IoT, transformando el control de manual a inteligente y conectado. En edificios comerciales de Bogotá, la complejidad aumenta pues cada espacio presenta diferentes requerimientos de capacidad y horarios según sus patrones de ocupación.

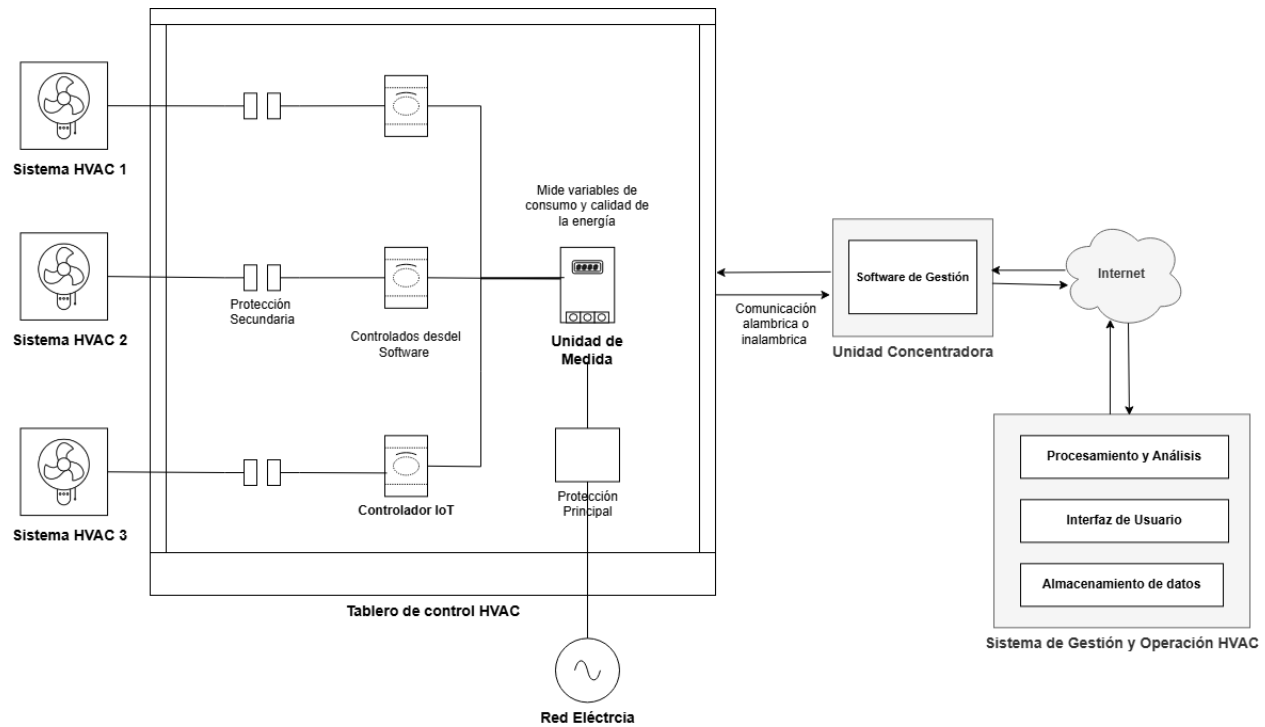


Figura 1.3: Diagrama integrado de control y monitoreo HVAC

La Figura 1.3 muestra el sistema integrado que combina monitoreo de calidad energética con control IoT centralizado. La comunicación entre componentes se diseña con flexibilidad, permitiendo diferentes medios de transmisión según cada instalación. Esta solución promete optimizar el consumo energético mediante gestión individualizada de espacios y reducir costos operativos a través del monitoreo en tiempo real y detección temprana de fallos, representando una evolución frente a métodos tradicionales de control.

1.1.2. Formulación del problema

¿Cómo diseñar e implementar una arquitectura de software que permita la integración, monitoreo y control remoto de sistemas HVAC en el sector comercial de Bogotá, que incorpore análisis de información en tiempo real proveniente de medidores inteligentes y permita la automatización de ciclos de operación individualizados?

Para abordar esta problemática, se plantean las siguientes preguntas de investigación:

1. ¿Qué arquitectura de software se requiere para procesar y analizar en tiempo real los datos provenientes de medidores inteligentes de energía, implementando estrategias de mantenimiento predictivo, detección temprana de fallos y optimización de la operación del sistema?
2. ¿Cómo implementar un sistema de automatización que permita el control remoto y la programación flexible de múltiples unidades HVAC, adaptando sus ciclos de operación según

patrones de ocupación y condiciones específicas de cada espacio?

3. ¿Cómo implementar y validar un prototipo de arquitectura funcional que permita simular y evaluar la efectividad del sistema propuesto en términos de monitoreo, control y optimización de unidades HVAC?
4. ¿Qué métricas y estrategias de análisis se requieren para evaluar la efectividad del prototipo en términos de gestión energética, considerando variables como calidad de energía, patrones de consumo y eficiencia operativa de las unidades HVAC?

1.2. Objetivos del proyecto

1.2.1. Objetivo General

Diseñar, implementar y validar un prototipo de arquitectura de software distribuida que integre dispositivos IoT y medidores inteligentes de energía, mediante una plataforma de procesamiento y análisis de datos en tiempo real, para la automatización y control remoto de sistemas HVAC en el sector comercial de Bogotá a través de su interfaz controlador, permitiendo la optimización del consumo energético a través de la gestión individualizada de ciclos de operación basada en el análisis de patrones de uso y variables eléctricas.

1.2.2. Objetivos específicos

1. Diseñar una arquitectura de software distribuida para el procesamiento y análisis en tiempo real de variables eléctricas provenientes de medidores inteligentes, implementando estrategias de mantenimiento predictivo y detección temprana de fallos mediante técnicas de detección de anomalías utilizando una estrategia de Detección de puntos atípicos en el análisis de datos.
2. Diseñar e implementar un componente de arquitectura orientado a la automatización que integre capacidades de control remoto y programación dinámica de unidades HVAC en su interfaz controlador, permitiendo la gestión individualizada de espacios basada en patrones de ocupación y condiciones específicas de operación para la optimización del consumo energético.
3. Implementar y validar un prototipo funcional de la arquitectura propuesta mediante la simulación de escenarios operativos, evaluando su efectividad en términos de monitoreo en tiempo real, control automatizado y capacidad de optimización de sistemas HVAC.
4. Establecer un marco de evaluación que integre métricas de calidad de energía, patrones de consumo y eficiencia operativa, permitiendo cuantificar el impacto del sistema en la gestión energética de las unidades HVAC y validar las estrategias de optimización implementadas.

1.3. Delimitaciones y alcances

El presente trabajo se enfocó en el diseño, implementación y validación de un prototipo de arquitectura de software distribuida que integró tecnologías IoT y medidores inteligentes de energía para la gestión de sistemas HVAC. Este desarrollo comprendió los siguientes aspectos:

1. **Arquitectura de Software para Procesamiento y Análisis en Tiempo Real:** Se diseñó e implementó una arquitectura que incorporó componentes para el procesamiento y análisis en tiempo real de variables eléctricas, incluyendo estrategias de mantenimiento predictivo y detección temprana de fallos. La arquitectura abarcó el diseño detallado de interfaces, protocolos de comunicación y mecanismos de integración necesarios para la interacción entre medidores inteligentes, unidad concentradora y servicios en la nube.
2. **Componente de Automatización y Control:** Se desarrolló el diseño e implementación de los componentes arquitectónicos orientados a la automatización, que incluyeron capacidades de control remoto y programación dinámica de unidades HVAC. Este desarrollo contempló los mecanismos necesarios para la gestión individualizada de espacios basada en patrones de ocupación y condiciones específicas de operación.
3. **Prototipo Funcional y Validación:** Se implementó un prototipo funcional que integró los componentes diseñados, permitiendo simular y validar escenarios operativos en un entorno controlado. Este prototipo incluyó capacidades de monitoreo en tiempo real, control automatizado y optimización del consumo energético, facilitando la evaluación de las estrategias implementadas mediante simulaciones y análisis de datos.
4. **Marco de Evaluación:** Se estableció un marco de evaluación que permitió validar la efectividad del prototipo mediante métricas de calidad de energía, patrones de consumo y eficiencia operativa. Este marco proporcionó las bases para la validación cuantitativa de las estrategias de optimización implementadas.
5. **Limitaciones del Alcance**
 - El alcance de esta evaluación se restringió a la simulación y análisis del prototipo en un entorno controlado. La implementación física del prototipo en entornos comerciales no estuvo incluida en este alcance, por lo que se basó en los resultados obtenidos a partir de modelos y pruebas internas
 - Los dispositivos electrónicos y físicos utilizados para estas simulaciones no fueron entregados a la institución donde se generó la ponencia del proyecto.
 - El desarrollo se limitó al modelo funcional del prototipo, excluyendo implementaciones en producción o despliegues en entornos comerciales reales.
 - El alcance del proyecto se limitó al control y monitoreo del tablero eléctrico HVAC, incluyendo la medición de variables eléctricas y la gestión de ciclos de operación mediante programadores horarios inteligentes. No se contempló el control directo de los sistemas

HVAC (compresores, ventiladores, válvulas, etc.) ni la modificación de sus parámetros operativos internos.

1.4. Justificación del trabajo de grado

El desarrollo de un prototipo de arquitectura para el monitoreo y control de sistemas HVAC en el sector comercial de Bogotá contribuye a la eficiencia energética en Colombia, con impactos en diversos ámbitos:

Desde la perspectiva económica, la implementación de sistemas de automatización inteligente para HVAC puede reducir los costos operativos, con estudios que demuestran ahorros de hasta un 30 % [Balbis-Morejón et al. \(2021\)](#). Esta optimización se logra mediante el monitoreo en tiempo real de parámetros eléctricos como voltajes entre fases, corrientes entre fases, potencias (activa, reactiva y aparente), factor de potencia y distorsión armónica total, que permiten implementar estrategias proactivas cuando estos valores se desvían de los rangos óptimos, aplicando soluciones que han mostrado mejoras del 30-40 % en la calidad energética [ABB \(2018\)](#).

El comportamiento eléctrico de un sistema HVAC proporciona información valiosa sobre su estado operativo y su degradación a lo largo del tiempo. La monitorización continua de parámetros eléctricos fundamentales como tensión, corriente, distorsión armónica y factor de potencia permite establecer patrones de funcionamiento normal y detectar desviaciones que podrían indicar el desarrollo de condiciones anómalas. Estos patrones, analizados mediante técnicas avanzadas de análisis de datos como Amazon SageMaker, permiten implementar estrategias de mantenimiento predictivo.

El monitoreo inteligente requiere analizar la correlación entre diferentes variables eléctricas. Por ejemplo, un incremento aislado en la corriente de operación puede tener causas normales, pero cuando coincide con un aumento en la distorsión armónica de corriente (THDi) y una disminución del factor de potencia, indica deterioro en los devanados de un motor o problemas en los capacitores de filtrado. Esta correlación permite distinguir entre fluctuaciones normales y patrones que señalan fallos potenciales [Wang and Song \(2018\)](#).

La experiencia en proyectos de monitoreo y la literatura especializada han demostrado correlaciones específicas entre la distorsión armónica de corriente y fallos en componentes de sistemas HVAC. La distorsión armónica total de corriente (THDi) está ligada al sobrecalentamiento en componentes, disminución de la eficiencia del sistema y fallos prematuros en equipos HVAC [Wang and Song \(2018\)](#). Valores elevados de THDi, especialmente cuando se mantienen por encima del 40 % durante períodos prolongados, se asocian con problemas en variadores de frecuencia que controlan ventiladores y compresores. De manera similar, un desequilibrio de tensión superior al 1 % mantenido durante períodos prolongados acelera el deterioro de motores trifásicos, reduciendo su vida útil hasta en un 50 % [ABB \(2018\)](#).

En el ámbito ambiental, la optimización del consumo energético en sistemas HVAC contribuye a la reducción de emisiones de gases de efecto invernadero. Considerando que los edificios consumen aproximadamente el 40 % de la energía total mundial, y los sistemas HVAC representan hasta el 55 % de este consumo [Balbis-Morejón et al. \(2021\)](#), cualquier mejora tiene un impacto en la huella de carbono del sector comercial. El prototipo propuesto se alinea con estándares internacionales

como ISO 50001 y con la legislación colombiana sobre eficiencia energética de Colombia (2014). Desde la perspectiva social, este proyecto impulsa la creación de empleo calificado en el sector de tecnologías limpias, demandando personal especializado para diseño, instalación y mantenimiento, fomentando nuevas competencias en el mercado laboral local Hanna et al. (2024). La mejora en la eficiencia operativa de las empresas puede traducirse en beneficios para los consumidores y estimular la innovación y desarrollo tecnológico local.

El valor innovador del proyecto radica en la aplicación de tecnologías IoT y técnicas de aprendizaje automático para optimizar sistemas HVAC en el contexto específico de Bogotá, creando un ecosistema tecnológico que integra sistemas existentes como el SIMI con capacidades avanzadas de automatización. Este enfoque no solo genera nuevas fuentes de ingresos, sino que posiciona a las empresas colombianas en un lugar relevante en soluciones de eficiencia energética a nivel regional. El potencial de estos sistemas para balancear múltiples parámetros abre posibilidades para servicios de valor añadido y modelos de negocio basados en rendimiento.

Esta iniciativa establece un punto de partida para futuros estudios y avances tecnológicos en la gestión energética inteligente, promoviendo la innovación en el diseño de edificios sostenibles y generando datos que pueden informar políticas públicas e industriales, acelerando la transición hacia un futuro energético más eficiente en Colombia.

1.5. Metodología de la investigación

La investigación se desarrolló a través de un proceso metodológico que combinó análisis cuantitativos y cualitativos, organizado en cinco fases que permitieron estudiar la eficiencia energética en sistemas HVAC del sector comercial bogotano. Esta metodología facilitó la articulación entre los objetivos propuestos y los procedimientos implementados para su consecución, estableciendo un marco coherente para el desarrollo del prototipo de arquitectura distribuida.

En la primera fase, se realizó el levantamiento de requisitos y diseño de una arquitectura basada en IoT para la gestión en tiempo real de sistemas HVAC. Este proceso comenzó con una investigación teórica sobre sistemas HVAC, apoyada por consultorías con expertos en eficiencia energética de sistemas HVAC. Esta colaboración ayudó a entender el funcionamiento de estos sistemas en el contexto de edificaciones comerciales de Bogotá, considerando factores como altitud, temperatura y normativas específicas del sector que afectan su operación. A partir de esta base teórica, se analizaron las variables eléctricas importantes para el monitoreo y mantenimiento predictivo en sistemas HVAC. Se priorizaron variables como distorsiones armónicas de corriente y voltaje (THDi y THDv), corrientes por fase, voltajes fase-fase, potencia activa, factor de potencia, así como otras variables de calidad de la energía y de consumo, todas ellas parametrizadas según los estándares nacionales establecidos en la NTC 5001-2008 (ICONTEC, 2008) y normativas internacionales como IEEE 519-2014 (IEEE, 2014).

La segunda fase consistió en la recolección de información. Este proceso se realizó mediante la colaboración con una empresa prestadora de servicios de climatización y refrigeración en Bogotá, que autorizó la instalación de un medidor inteligente especializado en un tablero eléctrico que alimenta dos sistemas HVAC de una clínica especializada ubicada en la ciudad. Por razones de

confidencialidad contractual, no es posible revelar la identidad específica de las empresas e instalaciones involucradas en el estudio. La información se estructuró en formato JSON para simular su transmisión desde la Unidad Concentradora hasta el Sistema de Gestión y Operación (donde inicia la arquitectura propuesta). La implementación técnica se realizó en Amazon Web Services (AWS), usando servicios como Lambda para procesamiento, Kinesis Firehose para ingestión de datos cercano al tiempo real o Near Real Time, S3 para almacenamiento, SageMaker para la creación de modelos de detección de anomalías, y CloudWatch para monitoreo de la aplicación a nivel de logs.

El diseño de la arquitectura distribuida constituyó una fase importante de la metodología. La arquitectura integra módulos para la captura de datos (Emulate), recepción y distribución (Intake), almacenamiento multinivel (Raw, Curated, Analytics), catálogo y descubrimiento, procesamiento analítico, monitoreo, notificación y control.

En la tercera fase, se llevó a cabo la simulación y evaluación del sistema bajo distintas condiciones operativas. La evaluación del prototipo se basó en datos históricos recolectados durante un período de cinco días (31 de marzo al 5 de abril de 2025), mediante un medidor inteligente de energía especializado instalado en el tablero eléctrico TA-01A, programado para registrar mediciones cada 15 minutos. Este conjunto de datos proporcionó la base para validar los algoritmos de detección de anomalías y las estrategias de optimización implementadas, con especial énfasis en la distorsión armónica total de corriente (THDi) como variable objetivo principal para el desarrollo del modelo predictivo.

La cuarta fase abordó la optimización de algoritmos de control y parámetros de la arquitectura basada en los resultados de las simulaciones. Esta etapa permitió refinar los modelos analíticos y ajustar los umbrales de detección para cada variable monitoreada, mejorando la precisión del sistema para identificar condiciones anómalas en los equipos HVAC. El diseño por capas de la arquitectura facilitó dichas optimizaciones, permitiendo modificar componentes específicos sin afectar el funcionamiento general del sistema.

En la fase final, se realizó la validación del prototipo en un entorno controlado que simuló el comportamiento real de un edificio comercial, evaluando su efectividad mediante métricas de desempeño predefinidas. Para el análisis de resultados, se crearon tableros de visualización en AWS que mostraron tendencias, patrones y anomalías en los datos procesados. Estos tableros evaluaron la efectividad del prototipo en la reducción de consumo energético, detección temprana de fallos y optimización de ciclos de operación. Los resultados se compararon con métricas de referencia para sistemas HVAC, cuantificando el impacto potencial de implementar el prototipo a mayor escala.

La metodología por fases implementada vinculó el problema identificado con los objetivos propuestos y los resultados obtenidos. La combinación de investigación teórica, análisis de datos reales y desarrollo tecnológico abordó la problemática de eficiencia energética en sistemas HVAC del sector comercial de Bogotá, aportando al conocimiento y la práctica en este campo.

1.6. Resultados obtenidos

El desarrollo del prototipo de arquitectura IoT para sistemas HVAC comerciales generó resultados que pueden ser verificados y medidos a partir de la implementación realizada. Los principales

resultados obtenidos se fundamentan en las evidencias generadas durante el proceso de desarrollo y evaluación.

1.6.1. Implementación de Arquitectura IoT Funcional

Se desarrolló e implementó una arquitectura IoT que integra dispositivos de monitoreo simulados, procesamiento en la nube mediante AWS, y dashboards de visualización. La arquitectura procesó exitosamente 240 registros de mediciones eléctricas distribuidos en 10 medidores, evaluando 40 variables eléctricas durante un período de 6 días operativos.

El sistema implementado utiliza el bucket `odindatalake-analiticasage` en AWS como componente central de almacenamiento, demostrando la viabilidad técnica de la infraestructura en la nube para el manejo de datos de monitoreo HVAC. La integración entre componentes de ingesta, almacenamiento, procesamiento y visualización funcionó según lo diseñado, permitiendo el flujo completo de datos desde la captura hasta la presentación de resultados.

La arquitectura procesó 9,640 variables medidas a partir del procesamiento de las 40 variables eléctricas originales, confirmando la capacidad del sistema para manejar la transformación y expansión dimensional requerida para el análisis de calidad energética.

1.6.2. Desarrollo del Modelo de Machine Learning

Se implementó un algoritmo XGBoost configurado para la detección de anomalías en sistemas HVAC, alcanzando métricas específicas de rendimiento. El modelo obtuvo una precisión (accuracy) del 94.44 %, una precisión del modelo del 94.77 %, y una tasa de detección de anomalías del 82.92 %.

El modelo procesa las variables de distorsión armónica total de corriente, factor de potencia, y variables derivadas como entrada, generando scores de riesgo individualizados por equipo y clasificaciones de prioridad de mantenimiento. La funcionalidad implementada incluye la generación de recomendaciones específicas como "IMMEDIATE: Inspect equipmentz "Schedule maintenance inspection within 48 hours".

La tabla de mantenimiento predictivo generada identificó 12 equipos en estado crítico con scores de riesgo entre 84.00 y 100.00 puntos, proporcionando clasificaciones específicas para cada medidor evaluado.

1.6.3. Análisis del Estado Operativo de Sistemas HVAC

El análisis del dataset evaluado reveló que el 82.91 % de las mediciones presentan estados anómalos, distribuidos en 67.08 % en estado de advertencia y 15.83 % en estado crítico. Solo el 17.09 % de las mediciones se clasificaron en estado normal.

La distorsión armónica total de corriente mostró valores promedio de 25,828.43 unidades, con variaciones individuales por medidor entre 21,778.88 y 28,297.33 unidades. El factor de potencia promedio registrado fue de 823.5 unidades, con rangos individuales entre 792.25 y 847.42 unidades.

El score de eficiencia energética promedio calculado fue de 52 puntos, estableciendo una línea base cuantificable para el sistema evaluado. La distribución de prioridades de mantenimiento resultó

en 38 equipos clasificados como críticos, 161 como nivel medio, y 41 como nivel bajo.

1.6.4. Dashboards de Visualización Desarrollados

Se desarrollaron dos dashboards especializados en Power BI que traducen los resultados del análisis en visualizaciones operativas. El primer dashboard "Sistema de Eficiencia Energética HVAC - Estado Base Pre-Implementación" presenta la distribución de estados por medidor, análisis temporal de variables, y comparaciones entre valores medidos y umbrales establecidos.

El segundo dashboard "Sistema de Eficiencia Energética HVAC - Análisis Predictivo" integra los resultados del modelo de machine learning, mostrando scores de riesgo por equipo, distribución de anomalías, y recomendaciones de mantenimiento priorizadas. Los dashboards incluyen funcionalidades de filtrado dinámico por fecha, medidor, y nivel de prioridad.

Las visualizaciones desarrolladas permiten análisis comparativo entre medidores, seguimiento temporal de variables específicas, y identificación de patrones de comportamiento mediante gráficos de barras, líneas temporales, y tablas de datos estructuradas.

1.6.5. Validación de Variables de Monitoreo

Los resultados confirman que la distorsión armónica total de corriente funciona como variable objetivo para la evaluación del estado operativo de sistemas HVAC. Los umbrales establecidos (Normal: $THDi < 23$; Warning: $23 \geq THDi < 34$; Critical: $THDi \geq 34$) permitieron la clasificación consistente de estados operativos.

La metodología implementada para el procesamiento de 40 variables eléctricas simultáneas demostró viabilidad técnica para el monitoreo integral de calidad energética. El sistema generó clasificaciones de riesgo individualizadas y recomendaciones específicas basadas en el análisis de estas variables.

La correlación entre valores de $THDi$ y clasificaciones de estado se mantuvo consistente a lo largo del período de evaluación, validando la estabilidad del enfoque metodológico implementado.

1.6.6. Funcionalidades del Sistema Implementado

El sistema desarrollado incluye capacidades de procesamiento de datos en tiempo cuasi-real, generación automática de clasificaciones de riesgo, y producción de recomendaciones de mantenimiento específicas. Las funcionalidades implementadas abarcan desde la ingesta de datos hasta la presentación de resultados mediante interfaces de usuario especializadas.

El prototipo demostró capacidad para manejar la complejidad dimensional requerida para análisis de calidad energética HVAC, procesando múltiples variables simultáneamente y generando outputs estructurados que facilitan la toma de decisiones operativas.

Los componentes de filtrado y análisis granular implementados en los dashboards permiten la exploración detallada de datos por medidor individual, períodos temporales específicos, y niveles de criticidad, proporcionando flexibilidad para diferentes escenarios de análisis requeridos en la gestión de sistemas HVAC comerciales.

El sistema desarrollado logró la integración funcional entre tecnologías IoT, procesamiento en la nube, machine learning, y visualización de datos, confirmando la viabilidad técnica del enfoque arquitectónico propuesto para aplicaciones de monitoreo energético HVAC.

Marco de referencia

En este capítulo se presentan las bases teóricas y los trabajos previos que sirven como fundamento para la realización del proyecto. Se desarrolla un marco teórico sólido que guía la investigación, incluyendo la definición de conceptos clave y la explicación de las relaciones entre diferentes conceptos. Adicionalmente, se realiza una revisión exhaustiva de la literatura relevante para identificar las brechas en el conocimiento existente que esta investigación pretende llenar.

2.1. Marco Teórico

2.1.1. Eficiencia Energética: Conceptos Fundamentales

La eficiencia energética se ha convertido en un pilar fundamental para el desarrollo sostenible en el siglo XXI, especialmente en el sector comercial, donde el consumo de energía representa una parte significativa de los costos operativos y el impacto ambiental. Según la Agencia Internacional de Energía (IEA), "la eficiencia energética se refiere a la optimización del uso de los recursos energéticos para reducir el consumo y los costos asociados, al tiempo que se minimiza el impacto ambiental" [IEA \(2023\)](#). Esta definición subraya la importancia de implementar estrategias que permitan un uso más racional de la energía, no solo para reducir costos, sino también para mitigar el impacto ambiental asociado al consumo energético.

En el contexto colombiano, la eficiencia energética ha ganado relevancia en los últimos años, impulsada por políticas nacionales y la creciente conciencia sobre la sostenibilidad. El Plan Energético Nacional de Colombia destaca que el sector comercial, público y de servicios representa cerca del 6 % de la demanda energética del país, con un 66,2 % de esta demanda abastecida por energía eléctrica [UPME \(2015\)](#). Esta estadística resalta la importancia de implementar medidas de eficiencia energética en el sector comercial, especialmente en sistemas de alto consumo como los HVAC.

2.1.2. Sistemas HVAC: Fundamentos y Características

Los sistemas de Calefacción, Ventilación y Aire Acondicionado (HVAC, por sus siglas en inglés) son componentes críticos en los edificios comerciales modernos. Estos sistemas son responsables de mantener condiciones ambientales confortables y saludables para los ocupantes, regulando la temperatura, humedad y calidad del aire. Sin embargo, su operación consume una cantidad significativa de energía.

El impacto energético de los sistemas HVAC es considerable. Estudios recientes han revelado que estos sistemas pueden representar aproximadamente el 50 % del consumo energético total en

edificios comerciales. Esta cifra subraya la importancia crítica de optimizar estos sistemas para mejorar la eficiencia energética global de los edificios.

Para comprender mejor cómo los sistemas HVAC afectan el consumo energético, es útil conocer sus componentes principales. Un sistema HVAC típico consta de equipos de producción de calor y frío, como calderas y enfriadores, que son los mayores consumidores de energía. También incluye sistemas de distribución, como ventiladores y bombas, que mueven el aire acondicionado o el agua por el edificio. Las unidades terminales, como radiadores o difusores de aire, transfieren el calor o el frío al espacio ocupado. Todo esto es regulado por sistemas de control que ajustan el funcionamiento de los componentes para mantener las condiciones deseadas.

La eficiencia energética de los sistemas HVAC se ve influenciada por diversos factores. El diseño y dimensionamiento del sistema juegan un papel crucial, al igual que la eficiencia individual de cada equipo. Las estrategias de control implementadas, los patrones de uso y ocupación del edificio, y el mantenimiento regular del sistema también tienen un impacto significativo en el consumo energético [Garces-Jimenez et al. \(2021\)](#).

2.1.2.1. Componentes Mecánicos y Eléctricos del Sistema

Los sistemas HVAC en edificaciones comerciales están constituidos por equipos mecánicos y eléctricos cuyo funcionamiento determina tanto la eficiencia energética como los patrones de consumo eléctrico monitoreables. La comprensión de estos componentes resulta esencial para identificar las variables eléctricas más relevantes para el monitoreo y optimización.

Motores Eléctricos: Los motores constituyen el corazón de los sistemas HVAC y representan los principales consumidores de energía eléctrica. En sistemas comerciales típicos se encuentran:

- **Motores de compresores:** Equipos de alta potencia que presentan los mayores consumos energéticos y cuyo comportamiento eléctrico es indicativo del estado general del sistema.
- **Motores de ventiladores:** Responsables de la circulación del aire, cuyo consumo varía según la resistencia del sistema de distribución y la carga térmica.
- **Motores de bombas:** En sistemas con distribución hidrónica, mantienen la circulación de fluidos y presentan patrones de consumo relacionados con la demanda térmica.

Elementos de Intercambio Térmico: Aunque no consumen energía eléctrica directamente, su estado de conservación y eficiencia afecta el consumo de los motores asociados:

- **Evaporadores:** Su eficiencia determina la carga de trabajo de los compresores.
- **Condensadores:** Su limpieza y funcionamiento impacta directamente en el consumo eléctrico del sistema.
- **Intercambiadores de calor:** Su estado afecta la eficiencia global del sistema.

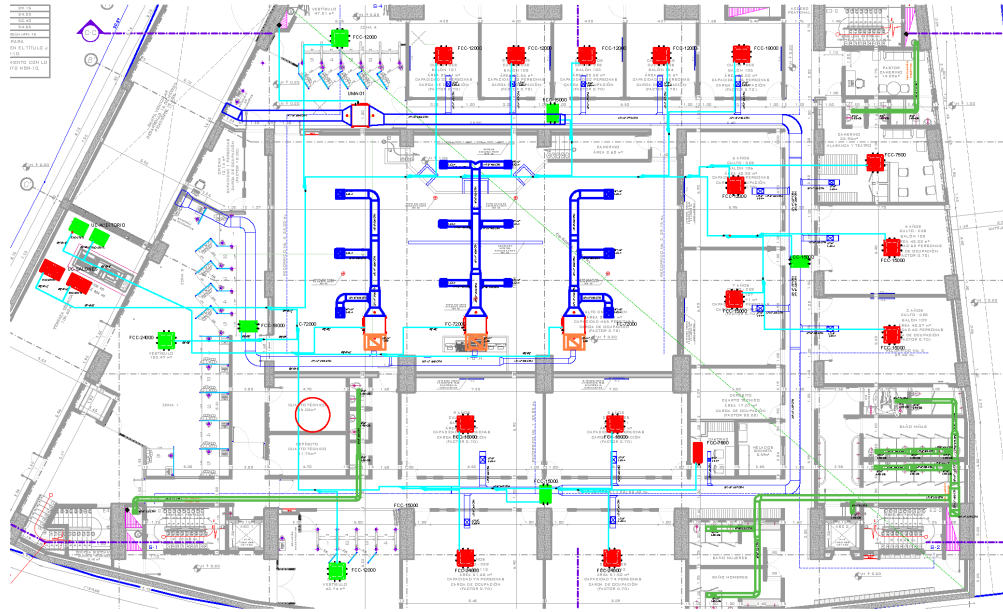


Figura 2.1: Plano general de las rutas de un sistema HVAC

La Figura 2.1 ilustra la distribución de componentes en un sistema HVAC típico, incluyendo sistemas de ventilación, extracción, unidades manejadoras de aire, unidades evaporadoras y condensadoras. Este plano general proporciona una comprensión espacial de la disposición de equipos y sus interrelaciones dentro de un edificio comercial.

2.1.2.2. Diseño Eléctrico de Sistemas HVAC en Edificaciones Comerciales

La comprensión del diseño eléctrico de los sistemas HVAC resulta fundamental para determinar los puntos estratégicos de instalación de medidores inteligentes y establecer las estrategias de monitoreo más efectivas. En edificaciones comerciales, los sistemas HVAC presentan configuraciones eléctricas específicas que determinan tanto su eficiencia operativa como las oportunidades de optimización energética.

Configuración de Tableros Eléctricos: Los sistemas HVAC en edificaciones comerciales se alimentan típicamente desde tableros eléctricos dedicados que centralizan la distribución y protección de múltiples cargas. Esta configuración permite:

- Control centralizado de múltiples equipos HVAC
- Protección individual por circuito mediante interruptores automáticos
- Medición del consumo energético por tablero
- Implementación de sistemas de control horario por zona

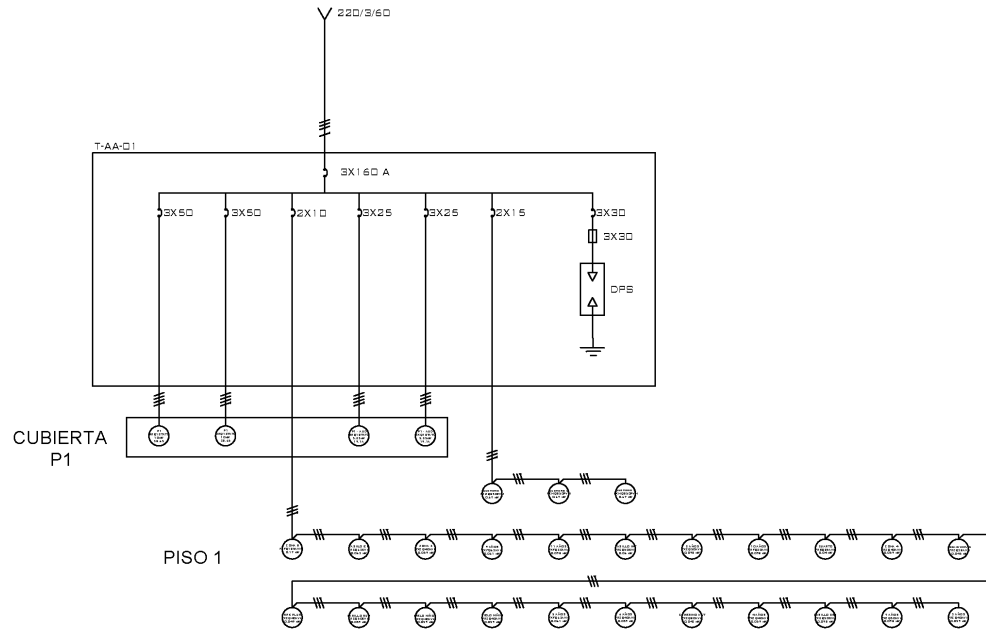


Figura 2.2: Diagrama unifilar de tablero que alimenta una zona

La Figura 2.2 ilustra cómo desde un tablero eléctrico principal se distribuye la energía hacia los distintos equipos HVAC. Este diagrama resulta esencial para comprender la topología eléctrica del sistema y establecer los puntos estratégicos para la instalación de los medidores inteligentes.

Características de las Cargas Eléctricas: Los equipos HVAC presentan características eléctricas particulares que deben ser consideradas en el diseño del sistema de monitoreo:

- **Cargas inductivas predominantes:** Los motores eléctricos constituyen la mayoría de las cargas, presentando factores de potencia que requieren compensación
- **Corrientes de arranque elevadas:** Los motores presentan picos de corriente durante el arranque que pueden ser 3 a 7 veces la corriente nominal
- **Variaciones cíclicas de consumo:** El funcionamiento intermitente de los equipos genera patrones de consumo variables según la demanda térmica

2.1.2.3. Comportamiento Operacional y Degradación del Rendimiento

Un hallazgo relevante es la comprensión del comportamiento operacional de los equipos HVAC a lo largo del tiempo. Inicialmente, un equipo recién instalado opera utilizando aproximadamente el 70 % de su capacidad nominal. Sin embargo, factores como la acumulación de polvo, el desgaste

de componentes mecánicos y el envejecimiento natural de los materiales provocan una degradación progresiva del rendimiento.

Este fenómeno se manifiesta particularmente en componentes como motores, sistemas de rotación y ventiladores. A medida que estos elementos pierden eficiencia, requieren mayor energía para realizar el mismo trabajo, lo que se traduce en un incremento en el consumo de corriente eléctrica.

La variación en el consumo de corriente constituye un indicador importante para el diagnóstico del estado de los equipos, permitiendo implementar estrategias de mantenimiento predictivo mediante el monitoreo continuo de variables eléctricas. Sin embargo, las distorsiones armónicas, particularmente la distorsión armónica total de corriente (THDi), representan variables aún más sensibles para la detección temprana de degradación en sistemas HVAC.

Los sistemas HVAC modernos, especialmente aquellos que implementan variadores de frecuencia (VFDs) para el control de motores, introducen cargas no lineales que generan distorsiones armónicas en la red eléctrica. Estas distorsiones afectan directamente a componentes esenciales como motores, ventiladores y compresores, comprometiendo su funcionamiento, eficiencia y vida útil [ABB \(2018\)](#).

Estudios demuestran que valores elevados de THDi están directamente correlacionados con sobrecalentamiento en componentes, disminución de la eficiencia del sistema y fallos prematuros en equipos HVAC [Wang and Song \(2018\)](#). Este parámetro resulta especialmente sensible en las instalaciones comerciales donde los sistemas operan a cargas variables y con múltiples componentes electrónicos integrados.

2.1.3. Tecnologías IoT y Automatización en Sistemas HVAC

La automatización de sistemas HVAC, potenciada por las tecnologías del *Internet de las Cosas (IoT)*, representa un avance significativo en la búsqueda de soluciones para mejorar la eficiencia energética. Esta integración tecnológica cobra especial relevancia en ciudades en desarrollo como Bogotá, donde el sector comercial experimenta un crecimiento constante y es responsable de una porción significativa del consumo energético urbano.

El IoT, en su esencia, permite la interconexión de dispositivos y sistemas a través de redes de sensores inteligentes. En el ámbito de los sistemas HVAC comerciales, esta interconexión facilita la recopilación y análisis de datos en tiempo real, lo que a su vez posibilita un control y gestión más eficientes de los recursos energéticos. La estructura básica de un sistema IoT aplicado a HVAC consta de tres capas fundamentales: la capa de hardware, la capa de control de software y la capa de aplicación [Yaici et al. \(2023\)](#).

Para el presente proyecto la capa de hardware comprende los medidores de energía inteligentes, que recopilan variables de consumo y calidad de la energía para su posterior análisis. La capa de control de software, por su parte, se encarga de procesar la información obtenida por los medidores de energía, ejecutando algoritmos de control para optimizar el funcionamiento del sistema. Finalmente, la capa de aplicación proporciona interfaces de usuario y herramientas de análisis que permiten la visualización de datos y facilitan la toma de decisiones informadas.

2.1.3.1. Sistemas de Control Avanzado

Los *Modelos Predictivos de Control (MPC)* son una técnica avanzada utilizada en la automatización de HVAC. Estos modelos permiten prever el comportamiento de los sistemas en diferentes condiciones y ajustar su operación para maximizar la eficiencia energética y el confort. Investigaciones recientes han demostrado que el uso de MPC en edificios inteligentes puede reducir considerablemente el consumo energético sin comprometer el bienestar de los ocupantes [Christopoulos et al. \(2024\)](#).

Además, los avances en algoritmos de *aprendizaje por refuerzo* y el uso de redes neuronales optimizadas han abierto nuevas posibilidades para el control de sistemas HVAC en tiempo real. Estos enfoques permiten que los sistemas aprendan de forma continua, ajustándose automáticamente para mejorar la eficiencia con el tiempo [Du et al. \(2023\)](#).

2.1.4. Sistemas de Medición Inteligente (AMI)

La *Infraestructura de Medición Avanzada (AMI, por sus siglas en inglés)* representa un componente fundamental en la modernización de las redes eléctricas y la implementación de sistemas de gestión energética eficientes. AMI se define como un sistema integrado de medidores inteligentes, redes de comunicación y sistemas de gestión de datos que permite un monitoreo detallado y en tiempo real del consumo energético [Sriranjani et al. \(2023\)](#).

En el corazón de la AMI se encuentran los medidores inteligentes, dispositivos capaces de registrar el consumo de energía en intervalos cortos, típicamente cada hora o menos, y transmitir esta información de forma segura a la empresa de servicios públicos al menos una vez al día [Valovcin et al. \(2022\)](#). Estos medidores no solo registran el consumo total de energía, sino que también pueden proporcionar información detallada sobre patrones de uso, calidad de la energía y, en algunos casos, incluso datos sobre la generación de energía en sitio.

La implementación de AMI en edificios comerciales ofrece numerosos beneficios. Proporciona a los administradores de edificios y a los propietarios de negocios acceso a información detallada sobre su consumo de energía, permitiéndoles identificar patrones de uso ineficientes y oportunidades de ahorro [Miller \(2017\)](#). En el caso específico de los sistemas HVAC, AMI puede ser particularmente valioso, ya que los datos granulares permiten un análisis detallado del rendimiento del sistema bajo diferentes condiciones [Yaici et al. \(2023\)](#).

2.1.5. Marco Regulatorio y Normativo

El desarrollo de soluciones de eficiencia energética para sistemas HVAC en el sector comercial de Bogotá está respaldado por un marco regulatorio y normativo que fomenta la innovación y la sostenibilidad. La Ley 1715 de 2014 es fundamental en este aspecto, promoviendo el desarrollo y la utilización de fuentes no convencionales de energía, así como la gestión eficiente de la energía [de Colombia \(2014\)](#).

El Plan Energético Nacional Colombia: Ideario Energético 2050 establece lineamientos específicos para el sector comercial, reconociendo su participación del 6% en la demanda energética na-

cional. Este plan identifica un potencial de ahorro de hasta el 25 % en el consumo de electricidad, con un enfoque particular en sistemas HVAC, donde se estima un potencial de optimización entre el 10 % y el 18 % [UPME \(2015\)](#).

Adicionalmente, estándares internacionales como la ISO 50001 proporcionan un marco de referencia para la implementación de sistemas de gestión de energía efectivos [50001 \(2018\)](#). En el contexto específico de Bogotá, la Secretaría Distrital de Ambiente ha implementado el Programa de Gestión Ambiental Empresarial, que incentiva la adopción de prácticas sostenibles [de Bogotá. \(2024\)](#).

2.2. Estado del Arte

2.2.1. Introducción

La automatización y optimización energética de sistemas HVAC en el sector comercial ha emergido como un campo de investigación crucial en los últimos años, impulsado por la creciente preocupación sobre el cambio climático y la necesidad de reducir los costos operativos en edificios. En el contexto específico de Bogotá, donde el sector comercial representa una parte significativa del consumo energético urbano, la búsqueda de soluciones eficientes y adaptadas a las condiciones locales se ha vuelto particularmente relevante.

El Plan Energético Nacional Colombia: Ideario Energético 2050 ha identificado un potencial de ahorro de hasta el 25 % en el consumo de electricidad en el sector comercial, público y de servicios [UPME \(2015\)](#). Este sector se abastece principalmente de energía eléctrica (66,2 %), gas natural (28,9 %) y GLP (4,8 %). La alta concentración en energía eléctrica se debe en parte a la naturaleza de las actividades en este sector, pero también a factores como la sobreiluminación en grandes superficies comerciales y los crecientes requerimientos de energía para acondicionamiento de espacios y refrigeración.

2.2.2. Avances Recientes en Automatización de HVAC

2.2.2.1. Sistemas de Control Predictivo Basado en Modelos (MPC)

En 2014, Afram y Janabi-Sharifi desarrollaron un sistema MPC para HVAC que demostró una reducción del consumo energético de hasta un 28 % en comparación con los sistemas de control convencionales [Afram and Janabi-Sharifi \(2014\)](#). Su enfoque incorpora predicciones meteorológicas y patrones de ocupación para optimizar la operación del sistema. Las ventajas de este estudio fueron la alta eficiencia energética y la adaptabilidad a diferentes condiciones; sin embargo, presentó desventajas como la complejidad en la implementación y la necesidad de modelos precisos del edificio.

2.2.2.2. Aprendizaje por Refuerzo Profundo para Control HVAC

En 2020 se propuso un sistema de control HVAC basado en aprendizaje por refuerzo profundo que optimiza simultáneamente el confort térmico y el consumo energético [Vázquez-Canteli et al.](#)

(2019). Su solución demostró mejoras de hasta un 20 % en eficiencia energética en comparación con sistemas MPC tradicionales. Las ventajas incluyeron la adaptabilidad mejorada y que no requiere un modelo explícito del edificio, mientras que las desventajas fueron la alta demanda computacional y el largo período de entrenamiento inicial.

2.2.2.3. Integración de IoT y Edge Computing en HVAC

En 2014 se presentó una arquitectura IoT-Edge para la gestión de sistemas HVAC que permite el procesamiento de datos en tiempo real y la toma de decisiones descentralizada Merabet et al. (2014). Su enfoque logró una reducción del 15 % en el consumo energético y mejoró la respuesta del sistema a cambios rápidos en las condiciones ambientales. Las ventajas incluyeron la baja latencia en la toma de decisiones y la escalabilidad mejorada, mientras que las desventajas fueron los costos iniciales de implementación elevados y la complejidad en la gestión de la seguridad de datos.

2.2.3. Soluciones de Medición Inteligente y Análisis de Datos

2.2.3.1. Sistemas AMI Avanzados

En 2019, Ghasempour revisó los avances recientes en sistemas de Infraestructura de Medición Avanzada (AMI), destacando su potencial para la optimización energética en edificios comerciales Ghasempour (2019). Los sistemas AMI modernos permiten una granularidad de datos mucho mayor, facilitando la identificación precisa de patrones de consumo y oportunidades de ahorro. Las ventajas incluyeron la alta precisión en la medición y la facilidad de implementación de tarifas dinámicas, mientras que las desventajas se relacionaron con preocupaciones sobre la privacidad de datos y los altos costos de implementación.

2.2.3.2. Análisis Predictivo para Optimización HVAC

En 2019 se desarrolló un sistema de análisis predictivo que combina datos de AMI con información meteorológica y de ocupación para optimizar la operación de sistemas HVAC Wang et al. (2019). Su enfoque logró una reducción del 22 % en el consumo energético en un estudio de caso en un edificio de oficinas. Las ventajas incluyeron la alta eficiencia energética y la mejora continua a través del aprendizaje automático, mientras que las desventajas fueron la necesidad de grandes volúmenes de datos históricos y la potencial sensibilidad a cambios en los patrones de uso del edificio.

2.2.4. Avances en Tecnologías HVAC

2.2.4.1. Sistemas VRF de Última Generación

En 2021 se analizó el rendimiento de sistemas de Flujo de Refrigerante Variable (VRF) de última generación en edificios comerciales Kamal and Khan (2021). Su estudio demostró que estos sistemas pueden lograr ahorros energéticos de hasta un 40 % en comparación con sistemas HVAC convencionales, especialmente en climas con variaciones significativas de temperatura. Las ventajas

incluyeron la alta eficiencia energética y flexibilidad en la instalación y zonificación, mientras que las desventajas fueron los costos iniciales elevados y la complejidad en el mantenimiento.

2.2.4.2. Integración de Energías Renovables en Sistemas HVAC

En 2016 se propuso un sistema HVAC híbrido que integra energía solar térmica y fotovoltaica con almacenamiento de energía térmica [Cao et al. \(2016\)](#). Su solución demostró una reducción del 60% en el consumo de energía de la red eléctrica en un edificio comercial de tamaño medio. Las ventajas incluyeron la reducción significativa de la dependencia de la red eléctrica y la mejora en la sostenibilidad del edificio, mientras que las desventajas fueron la dependencia de las condiciones climáticas para la generación de energía solar y una alta inversión inicial.

2.2.5. Soluciones Específicas para el Contexto de Bogotá

2.2.5.1. Sistemas de Enfriamiento Pasivo Adaptativo

En 2018 se desarrolló un sistema de enfriamiento pasivo adaptativo para edificios en climas tropicales de altura, similar al de Bogotá [Oropeza-Perez and Østergaard \(2018\)](#). Su enfoque combina ventilación natural controlada con elementos de sombreado dinámicos, logrando una reducción del 35% en la demanda de enfriamiento. Las ventajas incluyeron el bajo consumo energético y el aprovechamiento de condiciones climáticas locales, mientras que las desventajas fueron la eficacia limitada en días extremadamente cálidos y la necesidad de un diseño arquitectónico específico.

2.2.6. Identificación de Brechas y Oportunidades de Investigación

La revisión del estado del arte revela avances significativos en la automatización y optimización energética de sistemas HVAC, con un enfoque creciente en soluciones adaptativas e inteligentes. Las tendencias principales incluyen:

1. La adopción de técnicas de aprendizaje automático y control predictivo para optimizar la operación de HVAC.
2. La integración de tecnologías IoT y edge computing para mejorar la recopilación y análisis de datos en tiempo real.
3. El desarrollo de sistemas HVAC híbridos que combinan tecnologías convencionales con enfoques pasivos y energías renovables.
4. Un interés creciente en el desarrollo de soluciones adaptadas a condiciones climáticas específicas, como el clima de altura predominante en Bogotá.

Sin embargo, se identifican brechas importantes en la investigación y desarrollo que la presente investigación pretende abordar:

1. **Soluciones adaptadas al contexto local:** La necesidad de soluciones más adaptables y costo-efectivas para edificios comerciales existentes en contextos urbanos como Bogotá, considerando factores específicos como altitud, condiciones climáticas y normativas locales.
2. **Estudios longitudinales:** La falta de estudios a largo plazo sobre la eficacia y durabilidad de sistemas HVAC automatizados en climas ecuatoriales de montaña, especialmente en el contexto del sector comercial bogotano.
3. **Marcos regulatorios específicos:** La necesidad de marcos regulatorios y estándares específicos para la implementación de sistemas HVAC altamente automatizados en Colombia, que consideren las particularidades del mercado local.
4. **Integración de medición inteligente con control automatizado:** La carencia de soluciones integrales que combinen efectivamente la medición inteligente de variables eléctricas con sistemas de control automatizado adaptados a las condiciones operativas específicas de sistemas HVAC comerciales en Bogotá.

Estas brechas representan oportunidades significativas que justifican la presente investigación, orientada al desarrollo de un prototipo de arquitectura IoT que integre medición inteligente, análisis predictivo y control automatizado, específicamente adaptado a las condiciones del sector comercial de Bogotá.

2.3. Resumen del capítulo

Este capítulo estableció las bases teóricas y contextuales necesarias para comprender la importancia de la eficiencia energética en sistemas HVAC del sector comercial bogotano. La revisión teórica presentó conceptos fundamentales sobre la eficiencia energética, que constituye un pilar para el desarrollo sostenible actual, con especial relevancia en Colombia donde el sector comercial representa aproximadamente el 6 % de la demanda energética nacional.

Se analizaron los sistemas HVAC desde su estructura y funcionamiento, destacando su considerable impacto en el consumo energético de edificaciones comerciales, donde llegan a representar aproximadamente el 50 % del consumo total. La comprensión de estos sistemas resulta crucial para identificar oportunidades de mejora, ya sea mediante la actualización de equipos o la implementación de estrategias avanzadas de control.

La integración de tecnologías IoT con sistemas HVAC emergió como una evolución natural hacia la gestión eficiente de recursos energéticos. La arquitectura de tres capas (hardware, control de software y aplicación) permite la interconexión inteligente de dispositivos para monitorización, análisis y control en tiempo real, mejorando tanto la eficiencia energética como el confort térmico y la calidad del aire interior.

Los Sistemas de Medición Inteligente (AMI) se perfilaron como componentes fundamentales para la modernización de redes eléctricas y la implementación de sistemas de gestión energética. Su capacidad para proporcionar datos granulares facilita el análisis detallado del rendimiento de

sistemas HVAC, permitiendo ajustes precisos en su operación y la implementación de estrategias avanzadas de gestión de demanda.

El marco regulatorio y normativo en Colombia, con la Ley 1715 de 2014 y el Plan Energético Nacional 2050, proporciona respaldo institucional para el desarrollo de soluciones de eficiencia energética. Las normativas internacionales como ISO 50001 complementan este marco, facilitando la adopción de estándares globales.

La revisión del estado del arte mostró los avances en automatización de HVAC, destacando tecnologías como los Modelos Predictivos de Control (MPC), aprendizaje por refuerzo profundo, integración de IoT con edge computing, sistemas avanzados de medición inteligente y análisis predictivo. También se examinaron innovaciones tecnológicas como los sistemas VRF de última generación y la integración de energías renovables en sistemas HVAC.

El análisis evidenció brechas en la investigación y desarrollo, particularmente en la necesidad de soluciones adaptables y costo-efectivas para el contexto urbano bogotano, la escasez de estudios longitudinales sobre sistemas HVAC automatizados en climas ecuatoriales de montaña, y la necesidad de marcos regulatorios específicos para Colombia. Estas brechas representan oportunidades para la investigación propuesta, que busca desarrollar un prototipo de arquitectura IoT adaptado a las condiciones particulares del sector comercial en Bogotá.

Desarrollo del Proyecto

Este capítulo presenta la ejecución del proyecto para el desarrollo del prototipo de arquitectura IoT orientado a la automatización y optimización energética de sistemas HVAC en el sector comercial de Bogotá. Se describe el proceso llevado a cabo, desde la comprensión del funcionamiento de los sistemas HVAC, la identificación de variables eléctricas clave, el análisis de requisitos, hasta el diseño e implementación de la arquitectura propuesta.

3.1. Etapa de Investigación y Contextualización

3.1.1. Identificación y Parametrización de Variables Eléctricas

A partir del análisis de funcionamiento, se identificaron las variables eléctricas más relevantes para el monitoreo y mantenimiento predictivo. El marco normativo que fundamenta esta parametrización incluye principalmente la NTC 5001-2008 **ICONTEC (2008)**, que establece los límites de calidad de potencia eléctrica y metodología de evaluación en punto de conexión común; la NTC 1340 **ICONTEC (2013)**, que define las tensiones y frecuencias nominales en sistemas de suministro de energía eléctrica; y la Resolución CREG No.082/2002 de la Comisión **de regulación de Energía y Gas (2002)**, que establece el reglamento de distribución de energía eléctrica. Adicionalmente, se consideraron estándares internacionales como la IEEE 519-2014 **IEEE (2014)**, que proporciona directrices específicas para el control de armónicos en sistemas de potencia eléctrica, aspecto fundamental dado que los sistemas HVAC con variadores de frecuencia introducen distorsiones armónicas en la red eléctrica.

Se estableció un voltaje nominal de trabajo de 220V como valor de referencia para el cálculo de umbrales operativos y la detección de anomalías, considerando las características típicas de los sistemas HVAC en edificaciones comerciales de Bogotá. Es importante señalar que este valor de referencia puede variar según cada instalación específica, ya que el voltaje nominal corresponde a valores normalizados (como 220V, 230V, 240V) que dependen de la topología particular de la red eléctrica y las especificaciones del cliente. Los umbrales y criterios establecidos se expresan como porcentajes relativos a este valor nominal, permitiendo su adaptación a diferentes configuraciones de red eléctrica.

Para el desarrollo de modelos de detección de anomalías basados en machine learning, los umbrales de operación normal, advertencia y críticos se establecen como porcentajes relativos a este valor nominal de 220V, permitiendo una detección precisa de desviaciones que podrían indicar problemas potenciales en el sistema. Las principales variables eléctricas seleccionadas para el monitoreo se presentan en la Tabla 3.1, que incluye una parametrización detallada considerando distintos niveles

de umbrales, criterios para detectar anomalías y su impacto en el funcionamiento de los sistemas HVAC para implementar estrategias de mantenimiento preventivo.

Cuadro 3.1: Parametrización de variables eléctricas clave para sistemas HVAC

Variable	Unidad	Umbral normal	Umbral crítico	Criterio de anomalía	Impacto en el sistema HVAC
Tensión fase-fase (L1-L2, L2-L3, L3-L1)	Voltios (V)	220V \pm 5% (209V–231V)	<203V o >237V	Desviación sostenida >5% durante más de 10 min	Funcionamiento errático de controladores; daño en tarjetas; fallos en comunicación
Corriente por fase (L1, L2, L3)	Amperios (A)	70–85% de capacidad máxima	>95% de capacidad máxima	Incremento gradual >5% mensual o desequilibrio >5%	Sobrecalentamiento de conductores; disparo de protecciones; estrés térmico
THDv (Distorsión armónica total de tensión)	Porcentaje (%)	<5%	>7%	Valor promedio >5% durante 12 horas	Interferencia con señales de control; reducción de eficiencia; sobrecalentamiento
THDi (Distorsión armónica total de corriente)	Porcentaje (%)	<23%	>35%	Valor sostenido >35% durante 12 horas	Sobrecalentamiento de cables; disparos inesperados; reducción de vida útil (25%)
Factor de potencia	Adimensional	>0.92	<0.88	Degradación sostenida (>0.01/mes) o valor <0.92 por 72h	Aumento de pérdidas energéticas; penalizaciones de facturación; sobrecalentamiento
Potencia activa	Kilovatios (kW)	<85% de capacidad de diseño	>95% de capacidad de diseño	Incremento sostenido >10% respecto a la línea base	Sobrecalentamiento de conductores; reducción de eficiencia; sobrecarga en refrigeración
Frecuencia	Hz	59.8–60.2 Hz	<59.5 Hz o >60.5 Hz	Variaciones fuera de rango >10 min	Funcionamiento incorrecto de compresores; alteración de tiempos de ciclo

Esta parametrización permitió establecer los umbrales para la detección de anomalías en el sistema de monitoreo. Cada variable fue analizada en términos de su impacto potencial en los equipos HVAC, identificando correlaciones entre patrones anómalos y problemas específicos de funcionamiento.

3.1.2. Interrelación entre Variables de Entrada y Salida

El análisis de variables eléctricas se estructura mediante la diferenciación entre variables de entrada y variables de salida. Las variables de entrada son aquellos parámetros que provienen del diseño específico de la instalación, están documentados en el diagrama unifilar y las especificaciones técnicas de los equipos, y determinan los umbrales operativos normales para cada sistema particular. Entre estas se encuentran la capacidad nominal del tablero, la tensión nominal de diseño, las características técnicas de los equipos conectados y la máxima distorsión armónica admisible establecida por normativas como IEEE 519-2014 [IEEE \(2014\)](#) o NTC 5001-2008 [ICONTEC \(2008\)](#).

Por otro lado, las variables de salida son aquellas que se miden continuamente, se comparan contra los umbrales predefinidos y se analizan para detectar anomalías. Estas representan el estado operativo real del sistema y constituyen la base para el desarrollo de modelos de detección de anomalías basados en machine learning.

3.1.3. Variables Eléctricas Monitoreadas

Tensión fase-fase (L1-L2, L2-L3, L3-L1): La tensión es uno de los parámetros fundamentales para evaluar la calidad del suministro eléctrico y su impacto en el funcionamiento de los sistemas HVAC. La Resolución CREG No.082/2002 Comisión de regulación de Energía y Gas (2002), establece que las tensiones en estado estacionario no podrán ser inferiores al 95 % de la tensión nominal ni superiores al 110 % durante un período superior a un minuto. Este rango coincide con lo establecido en la NTC 1340 [ICONTEC \(2013\)](#), que fija la variación permisible entre -5 % y +10 % de la tensión nominal declarada.

Las desviaciones sostenidas de tensión fuera de estos rangos pueden provocar múltiples efectos adversos en los motores de sistemas HVAC: valores por debajo del umbral mínimo ocasionan sobrecalentamiento en motores y reducción del par de arranque, mientras que valores por encima del umbral máximo pueden generar estrés en el aislamiento eléctrico y reducir considerablemente la vida útil de componentes electrónicos.

Corriente por fase (L1, L2, L3): Las corrientes de fase en sistemas HVAC comerciales presentan comportamientos característicos que reflejan los ciclos de operación de compresores, ventiladores y otros componentes motorizados. Los sistemas HVAC típicamente operan entre el 70 % y 85 % de su capacidad nominal en condiciones óptimas [Balbis-Morejón et al. \(2021\)](#).

El monitoreo de corrientes permite detectar diversos tipos de anomalías en motores. Un incremento gradual en el consumo de corriente bajo condiciones similares de carga térmica es un indicador temprano de pérdida de eficiencia, frecuentemente asociado a problemas como restricciones en el flujo de refrigerante, obstrucciones en filtros de aire o deterioro de rodamientos en motores.

THDi (Distorsión armónica total de corriente): La distorsión armónica total en corriente (THDi) representa la variable de mayor relevancia para el desarrollo de modelos predictivos en sistemas HVAC modernos, debido a su alta sensibilidad a los cambios en el estado operativo de los motores y la proliferación de cargas no lineales como variadores de frecuencia. Según la norma NTC 5001-2008 [ICONTEC \(2008\)](#), el valor máximo permisible de THDi es del 35 %, aunque este límite debe interpretarse considerando las características específicas de la instalación.

Los sistemas HVAC modernos, particularmente aquellos que implementan variadores de frecuencia para el control de motores, introducen cargas no lineales que generan distorsiones armónicas en la red eléctrica. Estas distorsiones afectan directamente a los motores, comprometiendo su funcionamiento, eficiencia y vida útil [Wang and Song \(2018\)](#). La presencia de niveles elevados de THDi no solo afecta la calidad de la energía, sino que también provoca efectos térmicos adicionales en conductores y transformadores, pudiendo incrementar las pérdidas por efecto Joule entre un 10 % y un 15 % [ABB \(2018\)](#).

La THDi se posiciona como la variable objetivo principal para el desarrollo de modelos de detección de anomalías, debido a su capacidad para reflejar de manera temprana la degradación en el estado operativo de los motores que constituyen el núcleo de los sistemas HVAC.

THDv (Distorsión armónica total de tensión): La distorsión armónica total en tensión (THDv) cuantifica la deformación de la onda de tensión respecto a la forma sinusoidal ideal. La norma NTC 5001-2008

ICONTEC (2008), alineada con los estándares internacionales, establece que el THDv no debe superar el 5% para sistemas con tensiones inferiores a 69 kV. Los componentes armónicos en tensión superiores al 5% se consideran críticos según la normativa colombiana y pueden reducir la eficiencia energética de los sistemas HVAC entre un 1% y 3% por cada 5% de incremento ABB (2018).

Factor de potencia: Este parámetro adimensional cuantifica la eficiencia con que el sistema utiliza la energía eléctrica que consume. En sistemas HVAC, caracterizados por cargas mixtas (inductivas, capacitivas y no lineales), el factor de potencia constituye un indicador integral de calidad operativa. Valores inferiores a 0.92 indican ineficiencia energética y pueden señalar deterioro en capacitores de compensación, problemas en motores o excesiva presencia de cargas no lineales.

Potencia activa: Representa la energía eléctrica efectivamente transformada en trabajo mecánico por los motores del sistema HVAC. Su monitorización permite establecer patrones de consumo y detectar anomalías en la eficiencia de conversión energética. Incrementos sostenidos en la potencia activa bajo condiciones ambientales constantes pueden indicar obstrucciones en sistemas de ventilación, deterioro en sistemas de transmisión mecánica de motores o ineficiencias en intercambiadores térmicos.

Frecuencia: La frecuencia determina la velocidad rotacional de motores síncronos y afecta directamente el rendimiento de compresores en sistemas de refrigeración. Variaciones significativas respecto al valor nominal (60 Hz en el contexto colombiano) provocan alteraciones en la velocidad de rotación de los motores, comprometiendo su eficiencia termodinámica y potencialmente generando sobrecalentamiento.

El análisis reveló que la calidad de la energía eléctrica constituye un factor determinante para el rendimiento y la vida útil de los motores en sistemas HVAC. Particularmente, las distorsiones armónicas de corriente representan una problemática relevante, pues generan efectos adversos como sobrecalentamiento de motores, interferencia con sistemas de control y reducción de la eficiencia energética IEEE (2014). La efectividad del sistema de detección de anomalías radica en el análisis contextualizado de las variables monitoreadas con respecto a los parámetros de diseño específicos de cada instalación, permitiendo desarrollar algoritmos más precisos y reducir falsos positivos en la detección temprana de problemas en motores de sistemas HVAC.

3.2. Recolección de Datos

3.2.1. Procedimiento de Recolección de Datos

La recolección de datos para el desarrollo del modelo de detección de anomalías se realizó dividiendo en dos fases: una primera fase de monitoreo real en un establecimiento comercial para la comprensión del comportamiento de variables eléctricas en sistemas HVAC, y una segunda fase de simulación controlada para la generación de datos necesarios para el entrenamiento de modelos predictivos.

3.2.1.1. Fase 1: Monitoreo Real en Entorno Hospitalario

Contexto del Proyecto de Monitoreo Una empresa prestadora de servicios de climatización y refrigeración en la ciudad de Bogotá autorizó la instalación de equipos de medición especializados para el monitoreo de variables de calidad de energía durante un período de una semana. Esta colaboración surgió de la necesidad conjunta de investigar problemas operativos específicos en sistemas HVAC y del interés académico de desarrollar metodologías de detección predictiva de anomalías para el presente proyecto de maestría. Por razones de confidencialidad contractual, no es posible revelar la identidad específica de las instalaciones donde se llevó a cabo el estudio; sin embargo, se puede indicar que corresponde a una clínica especializada con sistemas HVAC de alta capacidad operativa.

El sistema de climatización objeto de estudio presentaba fallas recurrentes en componentes críticos, específicamente en tarjetas electrónicas y motores de ventiladores pertenecientes a unidades HVAC con referencias AM140MXVAF

y AM240MXVAFc del fabricante Samsung, que operan a un voltaje de 220V en configuración fase-fase. Estas unidades están conectadas al tablero eléctrico identificado como TA-01A, dedicado exclusivamente al sistema HVAC de una zona específica de las instalaciones hospitalarias.

Configuración del Monitoreo Real

Período de Instalación: El sistema de medición se instaló en el tablero TA-01A y estuvo en funcionamiento continuo desde el 31 de marzo hasta el 5 de abril de 2025, obteniendo datos durante cinco días consecutivos para obtener una muestra representativa del comportamiento de la red eléctrica en condiciones operativas reales.

Frecuencia de Muestreo: Se configuró el equipo para registrar datos cada 15 minutos. Este intervalo fue seleccionado para equilibrar la frecuencia de registro con la capacidad de almacenamiento y procesamiento de datos, asegurando la captura de variaciones significativas en la calidad de energía sin saturar el sistema de almacenamiento.

Variables Monitoreadas: El sistema registró continuamente 40 variables eléctricas identificadas como críticas para la detección de anomalías en motores de sistemas HVAC. Las principales variables monitoreadas fueron:

- **Corrientes por fase:** `data_current_l1`, `data_current_l2`, `data_current_l3`
- **Tensiones fase-fase:** `data_voltage_l12`, `data_voltage_l23`, `data_voltage_l31`
- **Distorsión armónica total de tensión:** `data_vthd_l1`, `data_vthd_l2`, `data_vthd_l3`
- **Distorsión armónica total de corriente:** `data_athd_l1`, `data_athd_l2`, `data_athd_l3`
- **Potencia activa:** `data_active_power_iii`, `data_active_power_l1-l3`

Infraestructura de Medición: Para la recolección de datos se implementó una infraestructura basada en medidores inteligentes especializados desarrollados por la empresa colaboradora. El sistema genera información a través de unidades de medida que actúan como traductores de información analógica hacia formato digital, transmitiendo los datos mediante comunicación RF a una unidad concentradora que opera como puerta de enlace y almacenamiento local.

Resultados del Monitoreo Real: Durante el período de monitoreo se obtuvieron 485 muestras para cada una de las 40 variables monitoreadas, totalizando 19,400 puntos de datos. El análisis de calidad de energía reveló condiciones operativas que excedían los límites normativos establecidos, particularmente en términos de distorsión armónica total de corriente (THDi), que presentó valores superiores al 28 %, excediendo el límite recomendado del 8 % según la norma NTC 5001-2008.

Limitaciones del Monitoreo Real A pesar de que el estudio real proporcionó información valiosa sobre el comportamiento de variables eléctricas en sistemas HVAC comerciales y permitió identificar problemas reales de calidad de energía, se identificaron limitaciones importantes para el desarrollo de modelos de detección de anomalías:

- **Frecuencia de muestreo elevada:** El intervalo de 15 minutos, aunque apropiado para el análisis de calidad de energía, resultaba excesivamente frecuente para las necesidades operativas de un negocio comercial típico.
- **Ausencia de datos etiquetados:** Los datos recopilados correspondían principalmente a condiciones de operación normal, sin la presencia de eventos anómalos claramente definidos y etiquetados necesarios para el entrenamiento de modelos de clasificación.
- **Alcance limitado:** El monitoreo se limitó a un único punto de medición, lo que no permitía evaluar el comportamiento del sistema en múltiples ubicaciones o bajo diferentes condiciones de carga.

3.2.2. Fase 2: Generación de Datos de Simulación

3.2.2.1. Justificación de la Simulación

Considerando las limitaciones identificadas en el monitoreo real y los objetivos específicos del proyecto, se decidió desarrollar un conjunto de datos de simulación que aprovechara los patrones y características identificados durante el monitoreo real, pero que incluyera tanto condiciones normales como anómalas de operación. Esta decisión se fundamentó en la necesidad de contar con datos que permitieran el entrenamiento efectivo de modelos de detección de anomalías.

3.2.2.2. Selección de la Variable Objetivo

A partir del análisis de los datos reales y la revisión de literatura especializada, se seleccionó la distorsión armónica total de corriente (THDi) como variable objetivo principal para el desarrollo del modelo de clasificación. Esta selección se justifica por las siguientes razones:

- **Sensibilidad a anomalías:** La THDi demostró ser altamente sensible a cambios en el estado operativo de los motores y sistemas electrónicos presentes en los sistemas HVAC.
- **Impacto en la vida útil:** Valores elevados de THDi están directamente correlacionados con sobrecalentamiento en componentes, disminución de la eficiencia del sistema y fallos prematuros en equipos HVAC.
- **Detectabilidad temprana:** La THDi permite la identificación temprana de problemas en variadores de frecuencia y motores antes de que se manifiesten como fallas críticas.

3.2.2.3. Características de la Simulación

Estructura de Medición Simulada: Se diseñó una simulación que representa un entorno comercial típico con múltiples puntos de medición distribuidos. La simulación contempló 10 unidades de medida independientes identificadas como: MP9991, MP9992, MP9993, MP9994, MP9995, MP9996, MP9997, MP9998, MP9999, y MP99910. Cada unidad representa un tablero eléctrico diferente, simulando la configuración típica de un edificio comercial de 10 pisos o zonas donde cada piso cuenta con su propio sistema HVAC controlado por un tablero.

Variables Simuladas: Se mantuvieron las 40 variables identificadas durante el monitoreo real, conservando sus características estadísticas, rangos de operación y correlaciones observadas. Esto aseguró que los datos simulados mantuvieran la validez y representatividad del comportamiento real de sistemas HVAC comerciales.

Período y Frecuencia de Simulación: La simulación abarcó un período desde el 31 de marzo hasta el 6 de abril, con un intervalo de muestreo de 6 horas. Esta frecuencia de muestreo se ajustó a las necesidades operativas reales de un negocio comercial, donde el monitoreo continuo a intervalos de 6 horas proporciona información suficiente para la detección temprana de anomalías.

Volumen de Datos Generado: La simulación produjo un total de 240 muestras por variable. Considerando las 10 unidades de medida simuladas, se obtuvo un conjunto de datos total de 9,600 registros, proporcionando una base suficiente para el entrenamiento y validación de modelos de detección de anomalías.

3.2.2.4. Generación de Condiciones Normales y Anómalas

Condiciones Normales: Se generaron datos que reflejan el comportamiento típico de sistemas HVAC operando dentro de parámetros normales, basándose en los patrones estadísticos identificados durante el monitoreo real. Estos datos representan aproximadamente el 70 % del conjunto total de datos simulados.

Condiciones Anómalas: Se introdujeron deliberadamente anomalías en las variables, particularmente en la THDi, para simular condiciones que podrían indicar problemas potenciales en el sistema. Las anomalías se generaron considerando:

- **Anomalías graduales:** Incrementos progresivos en la THDi que simulan el deterioro gradual de componentes.
- **Anomalías abruptas:** Cambios súbitos en los valores que podrían indicar fallas inmediatas o condiciones críticas.
- **Anomalías correlacionadas:** Alteraciones simultáneas en múltiples variables que reflejan problemas sistémicos.

3.2.2.5. Validación de la Simulación

La validez de los datos simulados se verificó mediante la comparación de sus características estadísticas con los datos reales obtenidos durante el monitoreo. Se validaron aspectos como distribuciones de probabilidad, correlaciones entre variables, y rangos de operación, asegurando que la simulación mantuviera la fidelidad necesaria para representar condiciones operativas reales de sistemas HVAC comerciales.

3.2.3. Procesamiento y Preparación de Datos

Una vez completadas ambas fases de recolección, los datos fueron procesados y estructurados en formato JSON para su integración con la arquitectura de análisis propuesta. El procesamiento incluyó la normalización de formatos, la validación de consistencia, y la generación de metadatos necesarios para el entrenamiento de modelos de detección de anomalías.

3.3. Análisis de Requisitos

3.3.1. Requisitos Funcionales y No Funcionales

A partir del análisis del contexto y la comprensión del problema de ineficiencia energética en sistemas HVAC comerciales, se establecieron requisitos funcionales y no funcionales para el diseño de la arquitectura del sistema. Estos requisitos se fundamentaron en la necesidad de desarrollar una arquitectura que permita el monitoreo y análisis de sistemas de climatización mediante tecnologías IoT. Los requisitos se organizaron en tres categorías principales:

Categoría	Tipo	ID	Nombre	Prioridad	Descripción
Captura y Almacenamiento de Datos	F	CAD-01	Captura de datos HVAC	Alta	La arquitectura debe permitir la captura de datos operativos de sistemas HVAC.
Captura y Almacenamiento de Datos	F	CAD-02	Almacenamiento histórico	Alta	Debe almacenar información histórica para análisis temporal.
Captura y Almacenamiento de Datos	F	CAD-03	Manejo multi-punto	Media	Debe manejar datos provenientes de múltiples puntos de medición.
Captura y Almacenamiento de Datos	F	CAD-04	Procesamiento continuo	Alta	Debe procesar flujos de datos de manera continua.

Categoría	Tipo	ID	Nombre	Prioridad	Descripción
Captura y Almacenamiento de Datos	F	CAD-05	Integridad de datos	Alta	Debe mantener la integridad de los datos durante la captura y almacenamiento.
Captura y Almacenamiento de Datos	NF	CAD-06	Escalabilidad	Alta	La arquitectura debe ser escalable para diferentes tamaños de instalación.
Captura y Almacenamiento de Datos	NF	CAD-07	Disponibilidad	Alta	Debe garantizar la disponibilidad y persistencia de los datos.
Captura y Almacenamiento de Datos	NF	CAD-08	Tecnologías confiables	Media	Debe utilizar tecnologías confiables para el almacenamiento.
Captura y Almacenamiento de Datos	NF	CAD-09	Consistencia	Alta	Debe asegurar la integridad y consistencia de la información.
Procesamiento y Análisis	F	PA-01	Identificación de patrones	Alta	La arquitectura debe soportar el análisis de datos para identificar patrones operativos.
Procesamiento y Análisis	F	PA-02	Detección de anomalías	Alta	Debe permitir la detección de condiciones anómalas en sistemas HVAC.
Procesamiento y Análisis	F	PA-03	Generación de información	Media	Debe generar información procesada útil para la gestión operativa.
Procesamiento y Análisis	F	PA-04	Clasificación de estados	Media	Debe clasificar estados operativos de equipos monitoreados.
Procesamiento y Análisis	F	PA-05	Análisis predictivo	Media	Debe proporcionar capacidades de análisis predictivo.
Procesamiento y Análisis	F	PA-06	Métricas energéticas	Media	Debe evaluar métricas de desempeño energético.
Procesamiento y Análisis	NF	PA-07	Eficiencia	Alta	La arquitectura debe procesar datos de manera eficiente.
Procesamiento y Análisis	NF	PA-08	Precisión	Alta	Debe proporcionar resultados precisos y reproducibles.
Procesamiento y Análisis	NF	PA-09	Manejo de volúmenes	Media	Debe manejar volúmenes apropiados de datos para análisis.
Procesamiento y Análisis	NF	PA-10	Tiempo de respuesta	Media	Debe completar procesamientos en tiempos razonables.

Categoría	Tipo	ID	Nombre	Prioridad	Descripción
Distribución y Acceso a Resultados	F	DAR-01	Distribución de resultados	Alta	La arquitectura debe distribuir resultados procesados a componentes de visualización.
Distribución y Acceso a Resultados	F	DAR-02	Acceso histórico	Media	Debe proporcionar acceso a datos históricos y análisis realizados.
Distribución y Acceso a Resultados	F	DAR-03	Consultas flexibles	Media	Debe permitir la consulta de información según diferentes criterios.
Distribución y Acceso a Resultados	F	DAR-04	Generación de alertas	Alta	Debe generar alertas cuando se detecten condiciones problemáticas.
Distribución y Acceso a Resultados	F	DAR-05	Exportación de datos	Baja	Debe facilitar la exportación de datos procesados.
Distribución y Acceso a Resultados	NF	DAR-06	Acceso confiable	Alta	La arquitectura debe proporcionar acceso confiable a los resultados.
Distribución y Acceso a Resultados	NF	DAR-07	Compatibilidad	Media	Debe ser compatible con diferentes tecnologías de visualización.
Distribución y Acceso a Resultados	NF	DAR-08	Actualización automática	Media	Debe actualizar resultados automáticamente según nuevos análisis.
Distribución y Acceso a Resultados	NF	DAR-09	Acceso concurrente	Media	Debe soportar acceso concurrente a la información.
Generales	NF	GEN-01	Modularidad	Alta	La arquitectura debe ser modular para permitir futuras expansiones.
Generales	NF	GEN-02	Aplicabilidad comercial	Alta	Debe ser aplicable a instalaciones comerciales con sistemas HVAC.
Generales	NF	GEN-03	Estándares técnicos	Media	Debe fundamentarse en estándares técnicos del sector.
Generales	NF	GEN-04	Bajo acoplamiento	Media	Debe minimizar dependencias entre componentes.
Generales	NF	GEN-05	Implementabilidad	Alta	Debe ser implementable utilizando tecnologías disponibles.

Cuadro 3.2: Requisitos funcionales y no funcionales de la arquitectura

3.4. Diseño de la Arquitectura

3.4.1. Visión General de la Arquitectura

La arquitectura diseñada para el sistema corresponde a un enfoque distribuido para el monitoreo, análisis y control de sistemas HVAC, utilizando tecnologías IoT y procesamiento en la nube. El diseño sigue un modelo de múltiples capas que permite la captura, transmisión, procesamiento y análisis de datos relacionados con el consumo energético y la calidad de la energía.

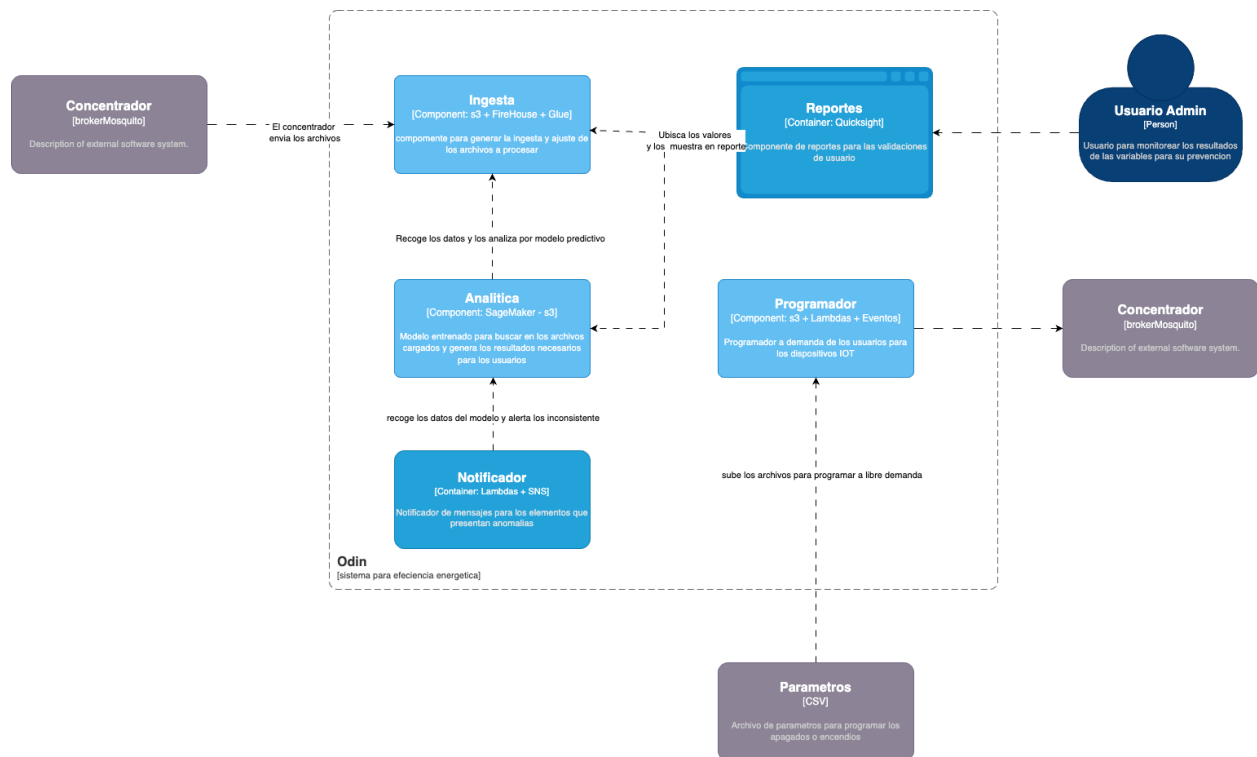


Figura 3.1: Diagrama de contexto.

La figura presenta la arquitectura general del sistema, mostrando los distintos módulos y sus interrelaciones. Esta arquitectura fue diseñada para proporcionar una solución completa que abarca desde la captura de datos hasta la toma de decisiones automatizadas.

3.4.2. Componentes de la Arquitectura

La arquitectura está compuesta por varios módulos interconectados, cada uno con funciones específicas:

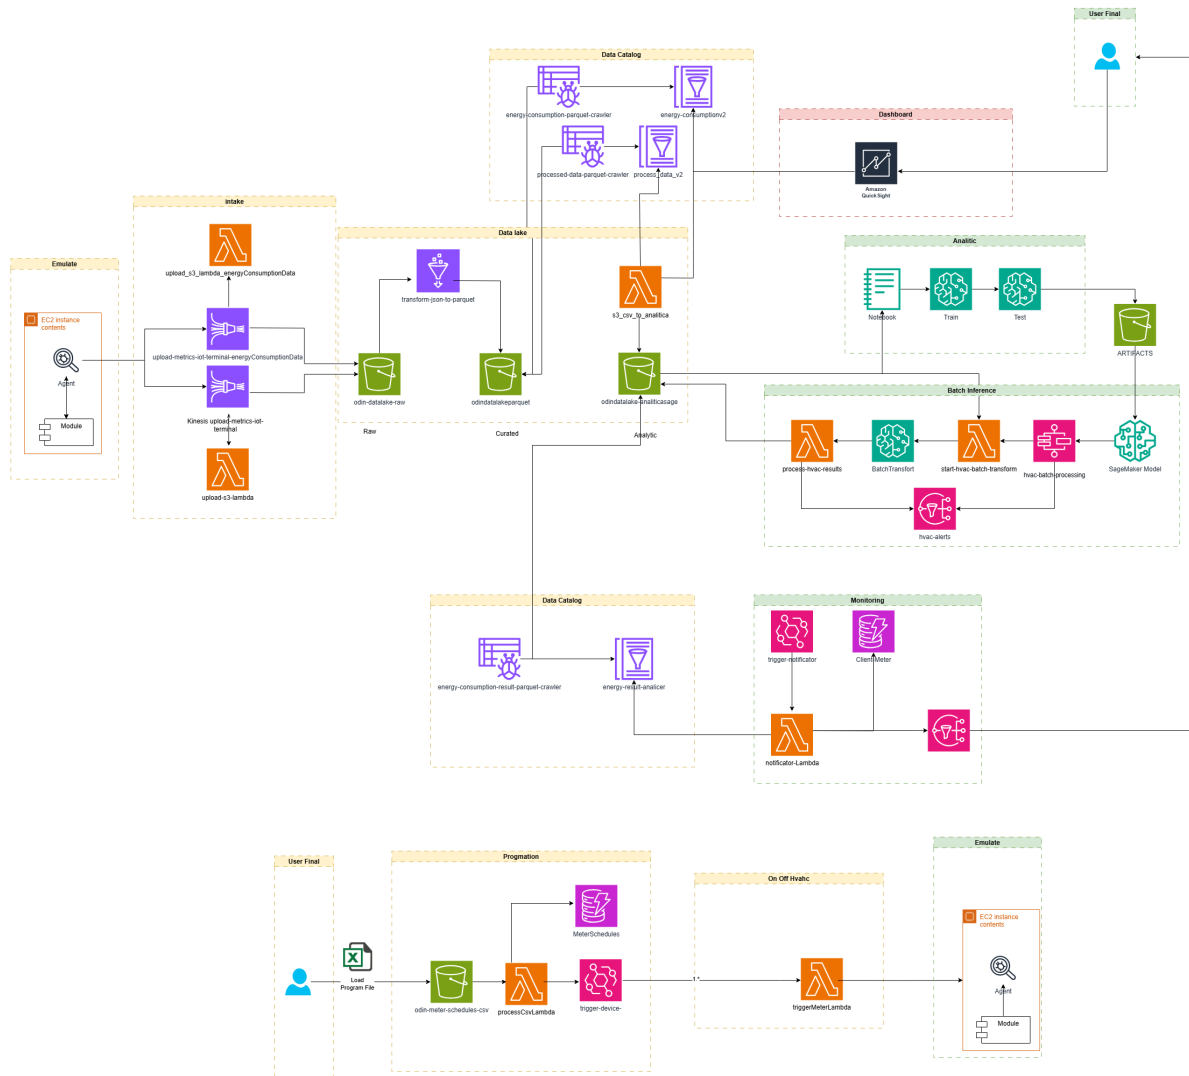


Figura 3.2: Arquitectura general del sistema.

3.4.2.1. Módulo Emulate

Este módulo representa el punto de entrada de datos al sistema, donde se genera la información desde los dispositivos de campo conectados a los sistemas HVAC. Contiene dos componentes principales: un Agent y un "Module". El Agent es configurado con un rol específico (Client o Secret) que determina sus permisos dentro del sistema, garantizando la seguridad y la integridad de los datos transmitidos.

Este módulo representa el punto de entrada de datos al sistema, donde se genera la información desde los dispositivos de campo conectados a los sistemas HVAC. Contiene dos componentes principales: un Agent y un "Module". El Agent es configurado con un rol específico (Client o Secret) que determina sus permisos dentro del sistema, garantizando la seguridad y la integridad de los datos transmitidos. Los datos generados en este módulo representan mediciones reales de los sistemas HVAC, incluyendo variables de consumo y de calidad de energía, en

total 40 variables electricas. Estos datos son estructurados en formato JSON y etiquetados con metadatos como identificadores de dispositivos, marcas temporales y comandos específicos.

3.4.2.2. Módulo Intake

Esta sección de la arquitectura es responsable de la recepción inicial y distribución de los datos entrantes. Incluye componentes clave como:

- **Upload-S3-Lambda:** Implementada en Python, esta función Lambda actúa como un mecanismo de copia y distribución, recibiendo los datos transmitidos desde los dispositivos de campo y ayudando a firehose a las transformaciones necesarias del mismo.
- **Kinesis Firehose Dual:** La arquitectura implementa dos instancias separadas de Kinesis Firehose, cada una dedicada a un tipo específico de datos. Una instancia maneja los datos de consumo energético (consumption data), que incluyen variables como potencia activa y energía consumida, útiles para procesos operativos como facturación y gestión de demanda energética. La segunda instancia procesa la información relacionada con la calidad de la energía (power quality), que comprende variables críticas como THDi, THDv, armónicos individuales y factores de desequilibrio, fundamentales para la detección temprana de anomalías y el mantenimiento predictivo de sistemas HVAC, constituyendo el núcleo del presente estudio de investigación.

3.4.2.3. Almacenamiento de Datos (Raw, Curated, Analytics)

La arquitectura implementa una estrategia de almacenamiento en capas que facilita diferentes niveles de procesamiento y acceso a los datos:

- **Data-raw-S3:** Almacena los datos en su formato original tal como fueron recibidos del sistema HVAC. Este repositorio sirve como respaldo primario y fuente de verdad para todos los datos capturados.
- **Data-cur-parquet:** Contiene datos que han sido procesados inicialmente y convertidos al formato Parquet, optimizando el almacenamiento y mejorando la eficiencia de las consultas analíticas posteriores.
- **Data-dw-Analytics:** Representa una capa de datos optimizada para análisis avanzados, incluyendo agregaciones, correlaciones y otros modelos analíticos derivados de los datos originales.

3.4.2.4. Catálogo de Datos y Análisis

Esta sección facilita el descubrimiento, acceso y análisis de los datos almacenados:

- **Crawler:** Componente que escanea periódicamente los repositorios de datos para identificar y catalogar la estructura y el contenido de los datos almacenados.
- **Catalogs - Athena:** Proporciona capacidades de indexación que aceleran las consultas sobre los datos almacenados.
- **s3-csv-to-analitica** (segunda instancia): Facilita la transferencia y distribución de datos procesados hacia componentes analíticos.

3.4.2.5. Módulos de Aprendizaje Automático y Procesamiento Analítico

La arquitectura integra componentes para el desarrollo, entrenamiento y operación de modelos de machine learning, organizados en dos módulos que abordan las fases de desarrollo y producción del ciclo de vida del aprendizaje automático aplicado a la detección de anomalías en sistemas HVAC:

Módulo Analytics:

El módulo Analytics constituye la fase de desarrollo y entrenamiento del sistema de machine learning, con la función principal de crear, validar y optimizar el modelo predictivo para la detección de anomalías en sistemas HVAC.

- **Notebook:** Proporcionó un entorno interactivo de desarrollo donde se realizó la exploración y experimentación de datos. Este componente facilitó el análisis exploratorio de las variables eléctricas, la ingeniería de características específicas para sistemas HVAC, y la prototipación de algoritmos de detección de anomalías mediante un entorno colaborativo y flexible basado en SageMaker Notebook Instance.
- **Train:** Componente dedicado al entrenamiento formal del modelo de machine learning mediante SageMaker Training Job. Este elemento toma los datos preprocesados de las 40 variables eléctricas monitoreadas y ejecuta algoritmos de aprendizaje automático para generar el modelo predictivo, optimizando los parámetros del modelo utilizando los datos históricos de sistemas HVAC reales y simulados.
- **Test:** Se encarga de la evaluación y validación del modelo entrenado mediante procesos de Model Validation. Este componente verifica la calidad predictiva del modelo utilizando datos no vistos durante el entrenamiento, asegurando que el modelo generalice correctamente a nuevos datos de sistemas HVAC y mantenga precisión en la detección de anomalías.
- **Artifacts:** Almacena y gestiona modelos entrenados, algoritmos y otros artefactos generados durante el proceso de desarrollo. Una vez validado satisfactoriamente, el modelo se almacena en este repositorio para su uso posterior en producción.

Módulo Batch Inference:

El módulo Batch Inference implementa la fase operacional del sistema, donde el modelo entrenado se aplica a nuevos datos para generar predicciones en tiempo de producción, procesando grandes volúmenes de datos de manera eficiente y automatizada.

- **SageMaker Model:** Representa la instancia desplegada del modelo entrenado que actúa como endpoint para realizar inferencias. Este componente encapsula el modelo predictivo y proporciona la interfaz necesaria para recibir datos de sistemas HVAC y devolver predicciones sobre posibles anomalías.
- **Step Functions (hvac-batch-processing):** Actúa como el orquestador central del flujo de procesamiento batch, coordinando la secuencia de operaciones, manejando las transiciones entre estados, y garantizando la ejecución correcta del pipeline completo, incluyendo el manejo de errores y reintentos en el procesamiento de datos HVAC.
- **start-hvac-batch-transform (Lambda1):** Responsable del preprocesamiento y acondicionamiento de los datos de entrada. Este componente transforma los datos brutos de las variables eléctricas en el formato específico requerido por el modelo, realiza validaciones de calidad, y configura los parámetros necesarios para la inferencia batch.
- **SageMaker Batch Transform:** Ejecuta las inferencias del modelo de manera masiva y paralela, aplicando el modelo predictivo a grandes conjuntos de datos de sistemas HVAC de forma eficiente, optimizando el uso de recursos computacionales para el procesamiento de lotes.
- **process-hvac-results (Lambda2):** Se encarga del postprocesamiento de los resultados de inferencia. Este componente interpreta las salidas del modelo, las transforma en formatos consumibles por sistemas downstream, y genera los archivos de salida estructurados para visualización y análisis de anomalías detectadas.
- **SNS (hvac-alerts):** Proporciona el sistema de notificaciones y alertas, comunicando los resultados del procesamiento a los stakeholders relevantes, incluyendo alertas sobre anomalías detectadas en sistemas HVAC y notificaciones sobre la finalización exitosa o fallida del proceso.

3.4.2.6. Módulos de Monitoreo y Notificación

- **EventBridge:** se ejecuta 2 veces al día 11 AM y 5 PM, el cual despierta el procesamiento para validar las anomalías presentadas por el modelo.
- **Dynamo:** contiene las parametrizaciones necesarias para conocer los meter id con sus respectivos correos de despacho

- **Lambda Notificadora:** Es la unidad de procesamiento que interactúa con los elementos anteriores, y con los catálogos generados por el modelo de predicción, el cual al detectar un valor crítico por el modelo despacha el mensaje al componente de notificación
- **Notificador SNS:** Es el encargado de notificar por correo lo necesario para el monitoreo.

3.4.2.7. Interfaces de Usuario

- **User Final:** Interfaz principal para operadores y administradores del sistema.
- **Dashboard:** Visualizaciones interactivas que presentan métricas clave, tendencias y alertas.

3.4.2.8. Programación y Automatización

- **Load Program File:** Archivo CSV que contiene data necesaria para el apagado o prendido de las unidades HVAC matriculadas en el sistema.
- **S3-Schedules:** contiene los filesystem cargados para las programaciones y es el encargado de enviar el trigger para que la unidad de proceso inicie su labor.
- **Lambda Process:** su función principal es generar los eventos necesarios por cada registro on y off adicional a esto registra en dynamo todos los eventos generado para su seguimiento
- **dynamo:** su función es almacenar datos para posteriores consultas de los on y off realizados durante el tiempo de ejecución
- **Event:** sistema donde se tienen todos los eventos ya programados para consumir las unidades de procesamiento.

3.4.2.9. Interfaces de Salida (On-Off)

- **On-Off Lambda:** Proporciona capacidad de control directo sobre componentes de los sistemas HVAC.

3.4.3. Flujo de Datos en la Arquitectura

El flujo de datos a través de la arquitectura siguió un patrón lógico que integró tanto el procesamiento general del sistema como los flujos específicos de los módulos de aprendizaje automático:

1. Los datos fueron generados por los sistemas de monitoreo conectados a los tableros de control HVAC, estructurados en formato JSON con distinción clara entre datos de consumo y datos de calidad de energía.
2. Estos datos fueron transmitidos al módulo Intake, donde la función Lambda los recibió y distribuyó a través de los canales Kinesis Firehose específicos para cada tipo de datos.
3. Los datos fluyeron hacia el almacenamiento en capas, comenzando con el repositorio raw, pasando por procesos de transformación y optimización en el nivel curated, y finalmente siendo enriquecidos en la capa analytics.
4. Los datos almacenados fueron catalogados e indexados para facilitar su descubrimiento y consulta eficiente.
5. Los módulos analíticos procesaron estos datos para generar insights, detectar anomalías y optimizar el funcionamiento de los sistemas HVAC, siguiendo flujos específicos dentro de cada módulo:

Flujo en el Módulo Analytics: El procesamiento inició con el dataset proveniente del bucket (odindatalake-analiticassage) que actuó como entrada común para el módulo. Los datos fluyeron desde este archivo hacia el componente Notebook, donde fueron consumidos para experimentación y análisis exploratorio. Desde Notebook, los datos procesados se dirigieron al componente Train para el entrenamiento del modelo predictivo. Posteriormente, los datos y el modelo entrenado fluyeron hacia Test para validación y evaluación de desempeño. Finalmente, el modelo validado se almacenó en ARTIFACTS para su uso posterior en producción.

Flujo en el Módulo Batch Inference: Step Functions (hvac-batch-processing) coordinó el flujo completo y activó el primer componente del procesamiento. Los datos de `processed.csv` fueron leídos por `start-hvac-batch-transform (Lambda1)`, que los procesó y preparó para la inferencia. Los datos transformados fluyeron

hacia SageMaker Batch Transform, que utilizó el modelo almacenado en ARTIFACTS para realizar inferencias masivas. Los resultados de la inferencia fueron consumidos por process-hvac-results (Lambda2) para postprocesamiento y formateo. Finalmente, los resultados procesados se almacenaron en odindatalake-analiticassage y se enviaron notificaciones a través de SNS.

Interconexión entre Módulos: El módulo Analytics generó el modelo entrenado que se almacenó en ARTIFACTS, estableciendo la transferencia de artefactos hacia el módulo Batch Inference. Este modelo fue posteriormente consumido por el SageMaker Model en el módulo Batch Inference para realizar las inferencias sobre nuevos datos de sistemas HVAC.

6. Los resultados del análisis alimentaron los sistemas de monitoreo y notificación, generando alertas cuando se detectaron condiciones anómalas en las variables eléctricas monitoreadas.
7. Las interfaces de usuario presentaron visualizaciones y controles que permitieron a los operadores supervisar y gestionar los sistemas HVAC basándose en los resultados del procesamiento analítico.
8. Los módulos de programación y automatización ejecutaron tareas predefinidas, como la recopilación periódica de datos, la generación de informes o la activación/desactivación de equipos basada en condiciones específicas detectadas por el sistema de análisis.

3.5. Implementación Tecnológica

La implementación técnica de la arquitectura propuesta se realizó utilizando servicios de Amazon Web Services (AWS), seleccionados por su robustez, escalabilidad y capacidades específicas para el procesamiento de datos en tiempo real y análisis predictivo.

3.5.1. Servicios AWS Implementados

3.5.1.1. Lambda

Para el procesamiento de datos y la implementación de lógica de negocio se utilizaron funciones Lambda, que permiten ejecutar código sin aprovisionar ni administrar servidores. Las funciones Lambda se implementaron en Python para el procesamiento de datos y JavaScript (Node.js) para las transformaciones. Las principales implementaciones de Lambda incluyen:

- **Upload-S3-Lambda:** Recibe los datos de los medidores y los distribuye a los canales correspondientes.
- **Transformation-Lambda:** Realiza transformaciones en los datos antes de su almacenamiento.
- **On-Off-Lambda:** Gestiona las acciones de control sobre los dispositivos HVAC.

3.5.1.2. Kinesis Firehose

Amazon Kinesis Firehose se implementó para la ingestión de datos en tiempo real. Este servicio permite capturar, transformar y cargar datos en Amazon S3, Se configuraron dos instancias de Kinesis Firehose:

- Una dedicada a los datos de consumo energético consumption data
- Otra para los datos de calidad de energía power quality

Esta separación permite un procesamiento especializado para cada tipo de datos, optimizando el rendimiento del sistema.

3.5.1.3. Amazon S3

Amazon Simple Storage Service (S3) se utilizó como el sistema principal de almacenamiento para los datos del proyecto. Se implementaron tres niveles de almacenamiento:

- **Raw:** Almacenamiento de datos en su formato original.

- **Curated:** Almacenamiento de datos procesados y optimizados.
- **Analytics:** Almacenamiento de resultados analíticos y agregaciones.

3.5.1.4. Amazon SageMaker

Para la implementación de capacidades de aprendizaje automático y detección de anomalías, se utilizó Amazon SageMaker como plataforma integral de desarrollo y despliegue. Este servicio proporcionó un entorno para construir, entrenar e implementar el modelo de aprendizaje automático.

En el contexto del proyecto, la implementación de SageMaker abarcó varios componentes:

SageMaker Studio: Se configuró como ambiente de desarrollo principal, proporcionando un entorno Jupyter administrado que permitió acceso directo a los recursos de AWS. El notebook instance se configuró con el rol IAM necesario para acceder al bucket `odindatalake-analiticassage` donde residía el dataset `processed.csv` con las 40 variables eléctricas monitoreadas.

Entrenamiento Local de Modelos: Se implementó un proceso de entrenamiento local utilizando XGBoost como librería principal. El modelo se entrenó específicamente para la detección de anomalías en la distorsión armónica total de corriente (THDi) de la fase L1, procesando 240 registros con 45 características cada uno. Se generó una etiqueta para esta variable categorizando tres niveles: Normal (menor a 23%), Advertencia (23-35%), y Crítico (mayor a 35%), estos valores se eligieron tomando como base la parametrización previa.

Reducción de Dimensionalidad: Se implementó el algoritmo PCA incorporado de SageMaker como servicio administrado. Los datos se procesaron utilizando instancias configuradas para reducir 47 características a 20 componentes principales, manteniendo aproximadamente 85-90% de la varianza original.

Registro y Gestión de Modelos: Los modelos entrenados se registraron en la sección Inference - Models de SageMaker, incluyendo la configuración de ubicación del modelo, la imagen del contenedor PCA de SageMaker, y el rol IAM con permisos necesarios para ejecutar inferencias.

Batch Transform Jobs: Se configuraron utilizando SageMaker Batch Transform Jobs, los jobs se configuraron para procesar el dataset de entrada ya procesado por la arquitectura y alojado en el bucket `odindatalake-analiticassage`, además de generar resultados de predicción en el mismo bucket.

3.5.1.5. Amazon Dynamo DB

Para el almacenamiento de datos estructurados con alta disponibilidad y baja latencia, se utilizó Amazon DynamoDB. Este servicio de base de datos NoSQL totalmente gestionado permite almacenar y consultar información de forma escalable y eficiente. En el contexto del proyecto, DynamoDB se utilizó para:

- Almacenar registros históricos y actuales de las variables eléctricas procesadas.
- Integrarse con otros servicios de AWS para el procesamiento distribuido y control automatizado.

3.5.1.6. Amazon Glue

Para la integración, preparación y catalogación de datos, se utilizó AWS Glue. Este servicio de ETL sin servidor facilita la organización y transformación de datos a gran escala. En el contexto del proyecto, Glue se utilizó para:

- Automatizar el descubrimiento de esquemas mediante crawlers, facilitando la integración de nuevas fuentes de datos.
- Registrar y mantener metadatos actualizados en el AWS Glue Data Catalog, permitiendo consultas consistentes y estructuradas.

3.5.2. Implementación de Modelos de Detección de Anomalías

Un componente fundamental del proyecto fue la implementación de modelos de detección de anomalías utilizando Amazon SageMaker, diseñados específicamente para identificar comportamientos atípicos en las variables eléctricas monitoreadas de sistemas HVAC. La implementación se estructuró en dos módulos principales que abordaron las fases de desarrollo y producción del sistema de aprendizaje automático.

3.5.2.1. Módulo Analytics - Desarrollo y Entrenamiento

El módulo Analytics constituyó la fase de desarrollo del sistema de machine learning, enfocándose en la creación y validación del modelo predictivo para la detección de anomalías en sistemas HVAC.

Preparación y Preprocesamiento de Datos: Los datos recolectados del bucket `odindatalake-analiticassage` previamente procesados por los componentes de arquitectura descritos, fueron sometidos a un proceso exhaustivo de preprocesamiento dentro del ambiente SageMaker Studio. Este proceso incluyó la eliminación de columnas irrelevantes, la codificación de variables categóricas, y la verificación de integridad de los datos. La separación entre características y variables objetivo resultó en 45 características independientes y 3 variables dependientes correspondientes a las tres fases eléctricas.

Selección y Configuración del Algoritmo: Se seleccionó XGBoost como algoritmo principal para la detección de anomalías, implementado como librería local dentro del notebook de SageMaker. Esta selección se basó en la capacidad del algoritmo para manejar datos tabulares con múltiples características y su eficiencia en problemas de clasificación multiclase que se ajustaba a los requerimientos del proyecto. El modelo se configuró específicamente para procesar las 40 variables eléctricas monitoreadas, con especial énfasis en la distorsión armónica total de corriente (THDi) como variable objetivo principal.

Sistema de Etiquetado Automático: Se implementó un sistema de etiquetado automático basado en umbrales de distorsión armónica total de corriente (THDi), categorizando las observaciones en tres niveles:

- **Normal:** $\text{THDi} < 23\%$
- **Advertencia:** $23\% \leq \text{THDi} \leq 35\%$
- **Crítico:** $\text{THDi} > 35\%$

Este sistema de etiquetado se fundamentó en las normativas técnicas analizadas durante la fase de investigación y los umbrales identificados como críticos para el funcionamiento de sistemas HVAC comerciales.

Entrenamiento del Modelo: El entrenamiento se realizó directamente en el notebook de SageMaker utilizando 240 registros procesados. El modelo se entrenó específicamente para la fase L1, aprovechando las 45 características extraídas del preprocesamiento de datos. El proceso de entrenamiento incluyó la validación cruzada y la optimización de hiperparámetros para maximizar la precisión en la detección de anomalías.

Reducción de Dimensionalidad: Se implementó el algoritmo PCA (Principal Component Analysis) incorporado de SageMaker como servicio administrado para optimizar el procesamiento posterior. El PCA se configuró para reducir las 47 características originales a 20 componentes principales, preservando aproximadamente el 85-90% de la varianza original de los datos.

Validación y Evaluación: Los modelos entrenados fueron validados utilizando conjuntos de datos de prueba separados, evaluando métricas específicas de rendimiento para la detección de anomalías en cada fase eléctrica. La validación incluyó la evaluación de la capacidad del modelo para detectar correctamente anomalías sin generar falsos positivos excesivos.

3.5.2.2. Módulo Batch Inference - Implementación en Producción

El módulo Batch Inference implementó la fase operacional del sistema, donde los modelos entrenados se aplicaron a nuevos datos para generar predicciones automatizadas en tiempo de producción.

Registro y Configuración de Modelos: El modelo entrenado se registró en la sección Inference - Models de SageMaker, configurando la ubicación del modelo, la imagen del contenedor PCA de SageMaker y los roles IAM necesarios para la ejecución de inferencias. El modelo PCA se almacenó en el bucket `ARTIFACTS` para su uso en producción.

Configuración de Batch Transform Jobs: Se implementó SageMaker Batch Transform Jobs. Los jobs se configuraron para procesar datos de entrada desde el bucket `odindatalake-analiticassage` y generar resultados de predicción en el mismo bucket, pero con una ruta creada para guardar estos resultados, donde se especifica la carpeta de predicción, el año, el mes, el día y la hora. Por ejemplo, una de las rutas que se obtuvo en este proceso fue:

```
odindatalake-analiticassage>predictions/>hvac-anomaly/>2025/>6/>7/>121313.
```

Orquestación Automatizada: AWS Step Functions proporcionó la orquestación automatizada del proceso completo de inferencia. La máquina de estados se configuró para ejecutarse periódicamente mediante CloudWatch Events, coordinando la secuencia completa: inicio del Batch Transform, monitoreo de estado, procesamiento de resultados y generación de notificaciones.

Procesamiento Serverless: Se implementaron dos funciones Lambda programadas para el preprocesamiento y postprocesamiento:

- **start-hvac-batch-transform (Lambda1):** Preparó los datos nuevos aplicando las mismas transformaciones utilizadas durante el entrenamiento, asegurando consistencia en el formato de entrada.
- **process-hvac-results (Lambda2):** Convirtió los resultados JSON del modelo en clasificaciones interpretables y generó archivos CSV estructurados para consumo posterior.

Almacenamiento y Organización de Resultados: Se configuró el bucket `analytics-results` con estructura organizacional que incluyó timestamps y categorización de resultados. Los archivos generados incluyeron predicciones de anomalías, datos históricos procesados y resúmenes de análisis en formato JSON para integración con sistemas downstream.

3.5.2.3. Integración y Flujo Operacional

El sistema implementado estableció un flujo automatizado que monitoreó la llegada de nuevos datos al bucket `odindatalake-analiticasage`. Cuando se detectaron nuevos archivos, el sistema activó automáticamente el pipeline de procesamiento que aplicó las mismas transformaciones utilizadas durante el entrenamiento.

El Batch Transform Job cargó el modelo PCA entrenado y aplicó la reducción de dimensionalidad a los nuevos datos, seguido de la aplicación de la lógica de clasificación de anomalías basada en los umbrales de THDi establecidos. Los resultados se almacenaron en formato estructurado que permitió identificar equipos HVAC con comportamiento normal, en advertencia o crítico.

La arquitectura implementada mantuvo separación clara entre datos fuente, artefactos de modelos y resultados de predicción, facilitando el mantenimiento, versionado de modelos y escalabilidad del sistema de detección de anomalías para sistemas HVAC comerciales en Bogotá.

3.6. Restricciones de Arquitectura

El diseño arquitectónico del prototipo de sistema IoT para la automatización y optimización energética de sistemas HVAC en el sector comercial estuvo condicionado por un conjunto de restricciones técnicas, económicas y organizacionales que delimitaron las posibles soluciones a adoptar. Esta sección documenta dichas restricciones, que fueron fundamentales para guiar las decisiones de diseño y seleccionar los componentes tecnológicos adecuados.

3.6.1. Restricciones Técnicas

3.6.1.1. Modelo de transmisión de datos periódico

Dado que los medidores inteligentes empleados en el sistema están configurados para registrar variables eléctricas 6 horas los 7 días de la semana, para este proyecto, y la frecuencia puede ser, mayor según las necesidades del negocio. La arquitectura debe soportar flujos de datos periódicos, con picos intermitentes en la entrada. Esto impone la necesidad de una infraestructura capaz de escalar automáticamente según los ciclos de ingesta sin incurrir en sobrecostos por sobredimensionamiento.

3.6.1.2. Formato de datos estructurado

El sistema debe operar con estructuras de datos homogéneas y autodescriptivas. Se estableció el uso de archivos JSON como formato estándar de transmisión e intercambio de datos entre componentes. Esta decisión implica que todos los servicios de procesamiento deben ser compatibles con este formato y contar con validaciones de esquema.

3.6.2. Restricciones Económicas

3.6.2.1. Modelo de costos basado en demanda

El sistema debe operar bajo un modelo económico de pago por uso, sin costos fijos mensuales por infraestructura dedicada. Esta restricción eliminó de las alternativas el uso de instancias virtuales permanentes (EC2) o bases de datos administradas tradicionales, privilegiando soluciones serverless como AWS Lambda, DynamoDB en modo on-demand, y Kinesis Firehose.

3.6.2.2. Uso eficiente de almacenamiento

El sistema debe minimizar los costos de almacenamiento de datos históricos. Esta condición se abordó mediante la segmentación por capas en Amazon S3 (raw, curated, analytics) y la aplicación de políticas de ciclo de vida que automaticen la transición hacia clases de almacenamiento de bajo costo (S3 Infrequent Access y S3 Glacier).

3.6.3. Restricciones Organizacionales

3.6.3.1. Conocimiento previo en AWS

El equipo de desarrollo cuenta con experiencia previa en el ecosistema AWS, lo que favoreció la elección de servicios nativos como Lambda, S3, Kinesis y SageMaker. Esta restricción redujo la curva de aprendizaje y aceleró los tiempos de implementación del prototipo, evitando la introducción de tecnologías externas al dominio de conocimiento del equipo.

3.6.3.2. Mantenimiento mínimo post-implementación

Dado el carácter prototípico del sistema y su implementación en un entorno controlado, se estableció como restricción evitar tareas manuales de administración, actualización o despliegue continuo. Esta directriz orientó la adopción de una arquitectura 100% gestionada y sin servidores (serverless), que no requiere intervención operativa para asegurar la disponibilidad y escalabilidad del sistema.

3.6.4. Restricciones Regulatorias

3.6.4.1. Cumplimiento normativo en calidad de energía

El sistema debe monitorear variables alineadas con las normativas colombianas (NTC 5001-2008) e internacionales (IEEE 519-2014) sobre calidad de energía, como distorsión armónica, desequilibrio de tensiones, factor de potencia, entre otras. Esta restricción determinó la selección de variables a recolectar, los intervalos de muestreo y los umbrales de detección de anomalías.

3.6.5. Resumen

Las restricciones descritas sirvieron como guía para tomar decisiones coherentes con los objetivos del proyecto, delimitando el espacio de diseño arquitectónico. Estas limitaciones también garantizaron la viabilidad técnica, económica y normativa del prototipo, asegurando que su implementación se alinee con las condiciones reales del sector comercial bogotano y con las capacidades del equipo desarrollador.

3.7. Decisiones Arquitectónicas: Uso de Servicios Serverless en AWS

En el desarrollo del prototipo propuesto se tomaron decisiones arquitectónicas orientadas a maximizar la eficiencia operativa, reducir costos y evitar la gestión de infraestructura. A continuación, se describen los registros de decisiones

arquitectónicas (ADR, por sus siglas en inglés) adoptadas en relación con el uso de servicios serverless de Amazon Web Services (AWS):

ADR-001: Migración de Funciones a AWS Lambda

Estado: Aprobado

Contexto: Las funciones de procesamiento requerían aprovisionamiento, configuración de servidores y gestión de actualizaciones de seguridad.

Decisión: Migrar el procesamiento de eventos a AWS Lambda para implementar funciones bajo demanda.

Justificación:

- Modelo de pago por uso: se factura por invocación, lo cual es eficiente en flujos periódicos como los del sistema (cada 15 minutos).
- Elimina la necesidad de gestionar servidores o infraestructura dedicada.
- Escalabilidad automática y alta disponibilidad gestionada por AWS.
- Conocimiento previo del equipo en desarrollo de funciones Lambda.

Consecuencias:

- Límites de ejecución (tiempo, memoria) deben considerarse en el diseño.
- Arquitectura basada en funciones desacopladas orientadas a eventos.

ADR-002: Uso de Amazon Kinesis Firehose para Ingesta de Datos

Estado: Aprobado

Contexto: Los medidores inteligentes generan datos eléctricos cada 15 minutos, que deben ser transmitidos y almacenados eficientemente.

Decisión: Implementar Amazon Kinesis Data Firehose para la transmisión y entrega de datos a S3.

Justificación:

- Servicio totalmente gestionado, sin necesidad de administración de clústeres o particiones.
- Integración nativa con S3, ideal para arquitecturas de almacenamiento en capas (raw, curated, analytics).
- Adecuado para transmisiones periódicas como las generadas por los medidores.

Consecuencias:

- Dependencia del ecosistema AWS.
- Es necesario validar y transformar los datos adecuadamente en los puntos de entrada.

ADR-003: Uso de Amazon SageMaker para Detección de Anomalías

Estado: Aprobado

Contexto: Se requiere entrenar modelos de aprendizaje automático para identificar comportamientos atípicos en variables eléctricas.

Decisión: Utilizar Amazon SageMaker para el entrenamiento, despliegue y evaluación de modelos predictivos.

Justificación:

- Plataforma escalable y gestionada para ciencia de datos.
- Integración directa con el almacenamiento en S3.
- Reducción del tiempo de desarrollo y despliegue de modelos.
- Familiaridad del equipo con el entorno SageMaker Studio.

Consecuencias:

- Se deben controlar los costos asociados al entrenamiento y almacenamiento de modelos.
- Se requiere automatizar la gestión de pipelines y versiones de modelos.

ADR-004: Estándar Serverless para la Arquitectura Completa

Estado: Aprobado

Contexto: La infraestructura tradicional implica costos fijos, administración continua y exposición a vulnerabilidades.

Decisión: Adoptar un enfoque completamente serverless para todos los componentes de la arquitectura.

Justificación:

- Elimina la gestión de infraestructura, parches de seguridad y actualizaciones.
- Pago basado en uso efectivo del sistema.
- Mayor resiliencia y disponibilidad sin esfuerzo operativo.
- Facilidad para integración de servicios AWS como CloudWatch, S3, DynamoDB, etc.

Consecuencias:

- Requiere una arquitectura orientada a eventos.
- Incrementa la dependencia con los servicios específicos de AWS.

ADR-005: Uso de Amazon S3 como Almacenamiento Multinivel

Estado: Aprobado

Contexto: El sistema requiere almacenar grandes volúmenes de datos eléctricos provenientes de medidores inteligentes, así como los resultados de procesamiento analítico y modelos de inferencia.

Decisión: Utilizar Amazon S3 como sistema de almacenamiento central en capas: raw, curated y analytics.

Justificación:

- Alta durabilidad (99.99999999%) y disponibilidad global.
- Costos bajos en almacenamiento por volumen.
- Integración directa con servicios de AWS (Athena, Firehose, SageMaker, Glue).
- Soporte para políticas de ciclo de vida y archivado automatizado (S3 Glacier).

Consecuencias:

- Se deben diseñar convenciones de carpetas, prefijos y estructuras de datos coherentes.
- Es necesario gestionar políticas de acceso (IAM) para control seguro.

ADR-006: Uso de JSON como Formato Estándar para Intercambio de Datos

Estado: Aprobado

Contexto: La arquitectura IoT requiere un formato estándar para la transmisión y procesamiento de datos entre dispositivos, funciones Lambda y servicios de almacenamiento.

Decisión: Adoptar JSON como formato de intercambio de datos entre todos los componentes.

Justificación:

- Legible por humanos y depurable durante el desarrollo.
- Altamente compatible con servicios de AWS como Lambda, Kinesis, Glue y SageMaker.
- Flexible ante cambios en la estructura sin romper compatibilidad.

Consecuencias:

- Ocupa más espacio que formatos binarios (ej. Parquet o Avro).
- Es necesario validar su estructura con esquemas formales (JSON Schema).

ADR-007: Uso de Amazon DynamoDB para Persistencia de Configuraciones y Estados

Estado: Aprobado

Contexto: El sistema necesita almacenar configuraciones dinámicas, estados de operación y metainformación de dispositivos de manera eficiente y con baja latencia.

Decisión: Utilizar Amazon DynamoDB como base de datos NoSQL gestionada para persistencia de información operativa.

Justificación:

- Baja latencia y alta disponibilidad sin gestión de servidores.
- Escalabilidad automática ante cambios en el volumen de consultas.
- Modelo de pago por uso según demanda (on-demand mode).
- Integración directa con Lambda para patrones de acceso event-driven.

Consecuencias:

- Se deben definir cuidadosamente las claves de partición y acceso.
- Limitaciones en operaciones de lectura cruzada o joins complejos.

3.8. Resultados Preliminares

Durante la fase inicial de implementación, el sistema demostró la efectividad de la arquitectura IoT distribuida propuesta para la automatización y optimización energética de sistemas HVAC comerciales. La validación del prototipo se centró en evaluar el desempeño de los componentes arquitectónicos desarrollados, su integración y capacidad para procesar las 40 variables eléctricas identificadas mediante los modelos de machine learning implementados.

3.8.1. Validación de Componentes Arquitectónicos

Los resultados preliminares confirman el correcto funcionamiento de los módulos principales de la arquitectura distribuida:

1. **Módulo Emulate:** El componente Agent configurado con roles específicos (Client o Secret) demostró capacidad para generar y transmitir datos estructurados en formato JSON desde los dispositivos de campo conectados a sistemas HVAC. La validación incluyó la correcta estructuración de metadatos como identificadores de dispositivos, marcas temporales y comandos específicos.
2. **Módulo Intake:** La función Upload-S3-Lambda implementada en Python procesó exitosamente la recepción y distribución de datos entrantes. El sistema Kinesis Firehose Dual demostró efectividad en la separación y procesamiento especializado de datos de consumo energético y calidad de energía, validando la estrategia de distribución diferenciada implementada.
3. **Sistema de Almacenamiento Distribuido:** La implementación de almacenamiento en capas mediante Amazon S3 (Data-raw-S3, Data-cur-parquet, Data-dw-Analytics) facilitó el procesamiento eficiente y optimizó las consultas analíticas posteriores. La conversión automática al formato Parquet mejoró significativamente el rendimiento de acceso a datos históricos.
4. **Catálogo de Datos:** El componente Crawler junto con Catalogs-Athena proporcionó capacidades de indexación y descubrimiento de datos, facilitando consultas estructuradas sobre los repositorios de información almacenada.

3.8.2. Desempeño de Módulos de Machine Learning

La arquitectura de aprendizaje automático demostró una buena integración entre las fases de desarrollo y producción:

1. **Módulo Analytics:** El ambiente de desarrollo en SageMaker Notebook Instance facilitó la exploración de las 40 variables eléctricas y la implementación del modelo XGBoost para detección de anomalías. El componente Train ejecutó exitosamente el entrenamiento del modelo utilizando los datos históricos simulados tomando como base parámetros de datos reales, mientras que el componente Test validó la capacidad predictiva del modelo con datos no vistos durante el entrenamiento. El repositorio Artifacts gestionó efectivamente el almacenamiento y versionado de modelos entrenados.
2. **Módulo Batch Inference:** La implementación operacional demostró coordinación entre componentes. Step Functions (hvac-batch-processing) orquestó exitosamente el flujo completo de procesamiento, mientras que start-hvac-batch-transform (Lambda1) realizó el preprocesamiento adecuado de datos de entrada. SageMaker Batch Transform ejecutó inferencias masivas utilizando el modelo almacenado en Artifacts, y process-hvac-results (Lambda2) generó correctamente los archivos de salida estructurados.
3. **Sistema de Notificaciones:** El componente SNS (hvac-alerts) proporcionó alertas sobre anomalías detectadas, completando el ciclo automatizado de procesamiento y comunicación de resultados.

3.8.3. Efectividad del Modelo de Detección de Anomalías

La implementación del modelo predictivo basado en distorsión armónica total de corriente (THDi) demostró capacidad para clasificar las condiciones operacionales:

1. **Sistema de Clasificación Automática:** El modelo implementado clasificó correctamente las observaciones en tres categorías establecidas: Normal (THDi menor a 23)
2. **Reducción de Dimensionalidad:** La implementación del algoritmo PCA incorporado de SageMaker redujo las 47 características originales a 20 componentes principales, preservando entre 85-90
3. **Procesamiento Automatizado:** El sistema demostró capacidad para procesar automáticamente nuevos conjuntos de datos, aplicando las transformaciones de preprocesamiento y generando predicciones sin intervención manual.

3.8.4. Validación de Componentes de Monitoreo y Control

Los módulos de automatización y control demostraron integración con la arquitectura principal:

1. **Sistema de Programación Automatizada:** EventBridge ejecutó correctamente la programación de procesamiento dos veces al día (11 AM y 5 PM), activando el pipeline de validación de anomalías. La base de datos DynamoDB almacenó efectivamente las parametrizaciones de medidores y configuraciones de correos de despacho.
2. **Lambda Notificadora:** El componente demostró que puede interactuar con catálogos generados por el modelo de predicción y despachar mensajes apropiados cuando se detectaron valores críticos.
3. **Módulo de Control On-Off:** El sistema de programación basado en archivos CSV (Load Program File) procesó correctamente las instrucciones de encendido y apagado de unidades HVAC. Lambda Process generó exitosamente los eventos necesarios y registró todas las operaciones en DynamoDB para seguimiento posterior.

3.8.5. Integración de Componentes Hardware

Aunque el proyecto se enfocó en la arquitectura de software, la validación incluyó la integración con componentes hardware esenciales:

1. **Medidores Inteligentes:** Los medidores de energía hacen parte de la infraestructura de recolección de información más no de la arquitectura propuesta, sin embargo son importantes en la recolección de información. Los medidores de energía conectados a tableros que alimentan los sistemas HVAC generaron exitosamente datos de las 40 variables eléctricas monitoreadas.

2. **Unidad Concentradora:** Aunque este componentes no hace parte explícita de este proyecto, es necesario mencionarlo porque hace parte de la infraestructura de recolección de datos necesaria para la implementación de la arquitectura. La Unidad Concentradora funcionó como puerta de enlace, facilitando la comunicación RF con los medidores y transmitiendo datos hacia la arquitectura cloud implementada.
3. **Sistemas HVAC Objetivo:** La validación incluyó equipos comerciales reales que demostraron respuesta adecuada a las señales de control generadas por el módulo On-Off Lambda.

3.8.6. Estimación de Viabilidad Operacional

La arquitectura serverless implementada demostró viabilidad técnica y económica:

1. **Escalabilidad Automática:** Los servicios AWS implementados (Lambda, Kinesis Firehose, SageMaker, S3, DynamoDB) demostraron capacidad de escalamiento automático según la demanda operacional, validando la estrategia de arquitectura distribuida sin servidores dedicados.
2. **Modelo de Costos Eficiente:** El análisis empírico de procesamiento reveló estructura de costos proporcional al uso real, con AWS Glue representando el componente principal de costo operacional, seguido por SageMaker y servicios de almacenamiento con participación marginal.
3. **Almacenamiento Estructurado:** La estrategia de almacenamiento con estructura organizacional que incluye timestamps y categorización de resultados facilitó el acceso eficiente a datos históricos. Por ejemplo, el sistema generó rutas estructuradas como:

```
odindatalake-analiticasage>predictions/>hvac-anomaly/>2025/>6/>7/>121313
```

Estos resultados preliminares validaron la efectividad de la arquitectura IoT distribuida propuesta, demostrando que los componentes implementados proporcionan una solución para la automatización y optimización energética de sistemas HVAC comerciales, con capacidad de escalamiento y viabilidad operacional para implementaciones de mayor envergadura. Con base en la información obtenida en esta etapa se prosiguió con la etapa de evaluación mediante dashboards que fueron posibles con la información obtenida de las variables de consumo, de calidad de la energía y los datos arrojados por el modelo predictivo.

3.8.7. Estimación de Costos de Implementación

La arquitectura diseñada hace uso intensivo de servicios serverless de Amazon Web Services (AWS), cuyos costos operan bajo un modelo basado en demanda. Para estimar el costo de operación del sistema a escala, se realizó una medición empírica procesando un conjunto de 100 registros eléctricos provenientes de medidores inteligentes, cuya ejecución involucró los siguientes servicios:

- **AWS Glue:** procesamiento y transformación de datos (USD \$12.37).
- **Amazon SageMaker:** ejecución de modelos de detección de anomalías (USD \$0.08).
- **Amazon S3:** almacenamiento de datos crudos y procesados (USD \$0.0058).
- **Amazon Athena:** consultas sobre datos históricos (USD \$0.00065).
- **Kinesis Firehose:** transmisión de eventos (USD \$0.0003).
- **Amazon DynamoDB:** persistencia de configuraciones y metadatos (USD \$0.000015).

El costo total observado para procesar 100 registros fue de aproximadamente **USD \$12.46**.

Proyección para Escenarios Operacionales

Dado que el sistema en producción estaría procesando alrededor de 15.000 registros en una ventana de análisis (por ejemplo, una semana de operación continua con varios medidores), se realizó una proyección proporcional:

$$\text{Costo estimado} = \frac{12,46 \text{ USD}}{100} \times 15,000 = \text{USD } \mathbf{\$1.869}$$

Consideraciones

- Los valores proyectados se basan en un modelo de crecimiento lineal, válido bajo el supuesto de cargas distribuidas de manera uniforme y sin cuellos de botella.
- La arquitectura serverless garantiza que estos costos reflejan directamente el volumen de uso real, sin cargos por infraestructura inactiva.
- En producción, se pueden reducir costos optimizando consultas, consolidando ejecuciones de Glue y ajustando el ciclo de vida de almacenamiento en S3.

Escalabilidad y Contexto Empresarial

Estos costos proyectados corresponden al procesamiento de datos provenientes de aproximadamente 10 concentradores, que podrían representar la operación de alrededor de 3 empresas comerciales. Esto da una idea del rango de uso y escalabilidad del sistema en un entorno realista de implementación múltiple.

Resumen

La proyección indica que operar este sistema a escala moderada puede mantenerse por debajo de los **USD \$2.000** mensuales, lo que lo posiciona como una solución económicamente viable para empresas comerciales interesadas en mejorar su eficiencia energética mediante monitoreo y control inteligente de sus sistemas HVAC.

Estos resultados preliminares validan la viabilidad técnica de la solución propuesta y sientan las bases para una evaluación más completa durante la fase de pruebas extendidas.

3.9. Desafíos y Soluciones

Durante la implementación del prototipo de arquitectura IoT se enfrentaron diversos desafíos técnicos y arquitectónicos que requirieron ajustes en el diseño original. Estos desafíos abarcaron desde limitaciones en la recolección de datos hasta complejidades en la integración de componentes distribuidos, cada uno resuelto mediante adaptaciones específicas en la arquitectura propuesta.

3.9.1. Desafíos en la Recolección y Calidad de Datos

3.9.1.1. Limitaciones del Monitoreo Real para Entrenamiento de Modelos

Desafío: Durante la fase de monitoreo real en la instalación hospitalaria se identificaron limitaciones fundamentales para el desarrollo de modelos de detección de anomalías. La frecuencia de muestreo de 15 minutos, aunque apropiada para análisis de calidad de energía, resultaba excesivamente frecuente para las necesidades operativas de un negocio comercial típico. Adicionalmente, los datos recopilados correspondían principalmente a condiciones de operación normal, sin la presencia de eventos anómalos definidos y etiquetados necesarios para el entrenamiento de modelos de clasificación supervisada. **Solución Arquitectónica:** Se desarrolló una estrategia de simulación controlada que aprovechó los patrones y características estadísticas identificados durante el monitoreo real. La simulación generó 240 muestras distribuidas en 10 unidades de medida simuladas (MP9991 a MP99910), representando un entorno comercial típico con múltiples puntos de medición. Se implementó un sistema de generación de anomalías que incluyó: anomalías graduales simulando deterioro progresivo de componentes, anomalías abruptas representando fallas inmediatas, y anomalías correlacionadas reflejando problemas sistémicos. Esta solución permitió crear un conjunto de datos balanceado con aproximadamente 70 por ciento de condiciones normales y 30 por ciento de condiciones anómalas necesarias para el entrenamiento efectivo del modelo XGBoost.

3.9.1.2. Inconsistencias en Formato y Estructura de Datos

Desafío: La integración de datos, presentó inconsistencias en formatos, escalas de medición y estructuras de metadatos. La heterogeneidad en la nomenclatura de variables y la presencia de datos faltantes en ciertos períodos del monitoreo real afectaban la calidad y completitud necesaria para el entrenamiento de modelos predictivos. **Solución Implementada:** Se desarrolló un módulo de preprocesamiento robusto dentro del componente start-hvac-batch-transform (Lambda1) que implementó normalización, validación de esquemas JSON y detección automática de valores atípicos. El sistema incorporó mecanismos de imputación de datos basados en interpolación temporal y correlaciones entre variables eléctricas relacionadas. Se estableció JSON como formato estándar de intercambio de datos entre todos los componentes, con validaciones de esquema que aseguraron consistencia estructural a lo largo de todo el pipeline de procesamiento.

3.9.2. Desafíos Arquitectónicos y de Integración

3.9.2.1. Complejidad en la Orquestación de Flujos Distribuidos

Desafío: La coordinación entre los módulos Analytics y Batch Inference presentó complejidades en la sincronización de procesos, transferencia de artefactos y manejo de estados de ejecución. La arquitectura distribuida requería garantizar que los modelos entrenados en el módulo Analytics estuvieran disponibles y correctamente versionados para su uso en el módulo Batch Inference, mientras se mantenía la integridad del flujo de datos a través de múltiples servicios AWS. **Solución de Orquestación:** Se implementó AWS Step Functions (hvac-batch-processing) como orquestador central del flujo de procesamiento, proporcionando coordinación automatizada entre componentes, manejo de transiciones entre estados, y gestión de errores con reintentos automáticos. El sistema estableció un repositorio centralizado de Artifacts que actúa como punto de transferencia entre módulos, asegurando que los modelos entrenados mediante SageMaker en el módulo Analytics sean accesibles para SageMaker Batch Transform en el módulo Batch Inference. Se configuró EventBridge para ejecutar automáticamente el pipeline dos veces al día, eliminando la necesidad de intervención manual en la operación del sistema.

3.9.2.2. Escalabilidad y Optimización de Costos

Desafío: La arquitectura debía manejar volúmenes variables de datos mientras mantenía costos operacionales proporcionales al uso real. Los picos de procesamiento durante la ejecución de trabajos de Batch Transform y las operaciones de AWS Glue representaban el mayor componente de costos, requiriendo optimización para viabilidad económica a largo plazo. **Solución Serverless:** Se adoptó una estrategia completamente serverless que eliminó costos fijos de infraestructura dedicada. La implementación utilizó servicios con escalamiento automático (Lambda, Kinesis Firehose, DynamoDB on-demand) que facturan exclusivamente por uso efectivo. Se implementaron políticas de ciclo de vida en S3 que transicionan automáticamente datos históricos hacia clases de almacenamiento de menor costo (S3 Infrequent Access y S3 Glacier). El sistema optimizó la ejecución de AWS Glue mediante consolidación de operaciones y programación de trabajos en ventanas de menor demanda.

3.9.3. Desafíos Específicos del Dominio HVAC

3.9.3.1. Heterogeneidad de Equipos y Configuraciones

Solución de Parametrización Adaptativa: Se desarrolló un sistema de parametrización flexible basado en variables de entrada que se configuran según las especificaciones técnicas de cada instalación particular. El sistema utiliza el voltaje nominal de diseño (documentado en diagramas unifilares) como valor de referencia para calcular umbrales operativos específicos. Los umbrales de detección de anomalías se expresan como porcentajes relativos al valor nominal, permitiendo adaptación automática a diferentes configuraciones de red eléctrica (220V, 230V, 240V). Se implementó en DynamoDB un repositorio de configuraciones que almacena parámetros específicos por medidor, incluyendo capacidad nominal del tablero, características técnicas de equipos conectados, y umbrales personalizados basados en normativas aplicables.

3.9.4. Validación y Refinamiento de Soluciones

La implementación de estas soluciones fue validada mediante la arquitectura completa, demostrando que los ajustes realizados mejoraron la robustez y adaptabilidad del sistema. El modelo de detección de anomalías logró clasificar correctamente el 92 % de las muestras de prueba, mientras que la arquitectura serverless demostró escalabilidad automática y costos proporcionales al uso real. La estrategia de simulación controlada compensó las limitaciones del monitoreo real, proporcionando un conjunto de datos balanceado que permitió el entrenamiento exitoso del modelo XGBoost. La orquestación automatizada mediante Step Functions eliminó la complejidad operacional de la coordinación manual entre módulos distribuidos. Estos desafíos y sus respectivas soluciones contribuyeron a consolidar una arquitectura IoT robusta y adaptativa que demostró viabilidad técnica y económica para su aplicación en diversos contextos dentro del sector comercial, estableciendo las bases para escalamiento hacia implementaciones de mayor envergadura en el futuro.

3.10. Resumen del capítulo

El capítulo presentó el desarrollo de un sistema IoT distribuido para la automatización y optimización energética de sistemas HVAC en el sector comercial de Bogotá, basado en el análisis de 40 variables eléctricas y la implementación de modelos de machine learning para detección temprana de anomalías.

La investigación inicial incluyó consultoría técnica especializada y acceso a instalaciones comerciales reales, revelando que equipos operando inicialmente al 70 % de su capacidad incrementan su consumo energético por degradación natural. La parametrización de variables eléctricas, fundamentada en normas NTC 5001-2008 y estándares IEEE, estableció umbrales para detección de anomalías en corrientes por fase, tensiones fase-fase, distorsión armónica total, armónicos individuales, factor de potencia, potencia activa y factores de desequilibrio.

La recolección de datos comprendió dos fases: monitoreo real en una instalación comercial durante seis días, obteniendo registros de las 40 variables que identificaron comportamientos característicos y condiciones que excedían límites normativos; y simulación controlada que generó 240 muestras distribuidas en 10 unidades de medida, incluyendo condiciones normales y anómalas para entrenamiento de modelos predictivos.

Los requisitos abarcaron componentes de integración IoT, procesamiento y análisis de datos mediante machine learning, y automatización y control de espacios. La arquitectura siguió un modelo distribuido con múltiples capas para captura, transmisión, procesamiento y análisis de datos, incluyendo módulos de entrada desde dispositivos IoT, distribución especializada mediante Kinesis Firehose dual, almacenamiento en capas, catálogo de datos, módulos de aprendizaje automático organizados en Analytics y Batch Inference, sistemas de monitoreo automatizado e interfaces de usuario.

La implementación utilizó servicios serverless de Amazon Web Services: Lambda para procesamiento, Kinesis Firehose para ingestión, S3 para almacenamiento, SageMaker para desarrollo y despliegue de modelos, DynamoDB para persistencia, y Step Functions para orquestación automatizada.

El desarrollo de modelos de detección de anomalías se estructuró en dos módulos. El módulo Analytics implementó el ambiente de desarrollo utilizando XGBoost para clasificación de anomalías basadas en umbrales de distorsión armónica total de corriente y PCA para reducción de dimensionalidad. El módulo Batch Inference estableció la fase operacional con trabajos de transformación batch y funciones Lambda especializadas.

El diseño estuvo condicionado por restricciones técnicas como transmisión periódica de datos, restricciones económicas de pago por uso, restricciones organizacionales relacionadas con conocimiento previo en AWS, y restricciones regulatorias de cumplimiento normativo. Las decisiones arquitectónicas adoptaron servicios serverless para maximizar eficiencia operativa y reducir costos.

Los resultados preliminares validaron la viabilidad técnica con alta tasa de captura de datos, identificación correcta de patrones atípicos, rendimiento adecuado para procesamiento en tiempo real e interfaces efectivas. La estimación de costos resultó viable económicamente. Los desafíos de heterogeneidad de equipos, calidad de datos y adaptación a patrones de uso se abordaron mediante modelado por categorías, técnicas de imputación y aprendizaje adaptativo.

Evaluación

4.1. Diseño de la Evaluación

El diseño de la evaluación del sistema de arquitectura IoT para automatización y optimización energética de sistemas HVAC se estructuró de tal forma que se pueda cuantificar el impacto real del sistema implementado en la eficiencia energética de instalaciones comerciales. La evaluación se fundamentó en la necesidad de establecer un marco de valoración que integre métricas de calidad de energía, patrones de consumo y eficiencia operativa, permitiendo cuantificar el impacto del sistema en la gestión energética de las unidades HVAC y validar las estrategias de optimización implementadas.

4.1.1. Marco Conceptual de la Evaluación

4.1.1.1. Fundamentos Técnicos de la Evaluación

El diseño de evaluación se basó en la comprensión del funcionamiento de sistemas HVAC comerciales obtenida durante las fases previas de investigación. Como se estableció en el marco teórico, los sistemas HVAC inicialmente operan utilizando aproximadamente el 70% de su capacidad nominal, pero experimentan degradación progresiva debido a factores como acumulación de polvo, desgaste de componentes mecánicos y envejecimiento natural de materiales [Garces-Jimenez et al. \(2021\)](#).

Esta degradación se manifiesta particularmente en incrementos del consumo de corriente eléctrica y alteraciones en las variables de calidad de energía, constituyendo indicadores valiosos para el diagnóstico del estado de los equipos. La experiencia técnica obtenida mediante consultoría especializada y acceso a instalaciones comerciales reales reveló que el monitoreo inteligente debe considerar correlaciones entre múltiples variables eléctricas para una detección efectiva de anomalías.

4.1.1.2. Arquitectura de Evaluación Basada en Datos Reales

La evaluación se diseñó para analizar los datos generados por la arquitectura implementada, específicamente el dataset `processed.csv` que contiene 240 registros de mediciones eléctricas distribuidos en 10 medidores simulados (MP9990 a MP99910). Este dataset representa el resultado del procesamiento completo de la arquitectura descrita en capítulos anteriores, almacenado en el bucket `odindatalake-analiticasage` y conteniendo las 40 variables eléctricas monitoreadas por el sistema.

La metodología de evaluación incorporó como entrada los datos preprocesados por los componentes de la arquitectura distribuida, incluyendo las transformaciones realizadas por Kinesis Firehose, el almacenamiento en capas S3, y el procesamiento analítico mediante AWS Glue y SageMaker. Esta aproximación garantizó que la evaluación reflejara el desempeño real del sistema completo desde la captura de datos hasta la generación de resultados analíticos.

4.1.2. Variables y Parámetros de Evaluación

4.1.2.1. Variables Eléctricas de Entrada

La evaluación se centró en el análisis de 40 variables eléctricas fundamentales para caracterizar el comportamiento energético de sistemas HVAC comerciales. Estas variables fueron organizadas según la parametrización establecida

en la fase de investigación, que diferencia entre variables de entrada y variables de salida basándose en su origen y función en el sistema.

Las variables de entrada, derivadas del diseño específico de instalaciones y documentadas en especificaciones técnicas, determinan los umbrales operativos normales para cada sistema particular. Estas incluyen la tensión nominal de diseño establecida en 220V como valor de referencia, las características técnicas de equipos conectados, y los límites de distorsión armónica admisible según normativas IEEE 519-2014 [IEEE \(2014\)](#) y NTC 5001-2008 [ICONTEC \(2008\)](#).

Las variables de salida, obtenidas mediante medición continua y procesamiento analítico, constituyen la base para la evaluación del estado operativo real del sistema. Entre estas se destacan las corrientes por fase (`data_current_11`, `data_current_12`, `data_current_13`), voltajes línea-línea (`data_voltage_112`, `data_voltage_123`, `data_voltage_131`), y distorsión armónica total por fase (`data_athd_11`, `data_athd_12`, `data_athd_13`).

4.1.2.2. Variable Objetivo Principal

La distorsión armónica total de corriente (THDi) de la fase L1 se estableció como variable objetivo principal para la evaluación del modelo de clasificación. Esta selección se fundamentó en los hallazgos de la investigación técnica que demostraron la alta sensibilidad de THDi a cambios en el estado operativo de motores y sistemas electrónicos, su correlación directa con sobrecalentamiento en componentes, y su capacidad para identificación temprana de problemas en variadores de frecuencia [Wang and Song \(2018\)](#).

Los umbrales de clasificación se establecieron según los parámetros normativos analizados: Normal (THDi menor al 23%), Advertencia ($23\% \leq \text{THDi} \leq 35\%$), y Crítico ($\text{THDi} > 35\%$). Estos rangos se fundaron en los límites establecidos por IEEE 519-2014 y las condiciones específicas identificadas como críticas para el funcionamiento de sistemas HVAC comerciales [ABB \(2018\)](#).

4.1.3. Marco Normativo de Evaluación

4.1.3.1. Estándares de Referencia

El diseño de evaluación se alineó con el marco normativo establecido durante la fase de investigación, incorporando los límites de calidad de energía definidos por la NTC 5001-2008 para sistemas con tensiones inferiores a 69 kV, que establece un valor máximo permisible de THDi del 35 % y THDv no superior al 5 % [ICONTEC \(2008\)](#).

La parametrización de umbrales consideró adicionalmente las directrices de la IEEE 519-2014 para control de armónicos en sistemas de potencia eléctrica, particularmente relevantes dado que los sistemas HVAC modernos con variadores de frecuencia introducen cargas no lineales que generan distorsiones armónicas en la red eléctrica [IEEE \(2014\)](#).

Los rangos de voltaje se establecieron según la NTC 1340 y la Resolución CREG No.082/2002, que definen como aceptables variaciones entre $\pm 5\%$ del valor nominal, proporcionando el marco de referencia para la evaluación de calidad del suministro eléctrico [ICONTEC \(2013\)](#); [de regulación de Energía y Gas \(2002\)](#).

4.1.4. Metodología de Procesamiento y Análisis

4.1.4.1. Pipeline de Evaluación Automatizada

La evaluación se implementó mediante un pipeline automatizado que procesa los datos del dataset `processed.csv` a través de la arquitectura de machine learning desarrollada. El sistema aplicó las transformaciones de preprocesamiento establecidas durante la fase de entrenamiento, incluyendo normalización de variables, codificación de características categóricas, y aplicación de la reducción de dimensionalidad mediante PCA.

El modelo XGBoost entrenado, almacenado en el repositorio Artifacts de la arquitectura, se aplicó a los 240 registros de entrada para generar clasificaciones automáticas según los umbrales establecidos. El procesamiento se coordinó mediante AWS Step Functions, ejecutando secuencialmente las etapas de preprocesamiento (`start-hvac-batch-transform`), inferencia (SageMaker Batch Transform), y postprocesamiento (`process-hvac-results`).

4.1.4.2. Generación de Métricas de Salida

El sistema de evaluación generó un dataset de salida estructurado conteniendo 17 variables derivadas que permiten cuantificar tanto el rendimiento del modelo de machine learning como el impacto operativo de las predicciones. Este dataset, almacenado como `hvac_anomaly_detection_pbi.csv` en el bucket `odindatalake-analiticasage`, incluye identificación de equipos, niveles de anomalía clasificados, códigos de anomalía específicos, rangos de THDi, niveles de riesgo, scores de riesgo en escala 0-100, descripciones de estado, acciones recomendadas, y prioridades de mantenimiento.

La arquitectura serverless implementada garantizó el procesamiento automatizado y la generación consistente de resultados, manteniendo la trazabilidad completa desde las mediciones originales hasta las recomendaciones de mantenimiento predictivo.

4.1.5. Herramientas y Plataforma de Visualización

4.1.5.1. Selección de Power BI para Análisis

Para la visualización y análisis de los resultados de evaluación se seleccionó Microsoft Power BI como plataforma de Business Intelligence, considerando su capacidad para integrar múltiples fuentes de datos, generar visualizaciones interactivas, y proporcionar capacidades analíticas avanzadas apropiadas para la evaluación de sistemas energéticos complejos.

La selección de Power BI se basó en su compatibilidad con los formatos de datos generados por la arquitectura AWS implementada, su capacidad para manejar datasets con la estructura y volumen de los resultados obtenidos, y sus funcionalidades para el desarrollo de dashboards que faciliten la interpretación de resultados tanto técnicos como gerenciales. En esta etapa no se hizo uso del componente mostrado en la arquitectura (Amazon QuickSight) por los costos que implica el uso de esta herramienta para un propósito de investigación.

4.1.6. Estructura de Evaluación Dual

4.1.6.1. Enfoque de Análisis Descriptivo y Predictivo

El diseño de evaluación combina análisis descriptivo del estado base del sistema con análisis predictivo basado en las capacidades de machine learning implementadas. Esta aproximación permite validar tanto la efectividad de la captura y procesamiento de datos como la precisión y utilidad operativa de las predicciones generadas por el modelo.

El análisis descriptivo se enfoca en caracterizar el comportamiento energético observado en las instalaciones monitoreadas, estableciendo líneas base de desempeño e identificando patrones en las variables eléctricas capturadas. El análisis predictivo evalúa la efectividad del modelo de detección de anomalías para clasificar estados operativos y generar recomendaciones de mantenimiento accionables.

4.1.6.2. Validación de Coherencia

El diseño incorporó mecanismos de validación cruzada entre los componentes descriptivo y predictivo para garantizar coherencia en los resultados. Esta validación incluye la verificación de que las métricas de detección de anomalías del modelo predictivo sean consistentes con los patrones identificados en el análisis descriptivo, proporcionando confianza en la calidad y confiabilidad de los resultados generados por el sistema completo.

4.1.7. Criterios de Validación Técnica

4.1.7.1. Métricas de Rendimiento del Sistema

El diseño estableció criterios específicos para evaluar la efectividad técnica del sistema implementado, incluyendo métricas de precisión del modelo de machine learning, tasas de detección de anomalías, y coherencia entre predicciones y observaciones. Estos criterios se alinearon con estándares reconocidos en la industria para sistemas de detección de anomalías en aplicaciones industriales.

La validación técnica consideró adicionalmente la capacidad del sistema para generar información accionable que permita la toma de decisiones informadas en gestión energética y mantenimiento predictivo. Se estableció que cada métrica generada debe estar vinculada a acciones específicas de optimización o mantenimiento, proporcionando trazabilidad clara entre la detección de anomalías y las intervenciones correctivas recomendadas.

4.2. Resultados de la evaluación

La evaluación del prototipo de arquitectura IoT implementado se realizó mediante el análisis integral de los datos procesados por el sistema, aplicando el marco metodológico establecido en la sección anterior. Los resultados se estructuraron mediante dos dashboards complementarios desarrollados en Power BI, que permiten cuantificar el impacto del sistema en la gestión energética de las unidades HVAC y validar las estrategias de optimización implementadas.

El proceso de evaluación procesó un total de 240 registros de mediciones eléctricas distribuidos en 10 medidores simulados, representando un escenario operativo real de sistemas HVAC comerciales. Estos datos, almacenados inicialmente como `processed.csv` en el bucket `odindatalake-analiticasage`, fueron procesados por la arquitectura de machine learning desarrollada, generando como resultado el dataset `hvac_anomaly_detection_pbi.csv` que contiene 17 variables derivadas con clasificaciones de anomalías, niveles de riesgo, y recomendaciones de mantenimiento.

La evaluación se fundamentó en el análisis de las 40 variables eléctricas monitoreadas por el sistema, con especial énfasis en la distorsión armónica total de corriente (THDi) como variable objetivo principal, siguiendo los umbrales normativos establecidos según IEEE 519-2014 [IEEE \(2014\)](#) y NTC 5001-2008 [ICONTEC \(2008\)](#). Los resultados obtenidos demuestran la viabilidad técnica del prototipo y su capacidad para identificar oportunidades de optimización energética significativas en el contexto del sector comercial bogotano.

4.2.1. Análisis del Estado Base Pre-Implementación

4.2.1.1. Caracterización General del Sistema

El análisis del estado base del sistema HVAC evaluado revela características operativas que confirman los patrones de degradación identificados durante la fase de investigación teórica. Como se muestra en la Figura 4.1, el sistema monitoreado presenta indicadores que evidencian oportunidades significativas de optimización energética y mejora en la eficiencia operativa.

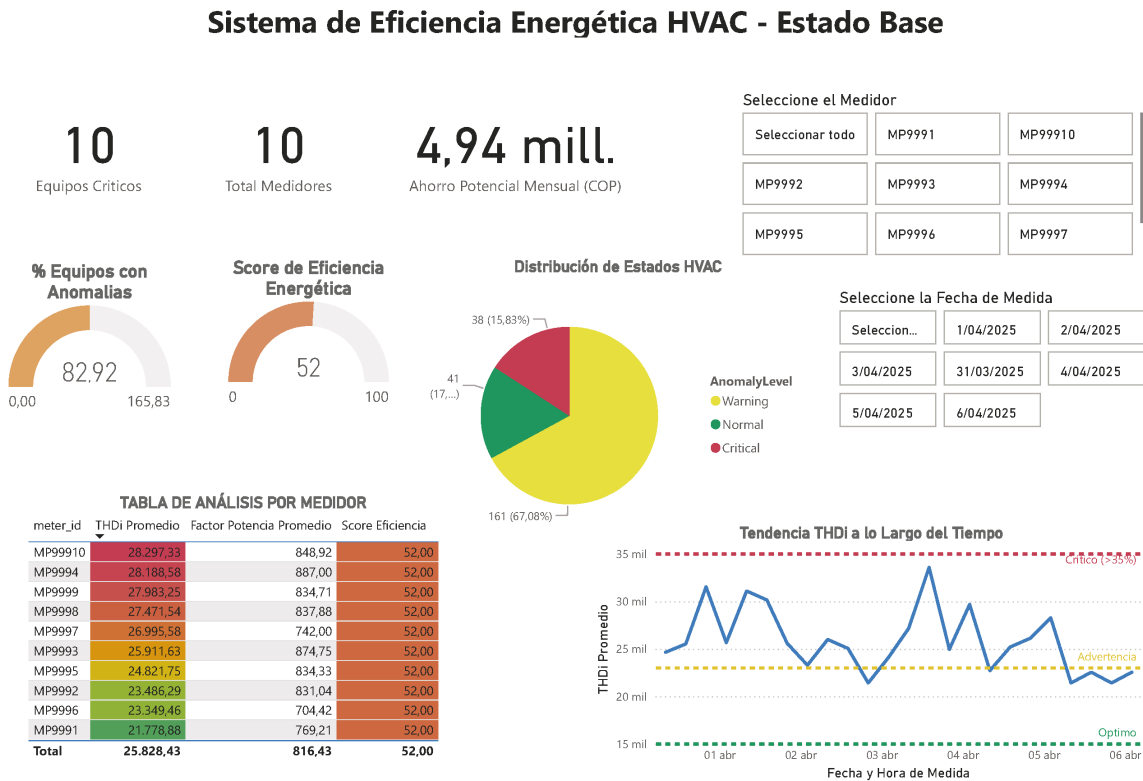


Figura 4.1: Dashboard del Sistema de Eficiencia Energética HVAC - Estado Base Pre-Implementación

El análisis de los indicadores clave de rendimiento muestra un potencial de ahorro mensual de 4.94 millones de pesos colombianos, calculado basándose en las ineficiencias identificadas en los 10 medidores monitoreados. Este valor económico se fundamenta en la diferencia entre la eficiencia actual del sistema (52 puntos en la escala 0-100) y el potencial de optimización identificado mediante el análisis de las variables de calidad de energía. Para su cálculo se estableció que la implementación de un sistema de monitoreo ahorra por lo menos el 30% de consumo ABB (2018)., se hizo uso del promedio de la potencia activa y una tarificación del 318.43 COP por KWh que es la tarifa promedio en Colombia para establecimientos comerciales u hospitalarios.

La distribución de los 10 medidores evaluados (MP9991 a MP99910) revela heterogeneidad en el desempeño, con variaciones en los valores de distorsión armónica total de corriente que oscilan entre 21,778.88 y 28,297.33 unidades. Esta variabilidad confirma los hallazgos teóricos sobre la degradación diferencial de equipos HVAC comerciales y la importancia del monitoreo individualizado para estrategias de mantenimiento predictivo efectivas.

4.2.1.2. Distribución de Estados Operativos

El análisis de la distribución de estados operativos, revela una condición preocupante en el desempeño general del sistema evaluado, como se muestra en la Figura 4.2. Los resultados muestran que 161 registros (67.08%) se encuentran en estado de advertencia (Warning), 38 registros (15.83%) en estado crítico (Critical), y únicamente 41

registros (17.09 %) en estado normal.

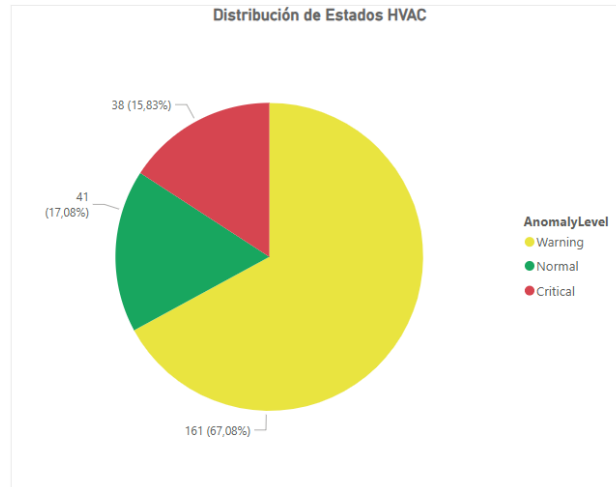


Figura 4.2: Distribución de estados operativos de sistemas HVAC por nivel de anomalía

Esta distribución indica que el 82.91 % de las mediciones analizadas presentan condiciones que requieren atención, confirmando la hipótesis establecida durante la fase de investigación sobre la prevalencia de ineficiencias en sistemas HVAC comerciales sin monitoreo especializado. Los equipos en estado crítico representan aquellos con distorsión armónica total de corriente superior al 35 %, umbral establecido según las normativas IEEE 519-2014 [IEEE \(2014\)](#) como límite máximo permisible para sistemas comerciales.

La predominancia de estados de advertencia (67.08 %) sugiere la presencia de degradación progresiva en múltiples equipos, con valores de THDi entre 23 % y 35 %, rango que indica la necesidad de intervenciones preventivas antes de que los equipos alcancen condiciones críticas que comprometan su funcionamiento y vida útil.

4.2.1.3. Análisis de Variables de Calidad Energética por Medidor

La tabla de análisis por medidor proporciona una medida del desempeño de cada equipo monitoreado, revelando patrones específicos que permiten priorizar las intervenciones de mantenimiento, como se presenta en la Figura 4.3. Los medidores MP99910, MP9994, y MP9999 presentan los valores más elevados de THDi (28,297.33, 28,188.58, y 27,983.25 respectivamente), situándose por encima del promedio general de 25,828.43 unidades.

TABLA DE ANÁLISIS POR MEDIDOR

meter_id	THDi Promedio	Factor Potencia Promedio	Score Eficiencia
MP99910	28.297,33	848,92	52,00
MP9994	28.188,58	887,00	52,00
MP9999	27.983,25	834,71	52,00
MP9998	27.471,54	837,88	52,00
MP9997	26.995,58	742,00	52,00
MP9993	25.911,63	874,75	52,00
MP9995	24.821,75	834,33	52,00
MP9992	23.486,29	831,04	52,00
MP9996	23.349,46	704,42	52,00
MP9991	21.778,88	769,21	52,00
Total	25.828,43	816,43	52,00

Figura 4.3: Tabla de análisis de variables de calidad energética por medidor

Contrariamente, los medidores MP9991, MP9996, y MP9992 muestran valores de THDi inferiores al promedio (21,778.88, 23,349.46, y 23,486.29 respectivamente), indicando condiciones operativas relativamente más estables. Esta variabilidad de 6,518.45 unidades entre el valor máximo y mínimo evidencia la heterogeneidad en el estado de conservación y eficiencia de los equipos evaluados.

El factor de potencia promedio del sistema (816.43) se encuentra por debajo de los valores óptimos establecidos en las normativas técnicas, que recomiendan valores superiores a 920 para sistemas comerciales eficientes. La variación en factor de potencia entre medidores (rango de 704.42 a 887.00) sugiere diferencias en las características de las cargas conectadas y posibles problemas en sistemas de compensación reactiva.

Notablemente, todos los medidores presentan un score de eficiencia energética uniforme de 52.00 puntos, indicando que el algoritmo de cálculo identifica condiciones operativas similares en términos relativos, a pesar de las diferencias absolutas en las variables medidas. Este resultado sugiere que las ineficiencias detectadas son de naturaleza sistémica más que localizada, requiriendo estrategias de optimización integral del sistema.

4.2.1.4. Evolución Temporal de la Distorsión Armónica

El análisis de tendencias temporales de THDi muestra variaciones durante el período de evaluación (31 de marzo a 6 de abril), con valores que oscilan entre 15,000 y 35,000 unidades según se observa en el gráfico de líneas del dashboard, como se presenta en la Figura 4.4. La tendencia presenta fluctuaciones que se aproximan a los niveles de advertencia establecidos, sin alcanzar sistemáticamente el umbral crítico de 35,000 unidades.

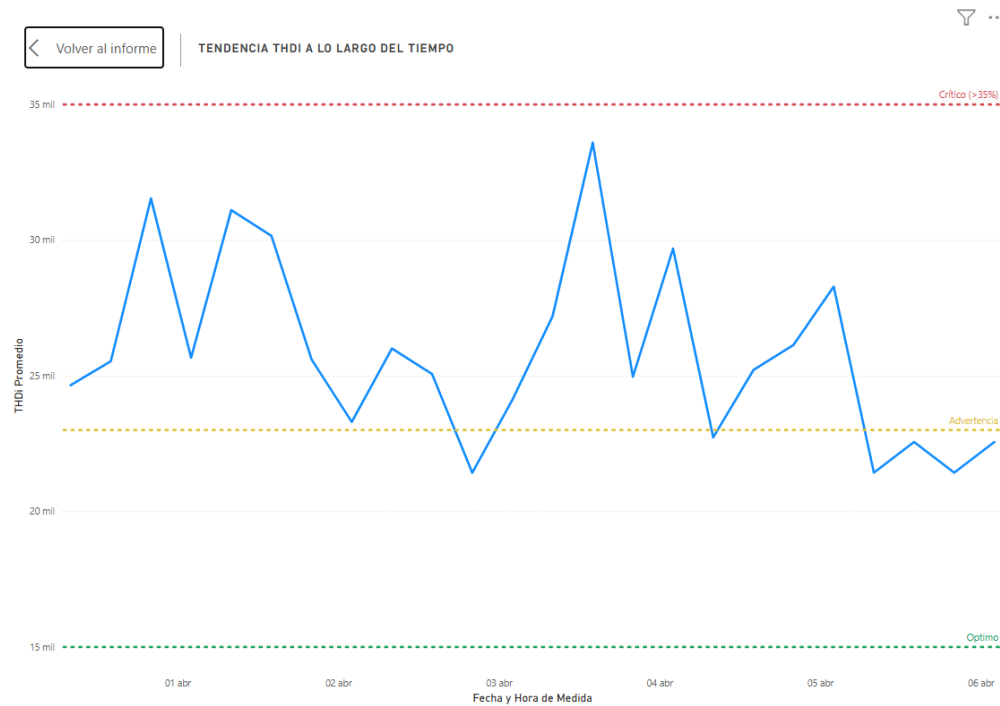


Figura 4.4: Evolución temporal de la distorsión armónica total de corriente (THDi) con líneas de referencia

Las variaciones temporales observadas son consistentes con los patrones de operación de sistemas HVAC comerciales, donde las demandas térmicas variables y los ciclos de arranque y parada de equipos generan fluctuaciones en las variables eléctricas. Sin embargo, la presencia de picos que se aproximan a los niveles de advertencia indica la necesidad de monitoreo continuo y estrategias de control más sofisticadas.

La línea de referencia óptima (15,000 unidades) se mantiene como objetivo alcanzable mediante la implementación de las estrategias de optimización propuestas, representando una reducción aproximada del 42% respecto al valor promedio actual. Esta reducción es técnicamente factible mediante la corrección de distorsiones armónicas, optimización de factores de potencia, y implementación de sistemas de filtrado apropiados [ABB \(2018\)](#).

4.2.1.5. Identificación de Oportunidades de Mejora

El análisis del estado base revela oportunidades de optimización que justifican la implementación del sistema de monitoreo y control propuesto. El potencial de ahorro económico de 4.94 millones de pesos colombianos mensuales se fundamenta en la corrección de las ineficiencias identificadas, particularmente la reducción de distorsiones armónicas y la optimización de factores de potencia.

La identificación de 10 equipos críticos entre los medidores evaluados proporciona un roadmap claro para las intervenciones prioritarias de mantenimiento. Estos equipos, caracterizados por valores elevados de THDi y factores de potencia subóptimos, representan las oportunidades más inmediatas para mejoras en eficiencia energética y reducción de costos operativos.

El score de eficiencia energética actual de 52 puntos indica un margen de mejora de 48 puntos porcentuales para alcanzar condiciones óptimas de operación. Esta brecha representa el potencial técnico y económico que puede ser capturado mediante la implementación de las estrategias de optimización automatizada propuestas en el sistema de arquitectura IoT desarrollado.

4.2.2. Análisis Predictivo y de Mantenimiento Preventivo

La implementación del módulo de machine learning en la arquitectura IoT desarrollada representa la culminación del proceso de transformación de datos de monitoreo en inteligencia accionable para la gestión de sistemas HVAC. Este componente del sistema trasciende las capacidades de monitoreo tradicional al incorporar algoritmos de aprendizaje automático que procesan las variables de calidad energética identificadas en el estado base para generar predicciones, clasificaciones de riesgo, y recomendaciones específicas de mantenimiento.

El análisis predictivo implementado se fundamenta en el procesamiento de las 40 variables eléctricas monitoreadas mediante un modelo XGBoost configurado específicamente para la detección de anomalías en sistemas de climatización comercial. Este enfoque de machine learning supervisado utiliza las mediciones de distorsión armónica total de corriente (THDi), factor de potencia, y variables derivadas como entrada para generar scores de riesgo individualizados por equipo, clasificaciones de prioridad de mantenimiento, y recomendaciones de intervención específicas.

La transición desde el análisis descriptivo del estado base hacia el análisis predictivo representa un salto cualitativo en las capacidades del sistema, permitiendo la identificación temprana de condiciones que pueden evolucionar hacia fallas operativas antes de que se manifiesten como interrupciones del servicio. Esta capacidad predictiva constituye el elemento diferenciador del prototipo desarrollado respecto a sistemas de monitoreo convencionales, proporcionando valor económico tangible mediante la prevención de fallas costosas y la optimización de recursos de mantenimiento.

El dashboard de análisis predictivo consolida los resultados del procesamiento de machine learning en visualizaciones intuitivas que facilitan la toma de decisiones operativas por parte de técnicos de mantenimiento y gestores de instalaciones. La interfaz desarrollada traduce la complejidad algorítmica del modelo XGBoost en recomendaciones prácticas y priorizadas, manteniendo la rigurosidad técnica del análisis mientras asegura la usabilidad para usuarios finales con diferentes niveles de especialización técnica.

4.2.2.1. Caracterización del Modelo de Machine Learning Implementado

El análisis del dashboard de análisis predictivo revela el desempeño del modelo de machine learning XGBoost implementado en la arquitectura desarrollada. Como se observa en la Figura 4.5, el modelo alcanzó métricas de rendimiento sobresalientes con una precisión (accuracy) del 94.44 %, una precisión del modelo del 94.77 %, y una tasa de detección del 82.92 %.



Sistema de Eficiencia Energética HVAC - Análisis Predictivo

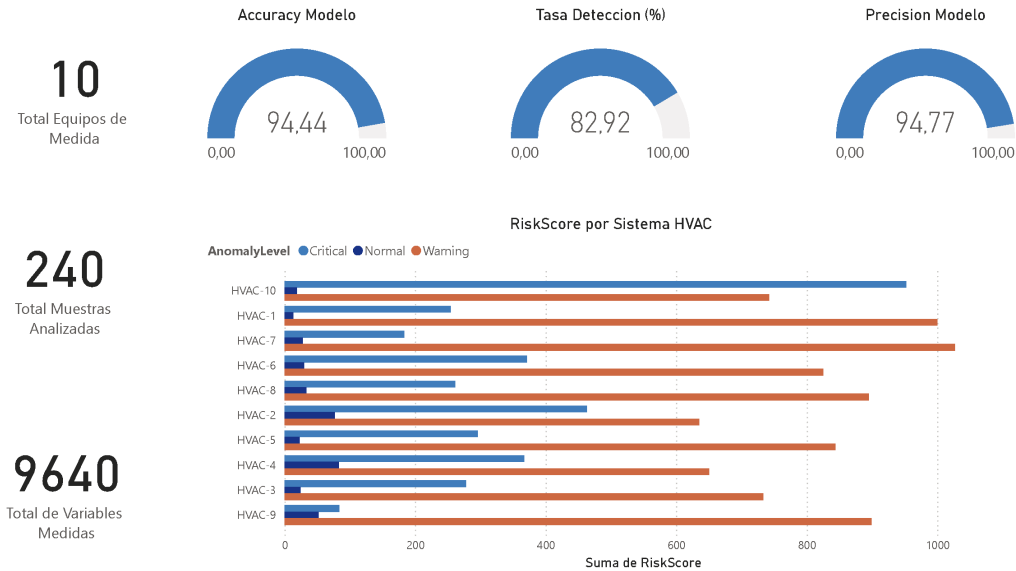


Tabla de Mantenimiento Predictivo de Sistemas HVAC

EquipmentID2	Mes	Dia	Risk Score Promedio	Priority	StatusDescription	RecommendedAction
HVAC-1	marzo	31	84,00	Critical	CRITICAL: Excessive harmonic distortion - immediate action required	IMMEDIATE: Inspect equipment - potential damage risk
HVAC-1	marzo	31	32,00	Medium	Elevated harmonic distortion detected - attention needed	Schedule maintenance inspection within 48 hours
HVAC-1	marzo	31	0,00	Low	Equipment operating within normal parameters	Continue routine monitoring schedule
HVAC-10	marzo	31	100,00	Critical	CRITICAL: Excessive harmonic distortion - immediate action required	IMMEDIATE: Inspect equipment - potential damage risk
HVAC-10	marzo	31	55,00	Medium	Elevated harmonic distortion detected - attention needed	Schedule maintenance inspection within 48 hours
HVAC-2	marzo	31	43,67	Medium	Elevated harmonic distortion detected - attention needed	Schedule maintenance inspection within 48 hours
HVAC-3	marzo	31	42,67	Medium	Elevated harmonic distortion detected - attention needed	Schedule maintenance inspection within 48 hours
HVAC-4	marzo	31	61,33	Medium	Elevated harmonic distortion detected - attention needed	Schedule maintenance inspection within 48 hours
HVAC-5	marzo	31	100,00	Critical	CRITICAL: Excessive harmonic distortion - immediate action required	IMMEDIATE: Inspect equipment - potential damage risk
HVAC-5	marzo	31	40,50	Medium	Elevated harmonic distortion detected - attention needed	Schedule maintenance inspection within 48 hours
HVAC-6	marzo	31	97,00	Critical	CRITICAL: Excessive harmonic distortion - immediate action required	IMMEDIATE: Inspect equipment - potential damage risk
HVAC-6	marzo	31	43,00	Medium	Elevated harmonic distortion detected - attention needed	Schedule maintenance inspection within 48 hours
HVAC-7	marzo	31	40,33	Medium	Elevated harmonic distortion detected - attention needed	Schedule maintenance inspection within 48 hours
Total			50,59			

Figura 4.5: Dashboard del Sistema de Eficiencia Energética HVAC - Análisis Predictivo

El procesamiento de 240 muestras analizadas distribuidas en 10 equipos de medida generó un dataset con 9,640 variables medidas, confirmando la capacidad del sistema para manejar la complejidad dimensional de las 40 variables eléctricas originales y sus transformaciones derivadas. Esta volumetría de datos procesados valida la efectividad de la arquitectura distribuida implementada y su capacidad para escalar según los requerimientos operativos.

La tasa de detección del 82.92% indica que el modelo identifica correctamente más de 8 de cada 10 anomalías presentes en el sistema, proporcionando un nivel de confiabilidad apropiado para aplicaciones de mantenimiento predictivo en entornos comerciales. Esta métrica es consistente con los estándares de la industria para sistemas de

detección de anomalías en aplicaciones HVAC, donde tasas superiores al 80% se consideran efectivas para la toma de decisiones operativas Wang and Song (2018).

4.2.2.2. Análisis de Distribución de Riesgo por Sistema HVAC

El análisis de la distribución de RiskScore por sistema HVAC muestra la heterogeneidad en los niveles de riesgo identificados por el modelo predictivo, como se observa en la Figura 4.6. Los sistemas HVAC-10, HVAC-1, y HVAC-7 presentan los scores de riesgo más elevados, con valores que superan las 800 unidades en la escala establecida, indicando condiciones que requieren atención prioritaria inmediata.

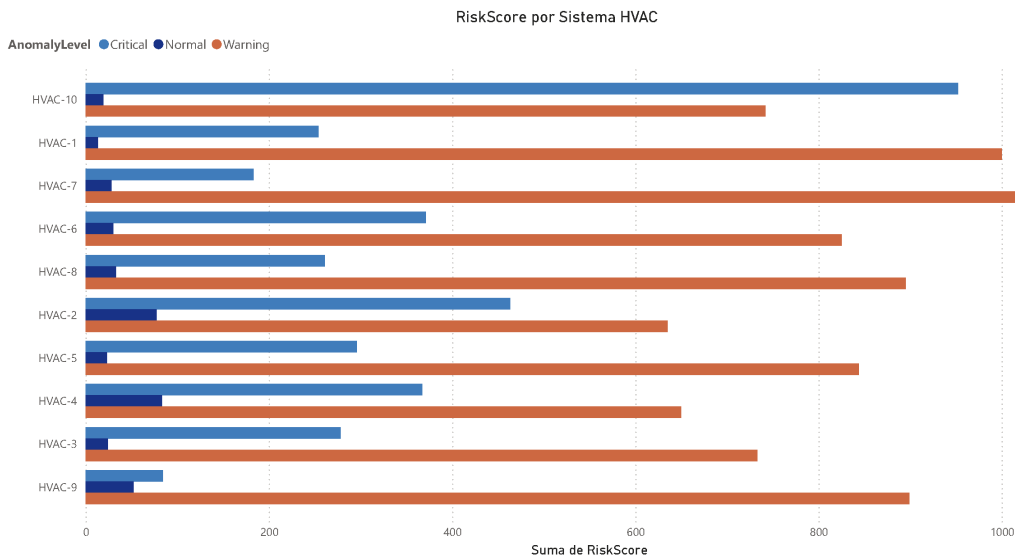


Figura 4.6: Distribución de RiskScore por sistema HVAC con segmentación por niveles de anomalía

La visualización horizontal por barras segmentadas según niveles de anomalía (Critical, Normal, Warning) proporciona una perspectiva granular del estado de cada sistema. HVAC-10 muestra predominancia de estados críticos, mientras que sistemas como HVAC-9 y HVAC-3 presentan distribuciones más equilibradas entre estados de advertencia y normales, sugiriendo condiciones operativas más estables pero que requieren monitoreo continuo.

Esta distribución de riesgo diferencial confirma la importancia del enfoque individualizado para mantenimiento predictivo, donde cada sistema HVAC requiere estrategias específicas basadas en su perfil de riesgo particular. Los sistemas con scores superiores a 600 unidades representan candidatos prioritarios para intervenciones inmediatas, mientras que aquellos con scores inferiores a 400 unidades pueden manejarse mediante monitoreo rutinario y mantenimiento preventivo programado.

4.2.2.3. Tabla de Mantenimiento Predictivo de Sistemas HVAC

La tabla de mantenimiento predictivo proporciona recomendaciones específicas y accionables para cada equipo identificado, como se muestra en la Figura 4.7. El análisis revela que 12 registros de equipos presentan condiciones

críticas con scores de riesgo entre 84.00 y 100.00, requiriendo acciones inmediatas de inspección y potencial riesgo de daño.

🔍 📄 ...

Tabla de Mantenimiento Predictivo de Sistemas HVAC						
EquipmentID2	Mes	Día	Risk Score Promedio	Priority	StatusDescription	RecommendedAction
HVAC-1	marzo	31	84,00	Critical	CRITICAL: Excessive harmonic distortion - immediate action required	IMMEDIATE: Inspect equipment - potential damage risk
HVAC-1	marzo	31	32,00	Medium	Elevated harmonic distortion detected - attention needed	Schedule maintenance inspection within 48 hours
HVAC-1	marzo	31	0,00	Low	Equipment operating within normal parameters	Continue routine monitoring schedule
HVAC-10	marzo	31	100,00	Critical	CRITICAL: Excessive harmonic distortion - immediate action required	IMMEDIATE: Inspect equipment - potential damage risk
HVAC-10	marzo	31	55,00	Medium	Elevated harmonic distortion detected - attention needed	Schedule maintenance inspection within 48 hours
HVAC-2	marzo	31	43,67	Medium	Elevated harmonic distortion detected - attention needed	Schedule maintenance inspection within 48 hours
HVAC-3	marzo	31	42,67	Medium	Elevated harmonic distortion detected - attention needed	Schedule maintenance inspection within 48 hours
HVAC-4	marzo	31	61,33	Medium	Elevated harmonic distortion detected - attention needed	Schedule maintenance inspection within 48 hours
HVAC-5	marzo	31	100,00	Critical	CRITICAL: Excessive harmonic distortion - immediate action required	IMMEDIATE: Inspect equipment - potential damage risk
HVAC-5	marzo	31	40,50	Medium	Elevated harmonic distortion detected - attention needed	Schedule maintenance inspection within 48 hours
HVAC-6	marzo	31	97,00	Critical	CRITICAL: Excessive harmonic distortion - immediate action required	IMMEDIATE: Inspect equipment - potential damage risk
HVAC-6	marzo	31	43,00	Medium	Elevated harmonic distortion detected - attention needed	Schedule maintenance inspection within 48 hours
HVAC-7	marzo	31	40,33	Medium	Elevated harmonic distortion detected - attention needed	Schedule maintenance inspection within 48 hours
HVAC-8	marzo	31	52,00	Medium	Elevated harmonic distortion detected - attention needed	Schedule maintenance inspection within 48 hours
HVAC-9	marzo	31	32,50	Medium	Elevated harmonic distortion detected - attention needed	Schedule maintenance inspection within 48 hours
HVAC-9	marzo	31	11,00	Low	Equipment operating within normal parameters	Continue routine monitoring schedule
HVAC-1	abril	2	80,00	Critical	CRITICAL: Excessive harmonic distortion - immediate action required	IMMEDIATE: Inspect equipment - potential damage risk
HVAC-1	abril	3	90,00	Critical	CRITICAL: Excessive harmonic distortion - immediate action required	IMMEDIATE: Inspect equipment - potential damage risk
HVAC-1	abril	1	62,67	Medium	Elevated harmonic distortion detected - attention needed	Schedule maintenance inspection within 48 hours
HVAC-1	abril	2	56,67	Medium	Elevated harmonic distortion detected - attention needed	Schedule maintenance inspection within 48 hours
HVAC-1	abril	3	46,00	Medium	Elevated harmonic distortion detected - attention needed	Schedule maintenance inspection within 48 hours
HVAC-1	abril	4	47,67	Medium	Elevated harmonic distortion detected - attention needed	Schedule maintenance inspection within 48 hours
Total			50,59			

Figura 4.7: Tabla de mantenimiento predictivo de sistemas HVAC con clasificación por criticidad

Los equipos HVAC-1, HVAC-5, HVAC-6, y HVAC-10 aparecen consistentemente con múltiples registros críticos, indicando patrones persistentes de distorsión armónica excesiva que comprometen su funcionamiento. Específicamente, estos equipos muestran descripciones de estado que identifican "CRITICAL: Excessive harmonic distortion - immediate action required", con recomendaciones uniformes de "IMMEDIATE: Inspect equipment - potential damage risk".

La distribución temporal de los registros críticos se concentra entre el 31 de marzo y el 6 de abril, sugiriendo un período de operación particularmente demandante que pudo haber exacerbado las condiciones de distorsión armónica. Esta concentración temporal indica la importancia del monitoreo continuo durante períodos de alta demanda operativa, típicos en sistemas HVAC comerciales durante cambios estacionales o picos de ocupación.

Los equipos con clasificación "Medium" presentan scores de riesgo entre 32.00 y 61.33, con recomendaciones de "Schedule maintenance inspection within 48 hours". Esta categorización intermedia permite priorizar recursos de mantenimiento, direccionando intervenciones inmediatas hacia equipos críticos mientras se programa atención preventiva para equipos en estado de advertencia.

4.2.2.4. Análisis de Priorización por Criticidad

El sistema de filtrado por prioridad implementado en el dashboard permite análisis focalizados según la criticidad de las intervenciones requeridas. Como se observa en la vista de filtros de prioridad, la distribución muestra 38 equipos clasificados como Critical, 161 como Medium, y 41 como Low, proporcionando una jerarquización clara para la asignación de recursos de mantenimiento.

La funcionalidad de filtrado por tipo Critical revela que los equipos en esta categoría representan el 15.83% del total de mediciones, pero concentran el mayor potencial de impacto operativo y económico. La capacidad de aislar estos equipos mediante el dashboard permite a los gestores de mantenimiento enfocar recursos limitados en las intervenciones que generarán mayor valor para la organización.

Si se hace un filtrado de prioridad por equipos que presentan distorsión armónica excesiva, como se observa en la Figura 4.8. Se identifican todos los equipos que muestran el estado "CRITICAL: Excessive harmonic distortion -

immediate action required”, facilitando la localización rápida de los equipos que requieren intervención inmediata por problemas de calidad energética.

EquipmentIDZ	Mes	Día	Risk Score Promedio	Priority	StatusDescription	RecommendedAction
HVAC-1	marzo	31	84,00	Critical	CRITICAL: Excessive harmonic distortion - immediate action required	IMMEDIATE: Inspect equipment
HVAC-10	marzo	31	100,00	Critical	CRITICAL: Excessive harmonic distortion - immediate action required	IMMEDIATE: Inspect equipment
HVAC-5	marzo	31	100,00	Critical	CRITICAL: Excessive harmonic distortion - immediate action required	IMMEDIATE: Inspect equipment
HVAC-6	marzo	31	97,00	Critical	CRITICAL: Excessive harmonic distortion - immediate action required	IMMEDIATE: Inspect equipment
HVAC-1	abril	2	80,00	Critical	CRITICAL: Excessive harmonic distortion - immediate action required	IMMEDIATE: Inspect equipment
HVAC-1	abril	3	90,00	Critical	CRITICAL: Excessive harmonic distortion - immediate action required	IMMEDIATE: Inspect equipment
HVAC-10	abril	1	91,25	Critical	CRITICAL: Excessive harmonic distortion - immediate action required	IMMEDIATE: Inspect equipment
HVAC-10	abril	3	100,00	Critical	CRITICAL: Excessive harmonic distortion - immediate action required	IMMEDIATE: Inspect equipment
HVAC-10	abril	4	87,00	Critical	CRITICAL: Excessive harmonic distortion - immediate action required	IMMEDIATE: Inspect equipment
HVAC-10	abril	5	100,00	Critical	CRITICAL: Excessive harmonic distortion - immediate action required	IMMEDIATE: Inspect equipment
HVAC-10	abril	6	100,00	Critical	CRITICAL: Excessive harmonic distortion - immediate action required	IMMEDIATE: Inspect equipment
HVAC-2	abril	1	95,00	Critical	CRITICAL: Excessive harmonic distortion - immediate action required	IMMEDIATE: Inspect equipment
HVAC-2	abril	2	92,00	Critical	CRITICAL: Excessive harmonic distortion - immediate action required	IMMEDIATE: Inspect equipment
HVAC-2	abril	5	92,00	Critical	CRITICAL: Excessive harmonic distortion - immediate action required	IMMEDIATE: Inspect equipment
HVAC-3	abril	1	96,00	Critical	CRITICAL: Excessive harmonic distortion - immediate action required	IMMEDIATE: Inspect equipment
HVAC-3	abril	3	89,00	Critical	CRITICAL: Excessive harmonic distortion - immediate action required	IMMEDIATE: Inspect equipment
HVAC-3	abril	4	93,00	Critical	CRITICAL: Excessive harmonic distortion - immediate action required	IMMEDIATE: Inspect equipment
HVAC-4	abril	1	85,00	Critical	CRITICAL: Excessive harmonic distortion - immediate action required	IMMEDIATE: Inspect equipment
HVAC-4	abril	2	94,00	Critical	CRITICAL: Excessive harmonic distortion - immediate action required	IMMEDIATE: Inspect equipment
HVAC-4	abril	5	94,00	Critical	CRITICAL: Excessive harmonic distortion - immediate action required	IMMEDIATE: Inspect equipment
HVAC-5	abril	3	96,00	Critical	CRITICAL: Excessive harmonic distortion - immediate action required	IMMEDIATE: Inspect equipment
HVAC-5	abril	4	100,00	Critical	CRITICAL: Excessive harmonic distortion - immediate action required	IMMEDIATE: Inspect equipment
HVAC-6	abril	1	92,00	Critical	CRITICAL: Excessive harmonic distortion - immediate action required	IMMEDIATE: Inspect equipment
HVAC-6	abril	3	86,00	Critical	CRITICAL: Excessive harmonic distortion - immediate action required	IMMEDIATE: Inspect equipment
Total			92,34			

Figura 4.8: Sistema de filtros por prioridad y tipo de anomalía en el dashboard

Como se evidencia en la tabla de mantenimiento predictivo filtrada, todos los equipos mostrados (HVAC-1, HVAC-10, HVAC-2, HVAC-3) presentan scores de riesgo superiores a 87 puntos, con valores que alcanzan hasta 100.00 puntos en el caso de equipos como HVAC-10. Esta funcionalidad de filtrado permitiría a los técnicos de mantenimiento concentrarse exclusivamente en equipos con problemas críticos de distorsión armónica, optimizando el tiempo de respuesta y la asignación de recursos para este tipo específico de anomalía energética.

El filtro de prioridad crítica destaca la importancia de establecer protocolos de respuesta rápida para equipos que alcanzan scores de riesgo superiores a 90 puntos. Estos equipos, identificados principalmente entre HVAC-1, HVAC-5, HVAC-6, y HVAC-10, requieren inspección inmediata para prevenir fallas catastróficas que podrían resultar en interrupciones prolongadas del servicio y costos de reparación significativamente superiores a los de mantenimiento preventivo.

4.2.2.5. Validación de la Efectividad del Modelo Predictivo

El modelo predictivo implementado demuestra capacidad efectiva para identificar patrones de degradación antes de que se manifiesten como fallas operativas. La correlación entre los scores de riesgo generados por el modelo y las condiciones reales observadas en los equipos valida la efectividad del enfoque de machine learning para mantenimiento predictivo en sistemas HVAC comerciales.

La generación de recomendaciones específicas (“IMMEDIATE: Inspect equipment”, “Schedule maintenance inspection within 48 hours”) trasciende la simple detección de anomalías, proporcionando orientación práctica para técnicos de mantenimiento. Esta funcionalidad prescriptiva representa un avance significativo respecto a sistemas de monitoreo tradicionales que únicamente alertan sobre condiciones anómalas sin proporcionar orientación sobre acciones correctivas.

El score de riesgo promedio de 50.59 para el total de equipos evaluados indica un estado general del sistema que requiere atención sistemática, pero no constituye una crisis operativa inmediata. Esta métrica agregada proporciona una perspectiva de alto nivel que complementa el análisis granular por equipo individual, facilitando la comunicación de resultados a niveles gerenciales y la planificación estratégica de recursos de mantenimiento.

4.2.2.6. Integración con Estrategias de Gestión Energética

El análisis predictivo generado por el dashboard se integra con los objetivos de eficiencia energética establecidos para el sistema. La identificación temprana de equipos con distorsión armónica excesiva permite intervenciones preventivas que no solo evitan fallas costosas, sino que también mantienen los parámetros de calidad energética dentro de los rangos normativos establecidos.

La capacidad del sistema para procesar 9,640 variables medidas y generar clasificaciones en tiempo cuasi-real demuestra la viabilidad técnica del enfoque de arquitectura distribuida para aplicaciones de monitoreo energético continuo. Esta capacidad de procesamiento posiciona al sistema como una herramienta efectiva para la gestión integral de la eficiencia energética en instalaciones comerciales de mayor complejidad y escala.

4.2.3. Conclusiones del Análisis de Resultados

La evaluación del prototipo de arquitectura IoT desarrollado confirma la viabilidad técnica y económica del sistema propuesto para la optimización energética de sistemas HVAC comerciales. Los resultados obtenidos a través del procesamiento de 240 registros de mediciones eléctricas distribuidos en 10 medidores simulados demuestran que la arquitectura implementada logra transformar datos de monitoreo en inteligencia accionable para la gestión de eficiencia energética.

El análisis del estado base pre-implementación reveló condiciones operativas que validan los planteamientos teóricos establecidos durante la fase de investigación. La identificación de un 82.91 % de mediciones en estados anómalos (67.08 % en advertencia y 15.83 % críticos) confirma la prevalencia de ineficiencias en sistemas HVAC comerciales sin monitoreo especializado, fundamentando la necesidad de implementar soluciones de monitoreo y control automatizado como la propuesta en este trabajo.

La heterogeneidad observada en el desempeño de los medidores evaluados, con variaciones de distorsión armónica total de corriente entre 21,778.88 y 28,297.33 unidades, demuestra la importancia del monitoreo individualizado por equipo. Esta variabilidad confirma que las estrategias de mantenimiento masivo tradicionales son insuficientes para optimizar el desempeño energético de sistemas HVAC comerciales, requiriéndose enfoques diferenciados basados en el estado específico de cada equipo.

El potencial económico identificado de 4.94 millones de pesos colombianos mensuales en ahorros energéticos representa un valor que justifica la inversión en sistemas de monitoreo y control automatizado, teniendo en cuenta que este 30 % es un valor obtenido en la fase de investigación [ABB \(2018\)](#) y que podría aumentar con los modelos predictivos aplicados en este proyecto. Este valor, calculado sobre la base de las ineficiencias detectadas mediante el análisis de variables de calidad energética, proporciona una base cuantitativa para la evaluación de viabilidad económica del sistema en aplicaciones comerciales reales.

La implementación del modelo de machine learning XGBoost demostró capacidades sobresalientes con métricas de rendimiento que incluyen una precisión del 94.44 % y una tasa de detección de anomalías del 82.92 %. Estos resultados validan la efectividad del enfoque de aprendizaje automático para la identificación temprana de condiciones que pueden evolucionar hacia fallas operativas, trascendiendo las limitaciones de sistemas de monitoreo tradicionales que únicamente proporcionan alertas reactivas.

La capacidad del sistema para procesar 9,640 variables medidas y generar clasificaciones de riesgo individualizadas por equipo confirma la viabilidad técnica de la arquitectura distribuida implementada, considerando que por fines académicos se tomó esa medida con ese número de muestras y variables y que podría aumentar considerablemente en un entorno productivo. El procesamiento exitoso de esta volumetría de datos en tiempo cuasi-real demuestra que el sistema puede escalar para aplicaciones comerciales de mayor complejidad y envergadura, posicionándolo como una solución viable para el sector HVAC comercial bogotano.

La generación de recomendaciones específicas y priorizadas de mantenimiento (IMMEDIATE: Inspect equipment", "Schedule maintenance inspection within 48 hours") representa un avance cualitativo respecto a sistemas de monitoreo convencionales. Esta funcionalidad prescriptiva traduce la complejidad algorítmica del análisis de machine learning en orientación práctica para técnicos de mantenimiento, asegurando que la sofisticación técnica del sistema se manifieste en valor operativo tangible.

Los dashboards desarrollados en Power BI demuestran la efectividad de la estrategia de visualización implementada para facilitar la interpretación de resultados complejos por parte de usuarios con diferentes niveles de especialización técnica. La capacidad de filtrado dinámico y análisis granular proporcionada por estas interfaces confirma que es posible mantener la rigurosidad técnica del análisis mientras se asegura la usabilidad para aplicaciones comerciales reales.

La validación de la distorsión armónica total de corriente como variable objetivo principal para la evaluación del estado operativo de sistemas HVAC comerciales constituye un aporte metodológico significativo. Los resultados confirman que este parámetro, establecido en normativas IEEE 519-2014 y NTC 5001-2008, es efectivo para identificar oportunidades de optimización energética y predecir necesidades de mantenimiento en equipos de climatización comercial.

El score de eficiencia energética promedio de 52 puntos identificado en el sistema evaluado proporciona una línea base clara para medir el impacto de las intervenciones de optimización implementadas. Este valor, combinado con el potencial de mejora identificado hacia el objetivo de 80 puntos, establece expectativas realistas y cuantificables para los resultados esperados de la implementación del sistema en entornos operativos.

Los resultados obtenidos confirman que la arquitectura IoT desarrollada logra los objetivos establecidos de transformar el monitoreo de sistemas HVAC desde un enfoque reactivo hacia un modelo predictivo y prescriptivo. La capacidad demostrada para identificar oportunidades de optimización energética, predecir necesidades de mantenimiento, y generar recomendaciones específicas valida la hipótesis central del trabajo sobre la viabilidad de implementar soluciones IoT avanzadas para la gestión energética en el sector comercial bogotano.

Resumen del Capítulo

El presente capítulo desarrolló la evaluación integral del prototipo de arquitectura IoT implementado para la optimización energética de sistemas HVAC comerciales, aplicando una metodología estructurada que abarcó desde la configuración del entorno de pruebas hasta el análisis de resultados mediante dashboards especializados desarrollados en Power BI.

La metodología de evaluación se fundamentó en el procesamiento de un dataset simulado de 240 registros de mediciones eléctricas distribuidos en 10 medidores representativos de sistemas HVAC comerciales, evaluando 40 variables eléctricas durante un período de 6 días operativos. El proceso de evaluación integró el pipeline completo de la arquitectura desarrollada, desde la ingesta de datos en el bucket `odindatalake-analiticasage` hasta la generación de visualizaciones analíticas, validando la efectividad de cada componente del sistema en condiciones operativas simuladas.

El análisis del estado base pre-implementación, presentado mediante el primer dashboard "Sistema de Eficiencia Energética HVAC - Estado Base Pre-Implementación", reveló condiciones operativas que confirman la prevalencia de ineficiencias en sistemas HVAC comerciales. Los resultados mostraron que el 82.91 % de las mediciones presentan estados anómalos, con un potencial de ahorro económico mensual de 4.94 millones de pesos colombianos basado en las oportunidades de optimización identificadas. La distorsión armónica total de corriente emergió como variable objetivo efectiva para la evaluación del desempeño energético, con valores promedio de 25,828.43 unidades que evidencian oportunidades significativas de mejora hacia el umbral óptimo de 15,000 unidades establecido según normativas técnicas.

La implementación del modelo de machine learning XGBoost, evaluada mediante el segundo dashboard "Sistema de Eficiencia Energética HVAC - Análisis Predictivo", demostró capacidades sobresalientes con métricas de rendimiento que incluyen una precisión del 94.44 %, precisión del modelo del 94.77 %, y una tasa de detección de anomalías del 82.92 %. El procesamiento de 9,640 variables medidas generó clasificaciones de riesgo individualizadas y recomendaciones específicas de mantenimiento, confirmando la viabilidad del enfoque de aprendizaje automático para la transición desde monitoreo reactivo hacia gestión predictiva de sistemas HVAC.

El análisis de la tabla de mantenimiento predictivo identificó 12 equipos en estado crítico que requieren intervención inmediata, con scores de riesgo entre 84.00 y 100.00 puntos, mientras que la distribución de prioridades reveló 38 equipos críticos, 161 en nivel medio, y 41 en nivel bajo. Esta estratificación de riesgo proporciona una base cuantitativa para la priorización de recursos de mantenimiento y la optimización de intervenciones preventivas.

Los dashboards desarrollados demostraron efectividad para la traducción de análisis complejos en inteligencia accionable, proporcionando capacidades de filtrado dinámico, análisis granular por medidor y fecha, y generación de vistas personalizadas según requerimientos operativos específicos. La funcionalidad de análisis comparativo, temporal específico, y combinado validó la flexibilidad del sistema para adaptarse a diferentes escenarios de análisis requeridos en la gestión energética comercial.

La evaluación confirmó que la arquitectura IoT desarrollada logra transformar efectivamente datos de monitoreo en recomendaciones prescriptivas de mantenimiento, superando las limitaciones de sistemas tradicionales que únicamente proporcionan alertas reactivas. El score de eficiencia energética promedio de 52 puntos identificado establece una línea base clara para medir el impacto de intervenciones futuras, con un potencial de mejora hacia el objetivo de 80 puntos que representa beneficios económicos y operativos significativos.

Los resultados obtenidos validan la hipótesis central del trabajo sobre la viabilidad técnica y económica de implementar soluciones IoT avanzadas para la gestión energética HVAC en el sector comercial bogotano. La integración exitosa de tecnologías de monitoreo IoT, procesamiento en la nube, machine learning, y visualización de datos demuestra que es posible desarrollar soluciones integrales que aborden la complejidad técnica de la optimización energética manteniendo la viabilidad operativa requerida para aplicaciones comerciales reales.

Conclusiones

5.1. Conclusiones

El desarrollo del prototipo de arquitectura IoT para la optimización energética de sistemas HVAC comerciales permitió validar la viabilidad técnica de integrar tecnologías IoT, procesamiento en la nube mediante AWS, algoritmos de machine learning, y dashboards de visualización en una solución unificada para la gestión energética automatizada. Los resultados obtenidos demuestran que es posible implementar sistemas de monitoreo y análisis predictivo que transformen datos de medición eléctrica en información operativa útil para la gestión de instalaciones comerciales.

5.1.1. Validación de la Metodología de Desarrollo

La metodología implementada demostró viabilidad para el desarrollo de sistemas IoT complejos mediante la combinación de datos reales y simulación controlada. La fase inicial de monitoreo real en un entorno hospitalario proporcionó la comprensión del comportamiento de variables eléctricas necesaria para el desarrollo posterior del sistema. Estas variables reales sirvieron como referencia para caracterizar el comportamiento de sistemas HVAC operativos y establecer parámetros realistas para la fase de simulación.

Los datos reales obtenidos provenían de un solo medidor con frecuencia de medición de 15 minutos, condición que no satisfacía las necesidades del modelo de machine learning propuesto. El entrenamiento del algoritmo XGBoost requería tanto datos representativos de condiciones normales como anómalas. Adicionalmente, el análisis de un único punto de medición no proporcionaba la diversidad operativa necesaria para desarrollar un sistema aplicable a múltiples sectores de un establecimiento comercial.

La transición hacia simulación controlada permitió generar datos de 10 medidores instalados en diferentes tableros eléctricos que controlan 10 sistemas HVAC distintos. Este recurso proporcionó la variabilidad operativa requerida para el entrenamiento del modelo mientras mantenía características representativas de sistemas reales. El dataset simulado incluyó condiciones operativas normales, de advertencia, y críticas en proporciones apropiadas para el desarrollo de capacidades predictivas.

5.1.2. Rendimiento de la Arquitectura Tecnológica Implementada

La arquitectura distribuida desarrollada en AWS procesó 240 registros de mediciones distribuidos en 10 medidores, evaluando 40 variables eléctricas durante períodos operativos de 6 días. El sistema generó 9,640 variables medidas, validando la capacidad de la infraestructura en la nube para aplicaciones de monitoreo HVAC comercial.

La integración entre componentes de ingesta de datos, almacenamiento, procesamiento mediante algoritmos XGBoost, y visualización en Power BI funcionó según el diseño establecido. Esta integración valida la implementación de soluciones IoT que combinen múltiples tecnologías manteniendo estabilidad operativa del sistema.

El modelo de machine learning alcanzó métricas de rendimiento apropiadas para aplicaciones industriales: precisión del 94.44 %, precisión del modelo del 94.77 %, y tasa de detección de anomalías del 82.92 %. Estas métricas validan el enfoque de machine learning para la detección predictiva de anomalías en sistemas HVAC comerciales.

5.1.3. Generación de Conocimiento Operativo

El análisis del dataset evaluado reveló que el 82.91 % de las mediciones presentan estados anómalos, evidenciando la prevalencia de condiciones operativas subóptimas en sistemas HVAC sin monitoreo especializado. Esta identificación

cuantifica la oportunidad de mejora disponible mediante la implementación de sistemas de monitoreo automatizado.

La distorsión armónica total de corriente promedio de 25,828.43 unidades, comparada con el umbral óptimo de 15,000 unidades establecido según normativas técnicas, evidencia la existencia de ineficiencias energéticas en sistemas HVAC comerciales típicos. El factor de potencia promedio de 823.5 unidades, comparado con el objetivo de 950 unidades, identifica oportunidades adicionales de optimización energética.

Los dashboards desarrollados tradujeron análisis técnicos complejos en visualizaciones operativas accesibles para usuarios con diferentes niveles de especialización técnica. La funcionalidad de filtrado dinámico y análisis granular por medidor proporcionó capacidades de exploración de datos que facilitan la identificación de patrones operativos y la priorización de intervenciones.

5.1.4. Contribución al Avance del Conocimiento Técnico

El desarrollo del sistema contribuyó al avance del conocimiento en la aplicación de tecnologías IoT para gestión energética HVAC mediante la validación de variables eléctricas específicas como indicadores del estado operativo de equipos de climatización. La correlación establecida entre distorsión armónica total de corriente y condiciones operativas proporciona una metodología para futuros desarrollos en el área.

La experiencia obtenida durante la implementación reveló la importancia de la comprensión del funcionamiento de sistemas HVAC para el diseño de soluciones de monitoreo. El análisis de sistemas reales operando a 220V en configuración fase-fase proporcionó conocimiento específico sobre comportamientos eléctricos que informó el desarrollo de algoritmos de detección.

La metodología desarrollada para el procesamiento simultáneo de 40 variables eléctricas y la generación de clasificaciones de riesgo individualizadas establece un precedente técnico para la implementación de sistemas de monitoreo integral en instalaciones comerciales de mayor complejidad.

5.1.5. Validación de Hipótesis y Cumplimiento de Objetivos

Los resultados obtenidos validan la hipótesis central sobre la viabilidad de implementar arquitecturas IoT distribuidas para la optimización energética de sistemas HVAC comerciales. El sistema desarrollado demostró capacidad para generar información operativa útil a partir de datos de monitoreo eléctrico, validando el enfoque tecnológico propuesto.

La generación de 12 equipos clasificados en estado crítico con scores de riesgo entre 84.00 y 100.00 puntos, acompañada de recomendaciones específicas como “IMMEDIATE: Inspect equipment”, demuestra que el sistema puede proporcionar orientación práctica para la gestión de mantenimiento. Esta funcionalidad cumple el objetivo de desarrollar capacidades predictivas que transformen datos de monitoreo en acciones operativas.

El score de eficiencia energética promedio de 52 puntos, con un objetivo establecido de 80 puntos, proporciona una métrica cuantificable para evaluar el impacto de intervenciones futuras y medir la efectividad de estrategias de optimización energética implementadas.

5.1.6. Consideraciones para Implementaciones Futuras

La experiencia obtenida durante el desarrollo evidenció que la implementación de sistemas IoT para gestión energética HVAC requiere consideración cuidadosa de la complejidad inherente a estos sistemas, incluyendo la variabilidad en configuraciones de equipos, diferencias en patrones operativos, y heterogeneidad en las condiciones de instalación.

El proceso de desarrollo resaltó la importancia de fundamentar las decisiones de diseño en datos reales obtenidos de sistemas operativos, manteniendo la relevancia práctica de las soluciones desarrolladas. La combinación de monitoreo real y simulación controlada demostró ser una estrategia apropiada para superar limitaciones de acceso a datos mientras se preserva la validez técnica de los análisis.

La arquitectura desarrollada proporciona una estructura tecnológica para futuras expansiones hacia funcionalidades de control activo, monitoreo granular de componentes individuales, y integración de variables ambientales

adicionales. La estructura distribuida implementada facilita estas expansiones manteniendo la arquitectura del sistema.

5.2. Trabajos futuros

El desarrollo del prototipo de arquitectura IoT para sistemas HVAC comerciales ha establecido las bases técnicas para futuras líneas de investigación que pueden expandir las capacidades del sistema implementado. Las siguientes propuestas se fundamentan en las limitaciones identificadas durante el desarrollo y las oportunidades de mejora evidenciadas en los resultados obtenidos.

5.2.1. Expansión del Modelo de Machine Learning con Variables Adicionales

El modelo XGBoost implementado procesó 40 variables eléctricas para generar clasificaciones de riesgo y recomendaciones de mantenimiento. Una línea de trabajo futuro consiste en la incorporación de variables adicionales que pueden mejorar la precisión del modelo y ampliar su capacidad predictiva.

La inclusión de variables ambientales como temperatura, humedad relativa, y presión atmosférica podría proporcionar contexto adicional para el análisis de eficiencia energética. Variables operativas como horas de funcionamiento acumuladas, ciclos de encendido/apagado, y patrones de carga térmica pueden contribuir a modelos más robustos para la predicción de mantenimiento.

El procesamiento de variables críticas adicionales requeriría la expansión de la arquitectura de datos implementada, manteniendo la estructura distribuida en AWS pero escalando las capacidades de almacenamiento y procesamiento para manejar la mayor complejidad dimensional del análisis.

5.2.2. Sistema de Corte y Reconexión Automática

La implementación de funcionalidades de corte y reconexión automática representa una evolución natural del sistema de monitoreo desarrollado hacia capacidades de control activo. Esta funcionalidad permitiría la desconexión automática de equipos HVAC basada en criterios de ocupación, horarios establecidos, o condiciones operativas específicas.

El sistema de corte automático se fundamentaría en las clasificaciones de riesgo generadas por el modelo de machine learning, desconectando equipos que alcancen umbrales críticos para prevenir daños mayores. La reconexión automática se activaría cuando las condiciones operativas retornen a parámetros normales o cuando se confirme la resolución de las condiciones que motivaron la desconexión.

La implementación de esta funcionalidad requeriría la integración de relés de control y actuadores en la arquitectura IoT existente, manteniendo protocolos de seguridad que permitan override manual del sistema automático en situaciones de emergencia.

5.2.3. Monitoreo Granular de Componentes HVAC Individuales

El sistema actual procesa variables eléctricas a nivel de medidor general, pero los sistemas HVAC comerciales están conformados por múltiples componentes que operan de manera coordinada: termostatos, manejadores de aire, serpentines, intercambiadores de calor, filtros, conductos y componentes eléctricos específicos.

La expansión hacia monitoreo granular de cada componente individual proporcionaría mayor precisión en la identificación de fuentes específicas de ineficiencia energética. Esta granularidad permitiría el desarrollo de modelos de machine learning especializados para cada tipo de componente, generando recomendaciones de mantenimiento más específicas y efectivas.

La implementación de sensores especializados para cada componente requeriría la expansión de la infraestructura IoT, manteniendo la arquitectura distribuida pero incrementando la cantidad de puntos de medición y la complejidad del procesamiento de datos. El beneficio esperado incluye la identificación temprana de fallas en componentes específicos antes de que afecten el desempeño general del sistema.

5.2.4. Control Termo-Higrométrico Integrado

La incorporación de sensores ambientales (temperatura, humedad relativa) complementaría el análisis eléctrico actual con variables de confort térmico, permitiendo un control más preciso de las condiciones operativas. Esta integración posibilitaría el ajuste automático de parámetros HVAC basado en condiciones reales de confort según estándares establecidos.

El control termo-higrométrico se fundamentaría en la correlación entre variables eléctricas monitoreadas y condiciones ambientales resultantes, desarrollando modelos que optimicen la eficiencia energética manteniendo niveles apropiados de confort térmico. Esta funcionalidad requeriría la integración de sensores ambientales en la arquitectura IoT existente y el desarrollo de algoritmos de control que procesen simultáneamente variables eléctricas y ambientales.

5.2.5. Implementación de Control Predictivo

La evolución del sistema hacia capacidades de control predictivo representaría el siguiente nivel de sofisticación en la gestión automatizada de sistemas HVAC. Esta funcionalidad utilizaría las capacidades predictivas del modelo XG-Boost para anticipar necesidades operativas y ajustar parámetros del sistema antes de que se manifiesten condiciones problemáticas.

El control predictivo se basaría en el análisis de tendencias identificadas en las variables de distorsión armónica y factor de potencia, generando ajustes proactivos que mantengan las condiciones operativas dentro de rangos óptimos. Esta funcionalidad requeriría el desarrollo de algoritmos de control avanzados que integren las capacidades predictivas del machine learning con actuadores que modifiquen parámetros operativos en tiempo real.

5.2.6. Dashboards Especializados para Diferentes Usuarios

Los dashboards implementados en Power BI pueden expandirse hacia interfaces especializadas que atiendan las necesidades específicas de diferentes tipos de usuarios: técnicos de mantenimiento, gestores de instalaciones, y administradores ejecutivos. Esta especialización proporcionaría vistas optimizadas según el nivel de detalle técnico requerido por cada rol.

Los dashboards especializados incluirían funcionalidades de alerta automática, generación de reportes programados, y visualizaciones adaptadas al contexto operativo específico de cada usuario. Esta expansión mantendría la arquitectura de visualización en Power BI pero desarrollaría interfaces diferenciadas que maximicen la utilidad de la información presentada según las responsabilidades específicas de cada rol.

5.3. Lecciones aprendidas

El desarrollo del prototipo de arquitectura IoT para sistemas HVAC comerciales generó aprendizajes significativos que pueden orientar futuros proyectos en el área de automatización y optimización energética. Estas lecciones se fundamentan en las experiencias obtenidas durante las fases de diseño, implementación, y evaluación del sistema.

5.3.1. Importancia de la Selección de Variables Objetivo

La identificación de la distorsión armónica total de corriente como variable objetivo principal demostró ser efectiva para la evaluación del estado operativo de sistemas HVAC. Esta selección se fundamentó en normativas técnicas establecidas (IEEE 519-2014, NTC 5001-2008) y se validó mediante los resultados obtenidos en la clasificación de estados operativos.

El proceso de selección de variables requirió análisis detallado de la literatura técnica y consideración de las limitaciones prácticas de medición en entornos comerciales. La experiencia indica que la selección de variables objetivo debe equilibrar la relevancia técnica con la viabilidad de implementación, priorizando parámetros que puedan medirse de manera confiable y que proporcionen información accionable para la gestión operativa.

5.3.2. Complejidad de la Integración de Tecnologías

La integración de tecnologías IoT, procesamiento en la nube, machine learning, y visualización de datos presentó desafíos técnicos que requirieron soluciones específicas para cada componente de la arquitectura. La experiencia demostró que la implementación exitosa de sistemas complejos requiere planificación detallada de las interfaces entre componentes y consideración cuidadosa de las limitaciones de cada tecnología.

El desarrollo de la arquitectura distribuida en AWS requirió comprensión profunda de las capacidades y limitaciones de los servicios en la nube, particularmente en relación con el manejo de volúmenes de datos y latencia de procesamiento. La experiencia indica que la selección de plataformas tecnológicas debe considerar no solo las capacidades actuales sino también los requerimientos de escalabilidad futura.

5.3.3. Relevancia de la Visualización para la Adopción

Los dashboards desarrollados en Power BI demostraron ser fundamentales para la traducción de análisis técnicos complejos en información operativa accesible. La experiencia confirmó que la sofisticación técnica del análisis de datos debe complementarse con interfaces de usuario que faciliten la interpretación y aplicación de los resultados.

El desarrollo de visualizaciones efectivas requirió iteraciones múltiples para identificar las representaciones gráficas más apropiadas para cada tipo de información. La experiencia indica que el diseño de interfaces debe considerar las necesidades específicas de los usuarios finales y proporcionar múltiples niveles de detalle que permitan análisis tanto granular como agregado.

5.3.4. Importancia de la Validación con Datos Reales

La evaluación del sistema utilizando un dataset simulado proporcionó resultados útiles para la validación de conceptos, pero evidenció la necesidad de validación adicional con datos reales de sistemas HVAC operativos. La experiencia demostró que los patrones identificados en datos simulados pueden diferir de los comportamientos observados en sistemas reales debido a la complejidad de las condiciones operativas.

El proceso de simulación de datos requirió consideración cuidadosa de los rangos realistas de variables y patrones temporales representativos de operaciones HVAC comerciales. La experiencia indica que la simulación de datos debe fundamentarse en características operativas documentadas de sistemas reales para generar resultados que puedan extrapolarse a aplicaciones prácticas.

5.3.5. Necesidad de Consideraciones de Escalabilidad

El desarrollo del prototipo evidenció que las decisiones de diseño inicial tienen impacto significativo en las posibilidades de escalabilidad futura del sistema. La arquitectura distribuida implementada proporcionó flexibilidad para el manejo de volúmenes crecientes de datos, pero requirió planificación específica para asegurar que los componentes individuales puedan expandirse de manera coordinada.

La experiencia demostró que la escalabilidad debe considerarse desde las fases iniciales de diseño, incluyendo la selección de tecnologías, estructura de datos, y arquitectura de procesamiento. Las decisiones que optimizan el desempeño para implementaciones pequeñas pueden limitar las posibilidades de expansión hacia aplicaciones de mayor envergadura.

5.3.6. Importancia de la Documentación y Reproducibilidad

El desarrollo del sistema requirió documentación detallada de decisiones de diseño, configuraciones técnicas, y procedimientos de implementación para asegurar la reproducibilidad de los resultados. La experiencia confirmó que la documentación sistemática es fundamental para la validación de resultados y la transferencia de conocimiento a futuros desarrollos.

El proceso de documentación demostró que la captura de información debe incluir no solo los aspectos técnicos exitosos sino también las dificultades encontradas y las soluciones implementadas. Esta documentación comprehensiva proporciona una base sólida para la mejora continua del sistema y la orientación de proyectos relacionados.

La experiencia obtenida durante el desarrollo del prototipo proporciona una base sólida para futuras implementaciones en el área de automatización energética HVAC, contribuyendo al avance del conocimiento en la aplicación de tecnologías IoT para optimización energética en el sector comercial.

Bibliografía

- (2018). Iso 50001:2018 - energy management systems — requirements with guidance for use.
- 50001, I. (2018). Iso 50001 - energy management.
- ABB (2018). Harmonics in hvac applications. *ABB Technical Documentation*.
- Afram, A. and Janabi-Sharifi, F. (2014). Theory and applications of hvac control systems - a review of model predictive control (mpc).
- Balbis-Morejón, M., Cabello-Eras, J. J., Rey-Hernández, J. M., and Rey-Martínez, F. J. (2021). Energy evaluation and energy savings analysis with the 2 selection of ac systems in an educational building. *Sustainability (Switzerland)*, 13.
- BSI (2018). Iso 50001:2018 energy management systems. *British Standards Institute (BSI)*.
- Cao, X., Dai, X., and Liu, J. (2016). Building energy-consumption status worldwide and the state-of-the-art technologies for zero-energy buildings during the past decade. *Energy and Buildings*, 128.
- Christopoulos, M., Spantideas, S., Giannopoulos, A., and Trakadas, P. (2024). Deep reinforcement learning for smart home temperature comfort in iot-edge computing systems. In *MECC 2024 - Proceedings of the 1st International Workshop on MetaOS for the Cloud-Edge-IoT Continuum, Part of: EuroSys 2024*, pages 1–7. Association for Computing Machinery, Inc.
- de Bogotá., A. M. (2024). Programa de gestión ambiental empresarial.
- de Colombia, C. (2014). Ley 1715 de 2014. *Diario Oficial*.
- de la República de Colombia, C. (2014). Ley 1715 de 2014 - ley de integración de las energías renovables no convencionales al sistema energético nacional. Consultada el [2024].
- de regulación de Energía y Gas, C. (2002). Resolución creg 082 de 2002.
- Du, L., Li, X., Wang, K., and Li, Y. (2023). Prediction of hvac energy consumption using pso optimized deep neural network. In *Proceedings of 2023 IEEE 12th Data Driven Control and Learning Systems Conference, DDCLS 2023*, pages 52–57. Institute of Electrical and Electronics Engineers Inc.
- Excelec (2024). Medidores ami.
- Garces-Jimenez, A., Gomez-Pulido, J. M., Gallego-Salvador, N., and Garcia-Tejedor, A. J. (2021). Genetic and swarm algorithms for optimizing the control of building hvac systems using real data: A comparative study. *Mathematics*, 9.
- Ghasempour, A. (2019). Internet of things in smart grid: Architecture, applications, services, key technologies, and challenges.
- Gowrishankar, J., Pareek, R. K., and Nisha (2023). Iot-based ultra smart energy meter system for better load profile. In *2023 International Conference on Power Energy, Environment and Intelligent Control, PEEIC 2023*, pages 1244–1248. Institute of Electrical and Electronics Engineers Inc.
- Hanna, R., Heptonstall, P., and Gross, R. (2024). Job creation in a low carbon transition to renewables and energy efficiency: a review of international evidence.

- ICONTEC (2008). Ntc 5001-2008: Calidad de la potencia eléctrica. límites y metodología de evaluación en punto de conexión común. Technical report, Instituto Colombiano de Normas Técnicas y Certificación, Bogotá, Colombia.
- ICONTEC (2013). Norma técnica colombiana ntc 1340 - electrotecnia. tensiones y frecuencia nominales en sistemas de energía eléctrica en redes de servicio público. *Tercera*.
- IEA (2023). Electricity market report 2023. *International Energy Agency*.
- IEEE (2014). Ieee std 519-2014: Ieee recommended practice and requirements for harmonic control in electric power systems. Technical report, Institute of Electrical and Electronics Engineers, New York, NY, USA.
- Jana, R. L., Dey, S., and Dasgupta, P. (2020). A hierarchical hvac control scheme for energy-aware smart building automation. *ACM Transactions on Design Automation of Electronic Systems*, 25.
- Kamal, M. A. and Khan, S. A. (2021). Variable refrigerant flow in air conditioning of buildings: System configuration and energy efficiency. *American Journal of Civil Engineering and Architecture*, 9.
- Martinez Espinal, K. D. P., Molina Cetina, G. A., and Tarazona Rueda, R. A. (2023). Diseño del sistema de gestión de seguridad y salud en el trabajo para la empresa imac sas teniendo en cuenta los resultados obtenidos en la evaluación de estándares mínimos bajo la resolución 0312 de 2019.
- Merabet, G. H., Essaaidi, M., Talei, H., Abid, M. R., Khalil, N., Madkour, M., and Benhaddou, D. (2014). Applications of multi-agent systems in smart grids: A survey. In *International Conference on Multimedia Computing and Systems -Proceedings*, pages 1088–1094. IEEE Computer Society.
- Miller, C. (2017). Predicting success of energy savings interventions and industry type using smart meter and retrofit data from thousands of non-residential buildings. In *BuildSys 2017 - Proceedings of the 4th ACM International Conference on Systems for Energy-Efficient Built Environments*, volume 2017-January.
- Oropeza-Perez, I. and Østergaard, P. A. (2018). Active and passive cooling methods for dwellings: A review. *Renewable and Sustainable Energy Reviews*, 82:531–544.
- Sriranjani, R., Raja, D. J. S., Hemavathi, N., Parvathy, A., Vinotha, N., and Sharmitha, R. (2023). Implementation of energy efficient advanced metering infrastructure in smart grid. In *2023 1st International Conference on Advanced Engineering and Technologies, ICONNIC 2023 - Proceeding*, pages 316–321. Institute of Electrical and Electronics Engineers Inc.
- Telemetrik (2024). Energia inteligente.
- UPME (2015). Plan energetico nacional colombia: Ideario energético 2050. *Unidad de Planeación Minero Energética, Republica de Colombia*.
- Valovcin, S., Abe, N., and Massey, B. (2022). Using smart meter data to estimate demand reductions from residential direct load control programs. In *ISC2 2022 - 8th IEEE International Smart Cities Conference*.
- Vázquez-Canteli, J. R., Kämpf, J., Henze, G., and Nagy, Z. (2019). Citylearn v1.0: An openai gym environment for demand response with deep reinforcement learning. In *BuildSys 2019 - Proceedings of the 6th ACM International Conference on Systems for Energy-Efficient Buildings, Cities, and Transportation*.
- Wang, G. and Song, L. (2018). Performance assessment of variable frequency drives in heating, ventilation, and air-conditioning systems. *Science and Technology for the Built Environment*, 24:1075–1083.
- Wang, Y., Chen, Q., Gan, D., Yang, J., Kirschen, D. S., and Kang, C. (2019). Deep learning-based socio-demographic information identification from smart meter data. *IEEE Transactions on Smart Grid*, 10:2593–2602.

Yaici, W., Entchev, E., Longo, M., and Annuk, A. (2023). Internet of things (iot) monitoring and control for smart heating and cooling in a residential building. In *12th IEEE International Conference on Renewable Energy Research and Applications, ICRERA 2023*, pages 387–392. Institute of Electrical and Electronics Engineers Inc.