



UNIVERSIDAD SANTO TOMÁS
PRIMER CLAUSTRO UNIVERSITARIO DE COLOMBIA
SECCIONAL TUNJA

VIGILADA MINEDUCACIÓN - SNIES 1732

APLICACIÓN DE ESCRITORIO PARA MANTENIMIENTO PREDICTIVO DE EQUIPOS
INDUSTRIALES DE REFRIGERACIÓN A TRAVÉS DE MACHINE LEARNING.

PROPONENTE

José Andrés Quiroga Niño

1098678410

2347659

DIRECTOR(ES)

PhD. Marien Rocío Barrera Gómez

MD. Andrés Leonardo Alfonso Díaz

Tunja, mayo 31 de 2023

Dedicatoria

Dedicado a un joven José Andrés en el año 2011, nunca dejes que un comentario malintencionado te llene de temor a lo desconocido, impidiendo la sensación de aventura en una nueva etapa de tu vida.

CONTENIDO

1. FICHA TECNICA DEL TRABAJO DE GRADO	8
2. PLANTEAMIENTO DEL PROBLEMA	9
3. JUSTIFICACIÓN	12
4. OBJETIVOS	13
5. MARCO TEORICO.....	14
5.1. Mantenimiento industrial	14
5.2. Industria 4.0 y el aprendizaje automático.	16
5.2.1. Clasificación de los algoritmos por su tipo de aprendizaje	18
5.2.2. Clasificación de los algoritmos por su estructura.....	18
5.3. Sistemas de refrigeración y aire acondicionado	19
6. ESTADO DEL ARTE Y ANÁLISIS DE VIGILANCIA TECNOLÓGICA.....	20
7. METODOLOGIA	29
7.1. Fase I. Sprint, backlog e historias de usuario.....	29
7.2. Fase II. Adquisición y preproceso de la información.....	30
7.3. Fase III. Procesamiento de la información y desarrollo de la solución	30
7.4. Fase IV. Revisión y retrospectiva	31
7.5. Fase V. Entregables y conclusión	31
8. SPRINTS, BACKLOG E HISTORIAS DE USUARIO	32
9. DESARROLLO DE LA SOLUCIÓN	37
9.1. Adquisición y preprocesamiento de los datos	37
9.2. Calidad de la información recopilada.....	40
9.3. Selección del método y herramientas utilizadas para el análisis de datos.....	41
9.3.1. Selección del método para el análisis de datos.....	41
9.3.2. Selección de las herramientas utilizadas para el análisis de datos.	43
9.3.3. Requisitos mínimos para ejecución	45
9.4. Desarrollo del algoritmo y flujo de trabajo de la aplicación.....	46
9.5. Configuración de la interfaz de usuario.....	53
10. VALIDACIÓN DE LA PRECISIÓN DE LA SOLUCIÓN	62
10.1. Error promedio al cuadrado (R^2).	63
10.2. Error absoluto promedio (MAE)	64
10.3. Raíz cuadrada del error promedio (RMSE)	65
10.4. Error cuadrado promedio (MSE)	65
11. DEMOSTRACION DE LA SOLUCION	66
12. OPORTUNIDADES DE MEJORA EN LA IMPLEMENTACION DE LA SOLUCION.....	67
12.1. Adquisición de la información mediante tecnologías IoT	67

MAESTRIA EN INGENIERIA
DOCUMENTO FINAL DE TRABAJO DE GRADO

12.2. Acceso remoto a la herramienta de predicción	67
13. ANÁLISIS Y DISCUSIÓN DE RESULTADOS	68
14. OBSERVACIONES Y RECOMENDACIONES	73
15. CONCLUSIONES	74
REFERENCIAS	76
ANEXOS	81
<i>Anexo 1. Registro del software ante DNDA:</i>	<i>81</i>
<i>Anexo 2. Manual de usuario:</i>	<i>83</i>

LISTA DE TABLAS

<i>Tabla 1. Clasificación de equipos de aire acondicionado en la Refinería Ecopetrol BCA.</i>	<i>9</i>
<i>Tabla 2. Ventajas y desventajas de las metodologías de mantenimiento.....</i>	<i>16</i>
<i>Tabla 3. Análisis preliminar de los resultados de la investigación relacionadas de fondo</i>	<i>20</i>
<i>Tabla 4. Análisis detallado de los artículos relacionados de fondo con la investigación.</i>	<i>22</i>
<i>Tabla 5. Análisis preliminar de los resultados de la investigación relacionadas de forma.</i>	<i>25</i>
<i>Tabla 6. Análisis detallado de los artículos relacionados de forma con la investigación.</i>	<i>26</i>
<i>Tabla 7. Atributos de un software de alta calidad.</i>	<i>30</i>
<i>Tabla 8. Backlog del Producto.....</i>	<i>32</i>
<i>Tabla 9. Perfiles implementados en las historias de usuario.....</i>	<i>33</i>
<i>Tabla 10. Historia de usuario 1.....</i>	<i>34</i>
<i>Tabla 11. Historia de usuario 2.....</i>	<i>34</i>
<i>Tabla 12. Historia de usuario 3.....</i>	<i>35</i>
<i>Tabla 13. Historia de usuario 4.....</i>	<i>35</i>
<i>Tabla 14. Historia de usuario 5.....</i>	<i>36</i>
<i>Tabla 15. Clasificación de historias de usuario, según sus atributos de calidad.</i>	<i>36</i>
<i>Tabla 16. Valores de referencia de presión según tipo de refrigerante.</i>	<i>39</i>
<i>Tabla 17. Valores de referencia límite para presiones de refrigerante.</i>	<i>39</i>
<i>Tabla 18. Valores de referencia límite para voltaje de red.</i>	<i>40</i>
<i>Tabla 19. Ambientes de entrenamiento disponibles según el escenario seleccionado.</i>	<i>47</i>
<i>Tabla 20. Costos asociados a Hardware</i>	<i>57</i>
<i>Tabla 21. Salarios aproximados de mano de obra</i>	<i>58</i>
<i>Tabla 22. Calculo de recursos asociados a mano de obra.....</i>	<i>59</i>
<i>Tabla 23. Costos directos de desarrollo de aplicación para mantenimiento predictivo</i>	<i>60</i>
<i>Tabla 24. Comparación de costos asociados a las metodologías de mantenimiento</i>	<i>61</i>
<i>Tabla 25. Validación de los criterios de las historias de usuario</i>	<i>68</i>
<i>Tabla 26. Validación de los criterios de los Sprints</i>	<i>69</i>

LISTA DE FIGURAS

<i>Figura 1. Distribución de tipo de equipos en la Refinería Ecopetrol BCA.</i>	10
<i>Figura 2. Hitos en el desarrollo de la filosofía del mantenimiento.</i>	14
<i>Figura 3. Tecnologías representadas en la Industria 4.0.</i>	17
<i>Figura 4. Ciclo de Carnot simplificado.</i>	19
<i>Figura 5. Resultados de la búsqueda de investigaciones relacionadas de fondo.</i>	20
<i>Figura 6. Publicaciones relacionadas con la investigación desde su fondo.</i>	21
<i>Figura 7. Publicaciones relacionadas por año con la investigación desde su fondo.</i>	21
<i>Figura 8. Resultados de la búsqueda de investigaciones desde su forma.</i>	25
<i>Figura 9. Publicaciones relacionadas por año con la investigación desde su forma.</i>	26
<i>Figura 10. Ciclo Scrum</i>	29
<i>Figura 11. Proceso general de desarrollo de aplicación.</i>	37
<i>Figura 12. Etapas de la construcción de un modelo de Machine learning.</i>	41
<i>Figura 13. Base de datos en Microsoft SQL Server Management Studio 18.</i>	43
<i>Figura 14. Microsoft Visual Studio 2022 y ML.NET Model Builder.</i>	44
<i>Figura 15. Selección de escenario de trabajo.</i>	46
<i>Figura 16. Ambiente de entrenamiento para el escenario predicción de valor.</i>	47
<i>Figura 17. Incorporación de datos en la aplicación.</i>	48
<i>Figura 18. Entrenamiento de la solución.</i>	49
<i>Figura 19. Evaluación de la solución.</i>	50
<i>Figura 20. Consumo de nueva información.</i>	51
<i>Figura 21. Opciones de despliegue y fortalecimiento de la aplicación.</i>	52
<i>Figura 22. Icono de la aplicación PREDICONFORT 1.0</i>	53
<i>Figura 23. Imagen de la marca PREDICONFORT 1.0.</i>	53
<i>Figura 24. Paleta de colores utilizados.</i>	54
<i>Figura 25. Ventana inicial.</i>	54
<i>Figura 26. Ventana principal.</i>	55
<i>Figura 27. Sección inspección.</i>	55
<i>Figura 28. Información del Modelo.</i>	56
<i>Figura 29. Predicción de valor.</i>	56
<i>Figura 30. Validación de datos.</i>	57
<i>Figura 31. Proceso de validación de la solución.</i>	62
<i>Figura 32. Resultado de análisis de validación de métricas (Desarrollo de consola).</i>	63
<i>Figura 33. Predicción de evento de fugas en EQUIPO_PRUEBA</i>	66
<i>Figura 34. Desarrollo de la solución bajo un entorno cloud.</i>	67

LISTA DE ECUACIONES

<i>Ecuación 1. Cálculo de error promedio al cuadrado.....</i>	<i>64</i>
<i>Ecuación 2. Cálculo del error absoluto promedio.</i>	<i>64</i>
<i>Ecuación 3. Raíz cuadrada del error promedio.....</i>	<i>65</i>
<i>Ecuación 4. Error cuadrado promedio.....</i>	<i>65</i>

1. FICHA TECNICA DEL TRABAJO DE GRADO

Titulo	Aplicación de escritorio para mantenimiento predictivo de equipos industriales de refrigeración a través de machine learning.
Autor(es)	José Andrés Quiroga Niño
Director(es) del proyecto	Marien Rocío Barrera Gómez Andrés Leonardo Alfonso Díaz
Palabras claves	Machine learning, Mantenimiento predictivo, Sistemas de aire acondicionado industrial.
Descripción	
Son innegables los beneficios obtenidos a través de la implementación de nuevas tecnologías. Desde la revolución industrial en el siglo XVIII hasta la actualidad, estos avances buscan en todo momento optimizar el consumo de recursos, elevar la calidad del producto o servicio y aumentar la eficiencia de los procesos. (Sanzana et al., 2022) Con esto como premisa, nos encontramos en plena madurez de la Industria 4.0 la cual está enmarcada en el manejo de datos, las ciencias computacionales y las telecomunicaciones, y se busca a través de estas, diseñar una plataforma que capture y analice información según algoritmos de Machine learning, proveniente de parámetros operacionales y rutinas de mantenimiento de sistemas industriales de aire acondicionado (para este caso puntual se realizará simulación parcial de los datos, incluyendo alteraciones para visualizar respuestas) tal que se obtenga un modelo de machine learning que permita anticipar fallas y/o deterioro de los equipos. (Es-sakali et al., 2022) Permitiendo en la práctica, el pre-alistamiento de los recursos y repuestos, ejecutando los trabajos con el menor efecto sobre la producción. Dejando dicha medición de métricas a posteriores investigaciones. (Es-sakali et al., 2022)	

2. PLANTEAMIENTO DEL PROBLEMA

A nivel industrial, un aspecto relevante para garantizar la operación es la conservación del activo (Jimenez Raya, 2015). Cada máquina, cada sistema, cada pieza tiene una vida útil, la cual se ve afectada por diversos factores: operación, mantenimiento, condiciones ambientales, horas de uso y horas de no uso, entre otros. (Jimenez Raya, 2015)

En gran parte de las empresas del sector primario y secundario de la economía, los sistemas de aire acondicionado y refrigeración industrial constituyen un activo importante, sus aplicaciones no solo se limitan a acondicionamiento de atmosferas, sino que incluyen conservación de productos y extracción de calor de procesos. (Candanedo et al., 2018)

Tanto el problema como la solución son inspirados en la Refinería de Ecopetrol, propiedad de ECOPETROL S.A.¹ una empresa líder en la industrial Oil & Gas, ubicada en la ciudad de Barrancabermeja, Santander, la cual cuenta con un total de 267 equipos centrales de aire acondicionado (ECOPETROL S.A, 2018), distribuidos como se presenta en la tabla 1, la cual representa ordenadamente el inventario de equipos industriales contenidos en la Refinería de Ecopetrol Barrancabermeja.

Tabla 1. Clasificación de equipos de aire acondicionado en la Refinería Ecopetrol BCA.

INVENTARIO DE EQUIPOS REFINERIA BCA	
TIPOS DE EQUIPOS	CANTIDAD
Chillers condensados por aire	9
Chillers condensados por agua	2
Chillers de absorción	6
Manejadoras de aire	31
Unidades paquete	86
Unidades Split	126
Cuartos fríos	7
TOTAL	267

Fuente: Los autores, 2023. Tomado de los registros públicos de la empresa Ecopetrol BCA, 2018.


De igual manera, estos equipos, se clasifican de acuerdo con la tipología industrial de su naturaleza, como se presenta en la figura 1 la cual representa el inventario y tipos de equipos contenidos en la Refinería Ecopetrol BCA en el año 2018. Esta clasificación, permite hacer una diferenciación por tecnología y etapa de proceso, manteniendo la cadena de valor bajo los principios científicos de operación estándar. (ECOPETROL S.A, 2018).

¹ La presente investigación es de tipo académica, no representa participación y/o responsabilidad de ECOPETROL S.A o sus empresas Aliadas.

Cada uno de estos equipos posee entre dos (2) y cuatro (4) rutinas de mantenimiento preventivo programado al año, teniendo como principio rector, su criticidad dentro del proceso productivo y la prioridad entregada por la matriz RAM, adicionalmente se realizan las intervenciones correctivas según condiciones e información recopilada. (Santos Sanchez & Castro Barrera, 2022)

Para la generación de reportes, el personal ejecutor de la empresa aliada realiza un proceso de recolección de información de manera manual, antes y después de la actividad, datos que posteriormente son ingresados en una hoja de trabajo de Excel que funciona como base para consultas.

Figura 1. Distribución de tipo de equipos en la Refinería Ecopetrol BCA.



Fuente. Los autores, 2023. Tomado de los registros públicos de la empresa Ecopetrol BCA, 2018.

Con este procedimiento de trabajo, la estimación temporal de los eventos futuros se convierte en la gran incógnita y su aproximación en una variable crítica para la empresa, implicando tiempos de parada superiores, debido a eventualidades como: disponibilidad de repuestos, disponibilidad de equipos y disponibilidad de personal, entre otros.

De acuerdo con (Braun et al., 2001), los daños que frecuentemente tienen lugar en sistemas de aire acondicionado son;

- ✓ Fugas de refrigerante en tuberías de refrigeración.
- ✓ Daño mecánico de compresor.
- ✓ Daño eléctrico de compresor.

MAESTRIA EN INGENIERIA
DOCUMENTO FINAL DE TRABAJO DE GRADO

- ✓ Daño mecánico en motores.
- ✓ Daño eléctrico en motores.
- ✓ Daño de dispositivos eléctricos.
- ✓ Mal funcionamiento de dispositivo de expansión.

Y en el caso particular, según la información recopilada entre los años 2019 y 2022, las fallas más presentadas fueron pérdida de refrigerante por roturas de líneas de refrigeración, representando un total de 45% del total de 509 fallas. (Refinería Ecopetrol BCA, 2022).

3. JUSTIFICACIÓN

La aparición de fugas de gas refrigerante es una de las fallas más recurrentes en los sistemas de refrigeración y aire acondicionado, HVAC&R por sus siglas en inglés (Heating, Ventilation, Air Conditioning and Refrigeration), su causa raíz es principalmente por desgaste de la pared de la tubería de refrigeración y la exposición al medio ambiente.

Su predicción del lugar y momento es imposible por medios tradicionales, por ende, las labores correctivas, se realizan generalmente de forma reactiva, sin previa logística de materiales, recursos y personal.

Con esto como premisa y haciendo uso de las herramientas computacionales desarrolladas a partir de la incorporación de algoritmos estadísticos se busca predecir la fecha de aparición de fugas de gas refrigerante, mediante la creación de una aplicación de machine learning para escritorio.

El uso de la herramienta permite la programación del trabajo correctivo, logística de recursos, materiales y personal. Disminuyendo el factor imprevisto, tiempos muertos y afectaciones en el proceso productivo.

4. OBJETIVOS

Objetivo General

Desarrollar una aplicación de escritorio para mantenimiento predictivo de equipos industriales de refrigeración a través de machine learning.

Objetivos Específicos:

- ✓ Diseñar las historias de usuario de los requerimientos del proceso de mantenimiento de los equipos de refrigeración industrial.
- ✓ Desarrollar los sprints de la aplicación de escritorio para mantenimiento predictivo de equipos industriales de refrigeración a través de machine learning.
- ✓ Validar la precisión del desarrollo a través de las métricas generales para evaluación de modelos de machine learning.

5. MARCO TEORICO

5.1. Mantenimiento industrial

El nacimiento del mantenimiento y su evolución está estrechamente ligado a las tecnologías que lo requieren. Naciendo como técnicas de limpieza y lubricación de herramientas manuales, no fue hasta el siglo XVII con el auge de la revolución industrial que fue necesario incorporar rutinas de trabajo correctivo en la maquinas, para disponer de estas nuevamente en la línea de producción específica, constituidas a partir de la fecha de piezas intercambiables, practica que continua vigente hasta nuestros días. (Gonzalez Ajuech, 2017a)


Durante el siglo XIX e impulsado principalmente por la Primera Guerra Mundial se evidencio la necesidad de programar las rutinas de trabajo correctivo, haciendo énfasis en la necesidad de un stock de repuestos, herramientas y personal. Naciendo los primeros frentes internos de mantenimiento, cuyo principal objetivo es minimizar las afectaciones en la producción y operación del ciclo del negocio. (Gonzalez Ajuech, 2017a)

En muy poco tiempo y debido en su mayoría a la presión que ejercía el continuo abastecimiento requerido por la Segunda Guerra Mundial, que se evidencio la necesidad de incorporar rutinas de mantenimiento que se encargaran de preservar los equipos. Basadas principalmente en las causas comunes de falla. (Gonzalez Ajuech, 2017a)

Dicho modelo es quizás el de mayor aceptación y practica hoy en día, pues está demostrado que la operación de una maquinaria u proceso trae como consecuencia el deterioro de sus componentes, que sin debida atención evoluciona en una pérdida de la operabilidad paulatina hasta su final inoperancia. (Boero, 2020a)

Con el nacimiento de la industria globalizada y el fácil acceso a la información, permitiendo realizar comparaciones, análisis y toma de decisiones, fue necesario cada día más generar procesos operacionales óptimos y competitivos, que disminuyan gastos asociados a deterioro de los activos. Es allí donde surgen diferentes corrientes de mantenimiento, sin duda alguna, una de las más significativas es el Mantenimiento predictivo, el cual tiene como objetivo detectar desviaciones en los parámetros operacionales en los equipos y diagnosticar fallas relacionadas, tal que se disponga de una logística y recursos ajustados a la oportunidad de mejora. (Cerquitelli et al., 2021a) Esta evolución del mantenimiento es representada en la figura 2.

Figura 2. Hitos en el desarrollo de la filosofía del mantenimiento.



Fuente. Los autores, 2023. Adaptado de Gonzalez Ajuech, V. L. (2017).

El auge de la electrónica y la automatización de procesos trajo como consecuencia procesos de mayor calidad, menor tiempo de producción y menos personal operativo requerido. Sin embargo, la gestión de su mantenimiento es cada vez más compleja, requiere mejores tecnologías asociadas y personal mantenedor cada vez más especializado. (Boero, 2020a)

Ligado directamente con la cultura organizacional de la empresa, el mantenimiento industrial cumple el importante rol de mantener el proceso productivo, con el cumplimiento de sus principales objetivos, aumento del rendimiento de los equipos, reducir costos asociados al proceso y generar un entorno seguro para trabajar, y estrechar lazos de colaboración con otras dependencias como operaciones y gerencia. (Jimenez Raya, 2015)

Cada proceso de mantenimiento es particular a la empresa donde se ejecute, pues está asociado directamente a la cultura organizacional, personal ejecutor y procesos internos. Por ende, la clasificación de dichos procesos sólo puede entregarse de forma general. (Boero, 2020a)

Según (Gonzalez Ajuech, 2017a) existen tres (3) principales sistemas de mantenimiento;

✓ **Mantenimiento Correctivo**

Aplicado únicamente cuando la falla ha aparecido, su costo es elevado no solo en repuestos, sino en tiempos muertos. Se busca evitar la aparición de este, pues generalmente no hay un preaviso, obstaculizando el proceso productivo.

✓ **Mantenimiento Predictivo**

Tiene como propósito monitorear las condiciones operativas del proceso. Tal que se identifiquen desviaciones en las condiciones de funcionamiento, con ello se realizan intervenciones programadas que generen una mínima alteración de los procesos productivos.

✓ **Mantenimiento Preventivo**

Quizás el más aplicado hoy en día, consiste en programar actividades de mantenimiento, teniendo como premisa, patrones operacionales y de fiabilidad para definir la frecuencia de las intervenciones. Pese a que disminuye los puntos de falla, no es totalmente efectivo. Pues no tiene en cuenta alteraciones en la operación ni curvas propias de desgaste por normal uso en los equipos.

Siendo las diferencias expresadas, se condensan en la tabla 2, las principales ventajas y desventajas de estas metodologías de mantenimiento.

Tabla 2. Ventajas y desventajas de las metodologías de mantenimiento.

METODOLOGÍA	VENTAJAS	DESVENTAJAS
Mantenimiento Correctivo	Disminuye costos en la administración del activo, principalmente debido a que la intervención se realiza por condición (Boero, 2020).	Su desarrollo implica que el equipo debe entrar parcial o totalmente en falla, afectando la cadena productiva, la integridad de los componentes circundantes del activo. Todo esto representado en sobrecostos (Gonzalez Ajuech, 2017).
Mantenimiento Preventivo	Su implementación permite un proceso cíclico, por ende, fácil de administrar. Dando la posibilidad de proyectar gastos y recursos necesarios (Boero, 2020).	No asegura completamente la correcta operación y disposición del equipo (Boero, 2020).
Mantenimiento Predictivo	Su implementación puede estar sujeta a costos elevados iniciales por las características del personal ejecutor y la tecnología implementada (Cerquitelli et al., 2021).	Debe ser complementado con mantenimiento preventivo y correctivo, según los requerimientos de la situación (Gonzalez Ajuech, 2017).


Fuente. Los autores, 2023

5.2. Industria 4.0 y el aprendizaje automático.

Se conoce como la industria digital o Smart industry, y está basada en el uso de tecnologías emergentes para mejorar los procesos de fabricación, mantenibilidad, producción y calidad de las empresas. Mediante la implementación de tecnologías que giran en torno a la administración de los datos. (Rodal Montero, 2020)

Según (Oficina Asesora de Planeación y Estudios Sectoriales, 2019) Industria 4.0 se desarrolla principalmente por la incorporación de nuevas y existentes tecnologías digitales en la industria existente. Tal como lo indica la figura 3.

Figura 3. Tecnologías representadas en la Industria 4.0.



Fuente. Los autores. 2023. Adaptado de Saturno, M., Pertel, V., & Deschamps, F. (2017).

Creando nuevos modelos, productos y servicios con enfoques basados principalmente en lo social, en competencia de mercado, calidad en la producción y modificación del comportamiento del proceso productivo. (Sukhodolov, 2019)

Una de las tecnologías que está propiciando esta nueva industria, es el Cognitive computing, la cual trae como premisa, el desarrollo de tecnologías, que imiten al menos en su proceso básico el comportamiento cognitivo del ser humano. (Saturno et al., 2017)

Surgiendo dentro de este campo el machine learning o aprendizaje automático la cual se basa en el uso de ciencias computacionales para el desarrollo de software capaz de generalizar comportamientos a partir de datos que pueden ser ingresados previamente o en tiempo real. (Rodal Montero, 2020). Y su clasificación puede darse por el tipo de aprendizaje realizado y por la estructura del algoritmo.

5.2.1. Clasificación de los algoritmos por su tipo de aprendizaje

De acuerdo con (Joshi, 2020) se presentan tres (3) principales tipos de algoritmos al ser observados desde su tipo de aprendizaje;

✓ **Aprendizaje supervisado**

Usado generalmente cuando se disponen de un conjunto de salidas, relacionadas con un conjunto de entradas. Tal que se establezcan relaciones directas de comportamiento. Su funcionamiento es visto como una “caja negra” donde su predicción está limitada a valores precargados.

✓ **Aprendizaje no supervisado**

Usado como metodología de aprendizaje cuando no se cuenta con la respuesta exacta aun grupo de parámetros de ingreso, tal que se obtiene del proceso un grupo de posibles respuestas, las cuales generalmente deben ser nuevamente analizadas para hallar la más cercana.

✓ **Aprendizaje por refuerzo**

Considerado como un aprendizaje semi supervisado, su característica principal es que posee un grupo de valores como respuestas posibles, por ende, se realiza una incorporación de información externa que permita filtrar la respuesta más adecuada.

5.2.2. Clasificación de los algoritmos por su estructura

En esta clasificación se maneja un concepto conocido como “linealidad”, y este es aplicado tanto a datos de entrada y salida como a los modelos generados a partir estos, tal que, existe una tendencia similar tanto en la información de entrada como en la salida del proceso predictivo a aumentar o decrecer. Así bien, un modelo lineal es aquel que cuyo comportamiento obedece a una ecuación lineal (Joshi, 2020).

Por otro lado, los modelos y datos no lineales basan su comportamiento en teorías de conjuntos y aproximaciones, que permiten poco a poco ir encontrando la salida según los parámetros de entrada. Son muchos los métodos no lineales implementados en procesos predictivos, algunos son; redes neuronales, arboles de decisión y probabilísticos (Kubat, 2017).


Pese a la naturaleza de la estructura o tipo aprendizaje del algoritmo, su implementación solo es posible si existen tres (3) factores en el proceso productivo (Joshi, 2020);

- ✓ Datos optimizados que sirven para alimentar el algoritmo.
- ✓ Cuantificación del error entre el comportamiento predeterminado por el algoritmo y el suceso efectuado.
- ✓ Retroalimentación del error, a fin de mejorar el algoritmo, por ende, su disminución.

5.3. Sistemas de refrigeración y aire acondicionado

Conocido como Ciclo de Carnot y ampliamente usado a nivel mundial por su simpleza y eficiencia. Tal como se indica en la figura 4, El ciclo de refrigeración por compresión en su forma más básica cuenta con cuatro (4) elementos principales. Evaporador, Compresor, Condensador y Elemento de expansión. (R. and A.-C. E. American Society of Heating, 2021)

Figura 4. Ciclo de Carnot simplificado.



Fuente. Los Autores. Adaptado de ASHRAE Handbook: Vol. Fundamentals. American Society of Heating, R. and A.-C. E. (2021).

✓ Evaporador.

Encargado de absorber el calor proveniente de la fuente. Ya sea de un área a acondicionar u otro fluido. Generalmente se utilizan serpentines de tubos de cobre y aletas de aluminio.

✓ Compresor.

Genera el trabajo dentro del ciclo, su principal función es elevar la presión del refrigerante, facilitando su cambio de fase en el condensador.

✓ Condensador

Transmite el calor del fluido al exterior o sumidero, dada sus características se presenta un cambio de fase gas-líquido dentro del el. Aumentando la eficiencia del proceso.


✓ Expansión

Cumple una función inversa que el compresor. Se encarga de bajar nuevamente la presión de fluido refrigerante, facilitando la absorción de calor por parte de este en el evaporador y por ende un nuevo cambio de fase líquido – gas.

6. ESTADO DEL ARTE Y ANÁLISIS DE VIGILANCIA TECNOLÓGICA

Tomando como herramienta académica, la plataforma SCOPUS, fue posible realizar una búsqueda de las publicaciones de tipo investigativa que abordan los principales hitos del proyecto, descritos en la figura 5, los cuales son; mantenimiento predictivo, machine learning y sistemas de aire acondicionado industrial.

Figura 5. Resultados de la búsqueda de investigaciones relacionadas de fondo.



Fuente. Los autores, 2023. Tomado de: <https://www-scopus-com>.

Obteniendo como resultado 22 resultados correspondientes al criterio de búsqueda, después de analizados es posible categorizarlos según la relación con los temas desarrollados en la investigación. Resumidos en la tabla 3 y figura 6.


Tabla 3. Análisis preliminar de los resultados de la investigación relacionadas de fondo

COINCIDENCIA CON LOS TEMAS DE LA INVESTIGACION	CANTIDAD
Totalmente relacionado	15
Parcialmente relacionado	6
No relacionado	1

Fuente. Los autores, 2023. Tomado de: <https://www-scopus-com>.

Para el análisis en cuestión se toma como referencia las publicaciones que coinciden totalmente con la temática de la investigación, sirviendo de igual manera como referentes externos del avance en el tiempo dentro del campo académico.


Figura 6. Publicaciones relacionadas con la investigación desde su fondo



Fuente. Los autores, 2023. Tomado de: <https://www-scopus-com>.

Es notorio observar en la figura 7 como la pandemia ocasionó una evidente disminución en las publicaciones relacionadas, con un repunte luego del retorno de las actividades exteriores.

Figura 7. Publicaciones relacionadas por año con la investigación desde su fondo.



Fuente. <https://www-scopus-com>

MAESTRIA EN INGENIERIA
DOCUMENTO FINAL DE TRABAJO DE GRADO

Siendo las publicaciones relacionadas con el tema descritas a continuación en la tabla 4 y organizadas según la cantidad de citaciones que poseen;

Tabla 4. Análisis detallado de los artículos relacionados de fondo con la investigación.

ARTÍCULO	CITACIONES	APORTE
Machine Learning Predictive Model for Industry 4.0.	47	Los sistemas HVAC se encuentran presentan en los entornos productivos de muchas industrias, sus aplicaciones no solo se limitan a confort térmico y calidad del aire. La investigación tiene como propósito hacer uso de algoritmos de machine learning (aprendizaje automático) en el diseño de modelos de predicción de patrones operativos.(Candanedo et al., 2018)
A practical solution por HVAC prognostics: Failure mode and effects análisis in building maintenace.	46	El diagnóstico temprano de fallas permite que los administradores de edificios desplieguen un abanico de soluciones en la búsqueda de la no interrupción de operaciones propias de la construcción y el mantenimiento de los equipos. Su objetivo es logrado mediante la incorporación de modelos predictivos. (Yang et al., 2018)
Predictive maintenance in building facilities: A machine learning-based approach.	19	Pese a que las incorporaciones de nuevas tecnologías en la administración de edificios son evidentes, aun se presentan deficiencias en las políticas de mantenimiento, en este artículo se propone un marco de mantenimiento predictivo basado en técnicas de aprendizaje automático. (Bouabdallaoui et al., 2021)
Building predictive maintenance framework for smart environment application systems	19	Sin duda el mantenimiento predictivo es una poderosa herramienta de administración de recursos que se encuentra en constante crecimiento y mejora. Sin embargo, esto no es posible sin la incorporación de nuevas tecnologías y procedimientos. El objetivo de esta investigación es examinar las posibilidades de una herramienta computacional basada en aprendizaje automático que use como modelo de prueba, la administración del mantenimiento de un sistema HVAC. (Panfilov & Katona, 2018)

MAESTRIA EN INGENIERIA
DOCUMENTO FINAL DE TRABAJO DE GRADO

A digital twin predictive maintenance framework of air handling units based on automatic fault detection and diagnostics.	18	Uno de los grandes hitos de la Industria 4.0 son los gemelos digitales, y aunque aun se encuentran en sus primeras etapas, permite la creación digitalizada con la ayuda de herramientas como el Internet de las cosas de plantas de proceso o sistemas complejos como un sistema HVAC. Tal que se pueda modelar su operación y por ende sus fallas, permitiendo generar políticas de mantenimiento, incluso del tipo experimental, sin causar afectaciones en los modelos reales. (Hosamo et al., 2022)
Toward failure mode and effect analysis for heating, ventilation and air-conditioning.	11	Buscando un continuo aprovechamiento energético, se busca hacer uso ciencias computacionales, mediante el análisis preliminar de una herramienta HVAC FMEA a partir de un gran número de órdenes de trabajo obtenidas de un BEMS en operaciones propias de mantenimiento rutinario.(Yang et al., 2017)
Machine Learning-Based Prognostics for Central Heating and Cooling Plant Equipment Health Monitoring.	10	La detección, el diagnóstico y el pronóstico de fallas (FDDP) garantizan la eficiencia operativa y la seguridad de los sistemas de ingeniería, específicamente en los sistemas de calefacción y aire acondicionado. Por lo tanto se realiza un modelamiento con información recopilada de los sensores y las rutinas de mantenimiento que busque aumentar la detección temprana de fallas y con ello aumentar la eficiencia de los sistemas. (Yang et al., 2021)
Toward machine learning-based prognostics for heating ventilation and air-conditioning systems.	6	El desarrollo de un método que permite determinar los lineamientos bajo los cuales el modelamiento de un proceso de mantenimiento predictivo es evaluado y puesto a prueba. Permite establecer una mirada crítica y seria a las soluciones planteadas a la problemática de la presencia de fallas inesperadas en sistemas HVAC. (Yang et al., 2019)
Preventive maintenance of centralized HVAC systems: Use of acoustic sensors, feature extraction, and unsupervised learning.	1	El uso de sensores acústicos que capturen los sonidos de los equipos y los comparen con información previamente guardada de equipos operando normalmente, permite establecer un paso significativo dentro del mantenimiento predictivo. Haciendo uso de un recurso, muchas veces dado por alto, el sonido. (Srinivasan et al., 2017)

MAESTRIA EN INGENIERIA
DOCUMENTO FINAL DE TRABAJO DE GRADO

Review of predictive maintenance algorithms applied to HVAC systems.	0	El mantenimiento predictivo posee entre sus principales ventajas la posibilidad de aumentar la confiabilidad del equipo sin incurrir en sobrecostos. Por ellos son muchas las investigaciones relacionadas con dicho proceso. Mediante esta investigación se busca condensar aquellas publicaciones que tuvieron como eje conductor los sistemas HVAC, analizando su enfoque y permitiendo un punto de partida para su implementación en este sector industrial. (Es-sakali et al., 2022).
Physics guided Gaussians process for HVAC systems performance prognosis.	0	Las técnicas de predicción matemática se clasifican en técnicas de modelo y técnicas de datos. Siendo las segundas de gran uso hoy en día, debido principalmente a la facilidad de su implementación, pese a que requieren un gran número de datos para su desarrollo. La investigación tiene como propósito fortalecer el método basado en modelo matemático, tomando con la particularidad que se usan datos para establecer las condiciones de frontera y así obtener un modelo robusto y aplicable. (Zhang et al., 2022)
A predictive model for an effective maintenance of hospital critical systems	0	En este trabajo se presenta un modelo predictivo para el mantenimiento de sistemas críticos en instalaciones hospitalarias. Principalmente sistemas HVAC como manejadoras de aire, calefacción y sistemas de ventilación. (Al-Tal et al., 2021)
Predictive Maintenance of Air Conditioning Systems Using Supervised Machine Learning	0	Mediante un algoritmo de predicción se busca analizar datos a fin de predecir las fallas más comunes en los sistemas de aire acondicionado doméstico, fugas de gas refrigerante y daño de capacitor. A fin de evitar la disminución de la confiabilidad, gastos de mantenimientos correctivos e ineficiencia energética. (Trivedi et al., 2019)
Predictive maintenance systems for efficiency improvement of heating equipment.	0	Los sistemas de HVAC consumen aproximadamente el 48% del consumo energético de los hogares, por lo tanto, la implementación de modelos matemáticos predictivos que busquen una operación optima es de gran importancia en el campo de la eficiencia energética. (Santiago et al., 2019)
Modelo-based predictive maintenance of chillers	0	Este documento investiga las ventajas del modelado de series temporales para la detección y el diagnóstico de fallas de Chillers (FDD), en comparación con los enfoques estándar basados en datos o en residuos.(Ke et al., 2014)

Fuente. Los autores, 2023. Tomado de: <https://www-scopus-com>.

Otro punto focal en la investigación fue consolidar una relación entre la metodología ágil de gestión de proyectos conocida como Scrum y el desarrollo de historia de usuario como medio mediante el cual se establece los lineamientos básicos de una herramienta tecnológica, para lo cual se entiende que su incorporación va asociada a la forma como se desarrolló la investigación y herramienta computacional. Los criterios de búsqueda se especifican la figura 8.

Figura 8. Resultados de la búsqueda de investigaciones desde su forma.

The screenshot shows the Scopus search interface. At the top, there's a navigation bar with the Scopus logo, a search bar, and links for Sources, SciVal, and a user profile icon labeled 'JN'. Below the navigation bar, a welcome message reads: 'Welcome to a more intuitive and efficient search experience. See what is new'. The main search area features a 'Search within' dropdown set to 'Article title, Abstract, Keywords' and a 'Search documents' input field containing 'user AND stories'. Below this, a second search field is visible with 'scrum' entered. The interface includes buttons for 'Save search', 'Set search alert', '+ Add search field', 'Reset', and 'Search'. At the bottom, it indicates '181 documents found' and provides links for 'Documents', 'Patents', 'Secondary documents', and 'Research data'. An 'Analyze results' link is also present.

Fuente. Los autores, 2023. Tomado de: <https://www-scopus-com>.

Debido al gran número de publicaciones relacionadas, su revisión se limitó a aquellas que presentan licencia tipo open access, ya que permiten una revisión completa y por ende un planteamiento más sólido de las conclusiones. Disminuyendo la cifra a un total 26 investigaciones. Los cuales en la tabla 5 se clasifican por la relación de su temática con el núcleo del proyecto.

Tabla 5. Análisis preliminar de los resultados de la investigación relacionadas de forma.


COINCIDENCIA CON LOS TEMAS DE LA INVESTIGACION	CANTIDAD
Totalmente relacionado	10
Parcialmente relacionado	15
No relacionado	1

Fuente. Los autores, 2023. Tomado de: <https://www-scopus-com>.

MAESTRIA EN INGENIERIA
DOCUMENTO FINAL DE TRABAJO DE GRADO

De igual manera se revisa en la figura 9, el avance de estos marcos de desarrollo de herramientas tecnológicas en forma de publicaciones de tipo investigativo.

Figura 9. Publicaciones relacionadas por año con la investigación desde su forma.



Fuente. <https://www-scopus-com>

Continuando la línea de análisis previamente planteada, se realizó una organización de los documentos encontrados, su influencia en diferentes investigaciones mediante citas y su aporte a la generación y/o fortalecimiento del conocimiento en la tabla 6. Esta revisión es de gran importancia en el desarrollo de los objetivos del proyecto, pues plantea el marco de ejecución y posterior evaluación de la implementación tanto de las historias de usuario y como de los sprints, concluyendo su total cumplimiento o desviaciones en el respecto análisis de resultados.

Tabla 6. Análisis detallado de los artículos relacionados de forma con la investigación.

ARTICULO	CITACIONES	APORTE
Automatic Transformation of User Stories into UML Use Case Diagrams using NLP Techniques	52	Establece un proceso de transformación de historias de usuario en casos de uso que permita bajo un enfoque MDA, aumentar significativamente la validación del producto de acuerdo con las demandas del usuario/cliente(Elallaoui et al., 2018).
Comparing requirements decomposition within the Scrum, Scrum with Kanban, XP, and Banana development processes	27	En el proceso de desarrollo de software, los requisitos del cliente generalmente son presentados de forma no estructurada, para el respectivo análisis por los equipos de trabajo existen métodos ágiles, los cuales difieren entre si, dando espacio al análisis de su viabilidad en esta investigación (Taibi et al., 2017).

MAESTRIA EN INGENIERIA
DOCUMENTO FINAL DE TRABAJO DE GRADO

A risk management framework for distributed scrum using prince2 methodology	20	La metodología Scrum es sin duda la mas implementada a la hora de desarrollar herramientas tecnológicas, sin embargo, su efectividad no debe darse como completa, sin la debida validación de procesos paralelos como PRINCE2 el cual permite administrar de forma lineal e imparcial el desarrollo de los proyectos con los objetivos planteados (Esteki et al., 2020).
The role of the user story agile practice in innovation	14	Establece una metodología evaluadora de las historias de usuario como bases en el proceso de innovación, principalmente por el marco no técnico y centrado en el usuario que poseen (O'hEocha & Conboy, 2010).
Modelling agile requirements using context-based persona stories	7	Presenta un método para la modelación de historias de usuario en procesos ágiles mediante técnicas HCD (Sedeño et al., 2017).
The impact of using a domain language for an agile requirement management	6	Esta investigación presenta un enfoque de trazabilidad en el cumplimiento de historias de usuario, principalmente en proyectos sujetos a periodos largos de desarrollo, donde es común no visualizar fácilmente las desviaciones con respecto al objetivo trazado (Urbieto et al., 2020).
Evaluating the impact of user stories quality on the ability to understand and structure requirements	6	Bajo el marco de QUS pretende evaluar y mejorar la calidad de las historias de usuario. Etiquetándolas para su posterior evaluación (Wautelet et al., 2019).
Incorporating quality control activities in scrum in relation to the concept of test backlog	6	Mediante la incorporación de backlog de pruebas se busca establecer un marco de calidad del método de gestion de proyectos conocido como Scrum (Aamir & Khan, 2017).

MAESTRIA EN INGENIERIA
DOCUMENTO FINAL DE TRABAJO DE GRADO

Implementation of use case point as software effort estimation in Scrum Framework	5	El UCP es un método de estimación de esfuerzo en el desarrollo de herramientas informáticas, por lo tanto, se plantea como objetivo la implementación de esta metodología en el proceso Scrum a fin de obtener un proceso mas eficiente sin descuidar los objetivos planteados (Yuliansyah et al., 2018).
A project tracking tool for scrum projects with machine learning support for cost estimation	3	Son varios los modelos existentes en la estimación del costo de producción de software, se determina el costo asociado al diseño y desarrollo de una herramienta tecnológica que fue creada bajo metodología Scrum (Periyasamy & Chianelli, 2021).


Fuente Los autores, 2023. Tomado de: <https://www-scopus-com>.

7. METODOLOGIA

Siendo la investigación, cuantitativa de tipo predictiva ya que se pretende pronosticar patrones de comportamiento a través de un modelo de machine learning programado en una aplicación de escritorio, con un diseño de investigación experimental y un diseño muestral no probabilístico seleccionado por conveniencia. (Monroy Mejia & Nava Sanchezllanes, 2018)

Para el desarrollo de proyectos tecnológicos, existen varias metodologías, entre ellas Scrum, la cual, por su flexibilidad de trabajo, permite retroalimentación continua, aportando a la construcción de un desarrollo oportuno, tal como se indica en la figura 10. (Heras del Dedo & Alvarez Garcia, 2017)

Figura 10. Ciclo Scrum



Fuente. Los autores, 2023. Adaptado de Heras del Dedo, R. de las, & Alvarez Garcia, A. (2017).

Tomando esta como referencia para delimitar el proceso de generación de un proceso de machine learning, se establecieron cinco (5) fases en el proceso a desarrollar en la investigación. Las cuales se desarrollan dentro de los siguientes capítulos;

7.1. Fase I. Sprint, backlog e historias de usuario

Todo proceso de creación de una herramienta de software debe estar enmarcado bajo una constante gestión de calidad, la cual, según (Subih et al., 2019) debe contar con al menos tres (3) enfoques; calidad en el diseño, calidad en el rendimiento y calidad en la adopción.

Los cuales presentan el marco descrito en la tabla 7, para establecer los atributos mínimos a cumplir cuando se plantea la implementación de una solución de alto valor. Estableciendo así en este apartado, los criterios de evaluación del cumplimiento de las historias de usuario, la metodología ágil y por ende la solución. Ambos no en vano puntualizados en los objetivos específicos.

Tabla 7. Atributos de un software de alta calidad.

ATRIBUTOS QUE CUMPLIR EN FUNCION DE LA CALIDAD		
Diseño	Corrección	El producto debe permitir correcciones y mejoras en sus subprocesos
	Mantenibilidad	El producto debe permitir adicionar y/o características.
Rendimiento	Eficiencia	El producto debe poseer una operación optima en toda su estructura transversal
	Fiabilidad	El resultado del producto debe ser veraz
	Facilidad de uso	La implementación debe ser sencilla
	Evaluable	El producto debe poder someterse a pruebas internas y externas
Adopción	Extensible	La herramienta puede permitir ampliaciones tanto en sus bases de datos como en sus procesos
	Portabilidad	El software debe permitir su uso en locaciones externas (bajo condiciones de arquitectura similares)
	Reutilización	La herramienta debe permitir la reutilización parcial o total de su código y características principales

Fuente. Los autores 2023. Adaptado de Subih et al., 2019.

Siendo la conclusión de esta fase, la definición del entregable (aplicación de escritorio) y la documentación soporte de la herramienta.

7.2. Fase II. Adquisición y preproceso de la información

En este punto de la investigación se desarrolla la adquisición de la información, revisión e identificación los parámetros de valor para el desarrollo de la solución, optimización de la información recopilada, creación de la base de datos SQL.

De igual forma se identifican los problemas asociados a la administración de los datos, y las estrategias implementadas para su solución. Pues es común en la ciencia de datos encontrar información corrupta o faltante y no por ello la implementación debe verse truncada.

7.3. Fase III. Procesamiento de la información y desarrollo de la solución

Constituye el proceso más extenso del proyecto, pues debe contener, la selección de las herramientas y el método a utilizar, el diseño del algoritmo, el desarrollo de la aplicación con su

respectiva interfaz de usuario y su análisis económico. Materializando por primera vez el objetivo principal de la investigación.

7.4. Fase IV. Revisión y retrospectiva

Ningún desarrollo o proyecto tecnológico basado en la predicción de un valor o evento esta completo sin las debidas pruebas del algoritmo de regresión, pues no son pocos los procesos administrativos, que una organización toma basada en dicho modelo y su nivel certeza debe ser elevada, es por ello que la implementación de pruebas de la solución y retroalimentación, tienen un lugar dentro de los objetivos de la investigación.

Igualmente la evaluación del cumplimiento de los objetivos, gestión de calidad y análisis de resultados toman lugar en este lugar de la investigación, dando a conocer la conclusiones encontradas, oportunidades de mejora y los posibles siguientes escenarios en el mismo campo de la investigación.

7.5. Fase V. Entregables y conclusión

No es suficiente con generar una solución, es importante documentar el proceso y materializar un manual de usuario que permita su buena operación, consolidando los objetivos trazados y la materialización de los resultados esperados.

Siendo el objetivo final del proceso, un modelado de una solución de machine learning, debidamente probado, documentado y retroalimentado. Cumpliendo con el objetivo general de la investigación.

8. SPRINTS, BACKLOG E HISTORIAS DE USUARIO

Considerando los objetivos específicos planteados y enmarcado dentro de la Fase I del desarrollo de la investigación, el desarrollo del Backlog y los Sprints, permite establecer un proceso de generación de producto ordenado, priorizando las actividades neurálgicas para el proceso y permitiendo identificar desviaciones de la ejecución. (Heras del Dedo & Alvarez Garcia, 2017) Por lo tanto en la tabla 8 se establece el backlog del proyecto, sus sprints y criterios de evaluación.

Tabla 8. Backlog del Producto

Proceso Transversal	BACLOKG DEL PRODUCTO		
Aplicación de escritorio para mantenimiento predictivo de equipos industriales de refrigeración a través de machine learning.	Sprint	Descripción	Criterio de evaluación
	1	Planteamiento del problema y descripción de la solución planteada	¿La solución planteada atiende las necesidades del cliente?
	2	Recopilación de la información - Análisis del estado del arte y vigilancia tecnológica.	¿Se establece una perspectiva de la investigación dentro de la comunidad académica y un soporte bibliográfico fiable?
	3	Revisión y selección de los parámetros operacionales. - Identificación de parámetros operacionales significativos al proceso. - Prefiltrado, revisión y optimización de la información.	¿La información entregada esta optimizada y obedece a las necesidades del algoritmo?
	4	Análisis y selección del método utilizado para el análisis de datos - Construcción de la base de datos - Identificación y selección de las herramientas tecnológicas a utilizar	¿Se tiene una base de datos adecuada para el consumo por el algoritmo? ¿Las herramientas seleccionadas cumplen con los requerimientos a un bajo costo?
	5	Diseño del algoritmo de procesamiento de la información y flujo de trabajo de la aplicación	¿Se implementan las historias de usuario dentro de la solución?

MAESTRIA EN INGENIERIA
DOCUMENTO FINAL DE TRABAJO DE GRADO

	6	Desarrollo de la aplicación de escritorio - Configuración de la interfaz conforme a las historias de usuario - Selección de plantillas de uso, colores y logos - Programación del proceso de preproceso, análisis y retroalimentación	¿El resultado es un producto mínimo viable? ¿Esta optimizada la solución?
	7	Realización de pruebas, retroalimentación y corrección	¿La solución cumple con los criterios de calidad planteados? ¿El análisis numérico de la solución cumple con los estándares?
	8	Desarrollo de la documentación	¿La documentación proporciona información de desarrollo y uso de la solución?

Fuente. Los autores, 2023.

El backlog del producto, pese a que determina una línea a trazar puede estar sujeto a cambios, modificaciones o actualizaciones, pues en el proceso pueden aparecer actividades que no fueron priorizadas en el momento de dar inicio. (Echavarria Ortiz, 2022)

No en vano especificadas como un objetivo a cumplir en la investigación las historias de usuario son utilizadas generalmente como la forma mediante la cual se describen las expectativas, necesidades y procesos que se esperan de la solución desde un lenguaje sencillo y poco tecnificado, constituyéndolas como un requerimiento fundamental en la definición de la solución a las necesidades identificadas. (Diercks et al., 2022). Para facilitar el proceso formulación de las historias de usuario, se establecen dos diferentes perfiles. Descritos en la tabla 9.

Tabla 9. Perfiles implementados en las historias de usuario

NOMBRE	PERFIL	CARACTERISTICAS
Usuario 1	Ingeniero de mantenimiento HVAC&R	Centrado en la implementación de la aplicación para la gestión de los recursos ante el acercamiento de la fecha de la eventualidad.
Usuario 2	Coordinador de mantenimiento	Su prioridad principal es verificar la información incorporada en la aplicación, haciendo uso de su experiencia, identifica datos inconsistentes y los valida.

Fuente. Los autores 2023

La parametrización de las historias de usuario va de la mano de los atributos de gestión de calidad evidenciados en la sección 7.1. Y su evaluación se realiza de acuerdo con la validación

MAESTRIA EN INGENIERIA
DOCUMENTO FINAL DE TRABAJO DE GRADO

proporcionada individualmente. Las tablas consecuentes entregan las historias que se definieron por los usuarios de la solución.

Tabla 10. Historia de usuario 1.

HISTORIA DE USUARIO		Numero:1
Nombre de la Historia: Como usuario quiero disponer de una herramienta informática que disminuya las labores de mantenimiento no programados		
Cliente: Usuario 1	Responsable: José Andrés Quiroga Niño	Prioridad: Alta
Sprint: 0	Versión: 1	
Fecha de Inicio: 15/06/2022	Fecha de Terminación: 15/12/2022	
Descripción:		
Como usuario quiero usar herramientas computacionales y Machine Learning que me permita aumentar la disponibilidad de mis equipos de aire acondicionado industrial.		
Atributo de calidad:		
Fiabilidad		
Criterio de validación:		
¿La implementación de la herramienta facilita la gestión de mantenimiento preventivo y correctivo?		
Observaciones de implementación:		
La herramienta debe ser de aplicación tipo escritorio		

Fuente. Los autores, 2023.

Tabla 11. Historia de usuario 2.

HISTORIA DE USUARIO		Numero:2
Nombre de la Historia: Como usuario quiero usar la información operacional para predecir fugas de gas refrigerante en sistemas HVAC&R.		
Cliente: Usuario 1	Responsable: José Andrés Quiroga Niño	Prioridad: Alta
Sprint: 6	Versión: 1	
Fecha de Inicio: 15/06/2022	Fecha de Terminación: 15/12/2022	
Descripción:		
Como usuario quiero obtener una fecha aproximada de la falla por fugas de gas refrigerante, a partir del procesamiento de los parámetros operacionales obtenidos del sistema.		
Atributo de calidad:		
Facilidad de uso		
Criterio de validación:		
¿La herramienta predice fugas, día o semana aproximada del evento?		
Observaciones de implementación:		
La herramienta debe permitir el ingreso de mas información.		

Fuente. Los autores, 2023.

MAESTRIA EN INGENIERIA
DOCUMENTO FINAL DE TRABAJO DE GRADO

Tabla 12. Historia de usuario 3.

HISTORIA DE USUARIO		Numero: 3
Nombre de la Historia: Como usuario quiero saber que tan fiable es la predicción realizada por la aplicación informática.		
Cliente: Usuario 1	Responsable: José Andrés Quiroga Niño	Prioridad: Alta
Sprint: 6	Versión: 1	
Fecha de Inicio: 15/06/2022	Fecha de Terminación: 15/12/2022	
Descripción:		
Como usuario deseo obtener una evaluación cuantitativa de la certeza estadística del resultado. Tal que me permita retroalimentar y comparar eventualmente.		
Atributo de calidad:		
Fiabilidad, Corrección		
Criterio de validación:		
¿La predicción realizada, cumple un marco de evaluación transparente?		
Observaciones de implementación:		
Debe compararse la predicción con la aparición de la falla. Dando pie a comparaciones y estimaciones estadísticas.		

Fuente. Los autores, 2023.

Tabla 13. Historia de usuario 4.

HISTORIA DE USUARIO		Numero: 4
Nombre de la Historia: Como usuario quiero ver, revisar y mejorar la información recopilada		
Cliente: Usuario 2	Responsable: José Andrés Quiroga Niño	Prioridad: Media
Sprint: 6	Versión: 1	
Fecha de Inicio: 15/06/2022	Fecha de Terminación: 15/12/2022	
Descripción:		
Como usuario deseo poder acceder a la información de consumo, revisarla y eventualmente mejorarla.		
Atributo de calidad:		
Evaluable, Corrección		
Criterio de validación:		
¿La información de consumo del algoritmo es accesible?		
Observaciones de implementación:		
Consolidar la información por equipos y por fecha, permite comparar desviaciones de operación entre activos idénticos a través del tiempo y/o condiciones atmosféricas para el mismo periodo.		

Fuente. Los autores, 2023.

Tabla 14. Historia de usuario 5.

HISTORIA DE USUARIO		Numero: 5
Nombre de la Historia: Como usuario quiero identificar desviaciones en la información utilizada		
Cliente: Usuario 2	Responsable: José Andrés Quiroga Niño	Prioridad: Media
Sprint: 6	Versión: 1	
Fecha de Inicio: 15/06/2022	Fecha de Terminación: 15/12/2022	
Descripción:		
Como usuario quiero una ayuda visual que me permita identificar valores fuera de rango que puedan interferir en la predicción y poder ser corregidos.		
Atributo de calidad:		
Evaluable, Corrección, Fácil uso		
Criterio de validación:		
¿Puedo identificar desviaciones en la información fácilmente?		
Observaciones de implementación:		
La información debe ser accesible y comparable rápidamente, para su buena implementación dentro del algoritmo.		

Fuente. Los autores, 2023.

Delineadas las historias de usuario, en la tabla 15 es posible realizar una clasificación de los principales atributos de calidad bajo los cuales fueron descritas, a fin de evaluar su posterior cumplimiento en la solución desarrollada.

Tabla 15. Clasificación de historias de usuario, según sus atributos de calidad.

HISTORIA DE USUARIO	ATRIBUTOS DE CALIDAD			
	Fiabilidad	Facilidad de uso	Corrección	Evaluable
Historia 1	X			
Historia 2		X		
Historia 3	X		X	
Historia 4			X	X
Historia 5		X	X	X

Fuente. Los autores, 2023.

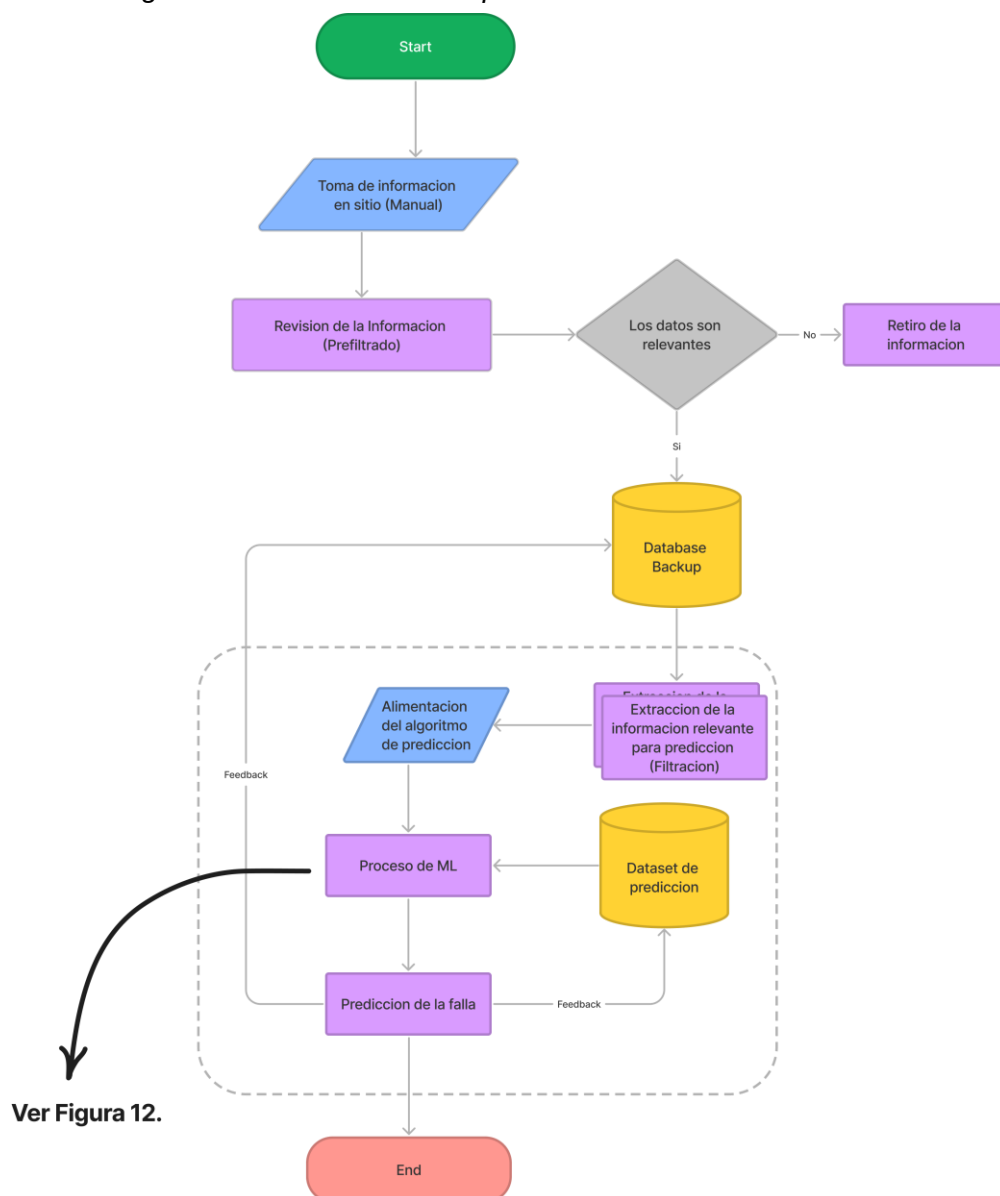
Siendo entonces el atributo de mayor importancia a la hora de definir las necesidades del cliente, el poder manipular la información contenida en el proceso, con el propósito de validarla y eventualmente mejorarla en pro de una herramienta más robusta.

9. DESARROLLO DE LA SOLUCIÓN

9.1. Adquisición y preprocesamiento de los datos

Pese a que no hace parte de forma directa con el proceso del desarrollo de la aplicación, la toma de datos en campo hace parte del procedimiento general y por ende fue incluido dentro de la Fase II del proyecto, pues entrega la materia prima para crear la herramienta, en este caso, se toma información recopilada de forma manual desde el 2018, la cual no está exenta de poseer errores, obligando con ello un proceso de revisión, y limpieza previa. Evitando el uso de datos erróneos en el desarrollo de la herramienta.

Figura 11. Proceso general de desarrollo de aplicación.



Ver Figura 12.

Fuente. Los autores, 2023. Adaptado de Candanedo, I. S., Nieves, E. H., González, S. R., Martín, M. T. S., & Briones, A. G. (2018).

Siendo el inicio de la investigación, los datos digitalizados y tabulados, sin profundizar en los procesos previos realizados, muchos de los cuales pertenecen a rutinas de mantenimiento preventivo programado y operación del equipo.

Teniendo dicho dataset, se requiere un proceso de prefiltrado, determinando cuales datos generan una medida cuantitativa directa o indirecta del estado del equipo y su buena operación. Siendo los siguientes datos los de más importancia para el modelo:

✓ **Fecha**

Facilita la predicción pues establecer la variante del tiempo dentro del análisis. Al reportar la fecha en la cual se tomaron los datos operacionales.

✓ **Equipo**

Una nomenclatura del equipo facilita el feedback en con su historial y comprobar la eficiencia de la herramienta al predecir la falla del activo en la fecha estipulada.

✓ **Refrigerante**

Importante a la hora de establecer las métricas de la operación, pues las presiones tanto de alta como de baja dependen directamente de este, en nuestro análisis tienen lugar los siguientes R410a, R407c, R134a y R22. Los cuales son utilizados para aplicaciones de aire acondicionado y refrigeración. Sus diferencias principalmente obedecen a evoluciones de carácter medioambiental y eficiencia energética. Pero su uso es general en la industria nacional.

✓ **Temperatura exterior y temperatura interior**

Expresada en grados Celsius, están estrechamente relacionadas con la operación del circuito de refrigeración y por ende de las presiones, pues ambientes con temperaturas ambientales extremas generan desviaciones en los valores nominales, generando posibles falsas alarmas.

Los rangos de temperatura interior, se determinan por un concepto conocido como Confort Térmico, el cual establece que existen cinco aspectos para determinar un sensación confortable en un entorno; temperatura, humedad y olor del aire, metabolismo y vestimenta. Para el caso de la temperatura establece un rango de 20,5° -25,5°.(ANSI/ASHRAE 55 - 2020. Thermal Environmental Conditions for Human Occupancy, 2020).

En aplicaciones de refrigeración no existe un rango de temperaturas especial, dado que depende directamente de la aplicación.

Con respecto a la temperatura, exterior. Los datos usados en el modelo corresponden a la ciudad de Barrancabermeja, Colombia. Donde se registraron durante 2021 temperaturas entre 22,1°y

los 30,6°. Es necesario mencionar que el uso de la herramienta no se limita únicamente a dicho lugar, ya que nuevos datos fortalecen la implementación del algoritmo. (Instituto de Hidrología, 2023)

✓ Presión alta y presión baja

Dentro del ciclo de refrigeración, las presiones entran en un constante cambio de fase, debido principalmente a la transferencia de calor, también son la clara señal que un circuito ha perdido gas refrigerante por fugas, pues su valor desciende progresivamente, alejándose de sus valores nominales, su valor está delimitado por el tipo de refrigerante, siendo los valores de referencia. La tabla 16 contiene una relación de los parámetros operacionales normales de la presión de alta y baja de refrigerante en un sistema de refrigeración industrial

Tabla 16. Valores de referencia de presión según tipo de refrigerante.

VALORES DE REFERENCIA OPERACIONALES DE PRESIONES DE REFRIGERANTE		
REFRIGERANTE	PRESION BAJA (PSI)	PRESION ALTA (PSI)
R22	60 - 70	250 - 260
R407C	60 - 75	260 - 275
R410A	120 - 125	370 - 390
R134A	32 - 35	230 - 250

Fuente. Los autores, 2023. Adaptado de Danfoss A/S. (2017).

Sin embargo, los sistemas de aire acondicionado industrial cuentan con protecciones tanto para alta como para baja presión por parte de sus fabricantes, las cuales ejercen un control ON-OFF y actúan cuando los valores alcanzan el setpoint. (Danfoss A/S, 2017)

Los valores utilizados generalmente por los fabricantes permiten establecer un campo de trabajo operacional para la herramienta de machine learning, ignorando la información que no se encuentre dentro de dichos parámetros, pues se entiende que el equipo se encuentra apagado. La tabla 17 expresa los valores límite de los dispositivos de control, establecidos por la mayoría de los fabricantes. Fuera del rango el equipo se encuentra apagado por seguridad.

Tabla 17. Valores de referencia límite para presiones de refrigerante.

VALORES DE REFERENCIA LIMITE DE PRESIONES DE REFRIGERANTE		
REFRIGERANTE	PRESION BAJA (PSI)	PRESION ALTA (PSI)
R22	25	350
R407C	25	350
R410A	80	600
R134A	20	300

Fuente. Los autores, 2023. Adaptado de Danfoss A/S. (2017).

✓ **Amperaje y tensión (voltaje)**

Proveniente directamente de las propiedades eléctricas del compresor, están estrechamente relacionados entre sí y la capacidad frigorífica de este. La variación del amperaje puede indicar múltiples factores internos y externos como; variación del voltaje, fallas mecánicas en el compresor, bajo refrigerante por fugas o alta temperatura exterior.

La tensión posee una particularidad y es que su valor proviene de factores externos (suministro eléctrico de la red), es por ello que esta puede oscilar en rangos sin generar mayores afectaciones en el sistema, siempre y cuando se respeten unos límites superiores e inferiores según el valor nominal. Si el valor operacional se encuentra fuera de las limitaciones establecidas, la funcionalidad del sistema no es correcta, llegando incluso a apagar el equipo, causando falsos pronósticos de falla o desviaciones erróneas. Los fabricantes recomiendan límites que no excedan un 10%. La tabla 18 expresa los valores límite de voltaje de trabajo establecidos por la mayoría de los fabricantes. Fuera del rango el equipo se encuentra apagado por seguridad. (YORK International. Jhonson Controls, 2004)

Tabla 18. Valores de referencia límite para voltaje de red.

VALORES DE REFERENCIA LIMITE DE TENSION		
LIMITE INFERIOR (V)	NOMINAL (V)	LIMITE SUPERIOR (V)
198	220	242
396	440	484

Fuente. Los autores, 2023. Adaptado de YORK International. Jhonson Controls. (2004).

✓ **Capacidad**

Se conoce como la magnitud (expresada en Toneladas de Refrigeración) del calor que el sistema puede retirar del área a acondicionar. Los fabricantes a nivel mundial tienden a estandarizar dicha capacidad entre sus equipos y componentes, facilitando la comercialización de estos.

9.2. Calidad de la información recopilada

Considerados uno de los pilares de la Industria 4.0 según (del Val Román, 2016), los datos juegan un rol importante en el proceso de desarrollo en el desarrollo de la investigación. Sin embargo, la validación de estos y la gestión de su calidad, es algo que se poco es priorizado durante el proceso productivo, el cual se centra en el filtrado y procesamiento con miras a construir las herramientas de software (Martínez et al., 2022).

Con esto como premisa, se identifican las principales fuentes de error en los datos, la naturaleza de estas y estrategias a desarrollar para su paulatina disminución, logrando con ello una mejora en la calidad de los datos y por ende en la solución que cumpla con los atributos de calidad expresados en la Tabla 7.

El tratamiento de los datos es un proceso simple, pero sobre el cual intervienen múltiples factores, siendo la polución la que mayor incidencia tiene sobre el proceso de intercambio de calor, por lo

tanto, en valores de presión y de consumo eléctrico de forma indirecta. Pues un intercambiador en alto estado de suciedad presenta valores de presión de gas refrigerante y consumo eléctrico mayores con respecto al mismo equipo en condiciones limpias (Stanfield & Skaves, 2013), siendo así, es posible evidenciar valores levemente fuera de rango (tomando como referencia las Tablas 16, 17 y 18) que infieren en las predicciones a realizar. Los cuales deben someterse a un proceso de depuración.

Finalmente, la información nuevamente es revisada, optimizada, y catalogada en la base de datos para su respectivo análisis.


9.3. Selección del método y herramientas utilizadas para el análisis de datos

Dando inicio a la Fase III del proyecto, y con la información operacional de los equipos revisada y pre filtrada, fue necesario establecer una metodología de generación del modelo, que incluya la selección de las herramientas utilizadas, sus características y ventajas. Fundamental para poder diseñar el algoritmo de trabajo e interfaz de usuario.

9.3.1. Selección del método para el análisis de datos.

Los modelos de machine learning para mantenimiento predictivo consisten principalmente en un bucle retroalimentado, el cual gira en torno a un algoritmo mediante el cual se identifican patrones de comportamiento y con ello se predice una situación a partir de un momento exacto. (Candanedo et al., 2018)

Figura 12. Etapas de la construcción de un modelo de Machine learning.



Fuente. Los autores.2023. Adaptado de Candanedo, I. S., Nieves, E. H., González, S. R., Martín, M. T. S., & Briones, A. G. (2018).

✓ **Preprocesamiento.**

Antes de realizar un proceso de aprendizaje automático es importante conocer los datos con los cuales se piensa trabajar, pues es allí donde se cimienta todo el ejercicio, tanto así que hoy en día existen profesionales únicamente dedicados al procesamiento, análisis e interpretación de datos (Joshi, 2020)

Su desarrollo viene de la mano de conocimientos objetivos de la problemática a tratar y que objetivos finales se pretenden obtener con los datos. A fin de realizar la selección de la información importante, filtrar posibles datos corruptos o de poca utilidad y generación de datos a partir de los existentes como comportamientos, métricas y estadísticas base (Joshi, 2020)

✓ **Preparación de los datos del entrenamiento.**

Obtenido un dataset de datos útiles, limpios y optimizados, es necesario prepararlos para su uso entrenando el algoritmo. Este proceso se realiza con la ayuda de un DBA (Administrador de bases de datos), es allí donde se establecen las principales señales de alerta y desviaciones a identificar en el modelo. (Salvaris et al., 2018)

✓ **Entrenamiento del algoritmo de machine learning.**

Luego que la información ya ha sido procesada y preparada, es momento de desarrollar el algoritmo de aprendizaje automático, actividad que se ejecuta con la ayuda de herramientas prediseñadas conocidas como API (Interfaz de programación de aplicaciones) y su respectivo IDE (Entorno de desarrollo integrado) donde esta se ejecuta. Es en este proceso donde se selecciona el modelo matemático que presenta los mejores resultados teóricos. Su implementación y comprobación se determinan en fases posteriores. (Salvaris et al., 2018)

✓ **Ingreso de información para prueba, uso del algoritmo de machine learning y predicción del evento.**

Una herramienta de machine learning no es útil si no se usa constantemente, pues es allí donde reside su función principal, para esta tarea es necesario ingresar nueva información que contiene las características mínimas establecidas en el preprocesamiento de los datos, obteniendo a cambio la predicción de eventos, identificación de desviaciones, alarmas tempranas o diagramas de comportamiento. (Joshi, 2020)

✓ **Prueba del modelo y retroalimentación.**

Su incorporación en el proceso permite obtener un algoritmo de nivel superior, que minimice paulatinamente el error en sus predicciones, obteniendo mayores aciertos y mejora de la confiabilidad en un bucle infinito. (Joshi, 2020b)

9.3.2. Selección de las herramientas utilizadas para el análisis de datos.

Para la selección de las herramientas computacionales, se usaron como criterio de evaluación las siguientes características;

- ✓ De uso gratuito o versión educativa gratuita.
- ✓ Cumpliendo con el objetivo principal de la investigación, debe permitir el uso en un hosting local o de escritorio.
- ✓ Con un gran abanico de aplicaciones disponible. No solo para procesos de mantenimiento o sistemas de aire acondicionado industrial.
- ✓ Con una interfaz de usuario amigable.

Obteniendo como mejor opción tres (3) servicios Open Source desarrollados por Microsoft®.

✓ **DBA (Administrador bases de datos) Microsoft SQL Server Management Studio 18.**

Considerado uno de los referentes en cuanto a administración de bases de datos, permite desarrollo y administración de bases de datos tanto de forma local como remota, su interfaz es intuitiva y su versión 18 fue la utilizada en el desarrollo de la investigación. (Microsoft, 2022)

Figura 13. Base de datos en Microsoft SQL Server Management Studio 18.

SQLQuery1.sqlMATEBOOK-X-PROWINCC Project (MATEBOOK-X-PROjaq89 (55))Microsoft SQL Server Management Studio

FileEditViewQueryProjectToolsWindowHelp

Quick Launch [Ctrl+Q]

Object Explorer

Connect

MATEBOOK-X-PROWINCC (SQL Server)

Databases

System Databases

Database Snapshots

Project

Database Diagrams

Tables

System Tables

File Tables

External Tables

dbo.PRUEBA4

Columns

Keys

Constraints

Triggers

Indexes

Statistics

Views

External Resources

Synonyms

Programmability

Service Broker

Storage

Security

Security

Server Objects

Replication

PolyBase

Management

XEvent Profiler

SQLQuery1.sql - M...X-PROjaq89 (55)

select*from dbo.PRUEBA4

100 %

Results Messages

AAO	WeekReg	NumM	NumA	Ref	TE	TI	HighPress1	LowPress1	HighPress2	LowPress2	AlertPA	AlertPB	AP1	AlertPA1	AlertPB1	AP2	Total	AlertPA2	AlertPB2	
40	2018	22	5	2	R407C	31.4	216	265	60	265	66	1	1	2	1	0	1	3	1	1
41	2018	22	5	2	R407C	31.4	216	265	60	265	66	1	1	2	1	0	1	3	1	1
42	2018	34	8	2	R407C	31.4	216	220	70	220	70	0	0	0	0	0	0	0	0	0
43	2018	35	8	2	R407C	31.4	216	220	65	220	65	0	0	0	0	0	0	0	0	0
44	2018	22	5	2	R407C	31.4	216	265	60	265	66	1	1	2	1	0	1	3	1	1
45	2018	22	5	2	R407C	31.4	216	265	60	265	66	1	1	2	1	0	1	3	1	1
46	2018	22	5	2	R22	31.4	216	250	55	240	50	0	0	0	0	0	0	0	0	0
47	2018	40	9	2	R22	31.2	216	240	50	230	50	0	0	0	0	0	0	0	0	0
48	2018	3	0	7	R22	30	216	250	60	260	60	0	0	0	0	0	1	1	0	1
49	2018	30	7	2	R22	31.4	216	280	47	270	50	1	0	1	1	0	1	2	1	1
50	2018	40	9	2	R22	31.2	216	270	50	280	50	1	0	1	1	0	1	2	1	1
51	2018	40	9	2	R22	31.2	216	270	50	270	50	1	0	1	1	0	1	2	1	1
52	2018	3	0	7	R22	30	216	250	50	255	65	0	0	0	0	0	1	1	1	0
53	2018	20	4	2	R22	31.4	216	280	50	290	55	1	0	1	1	0	1	2	1	1
54	2018	40	9	2	R22	31.2	216	300	50	300	45	1	0	1	1	0	1	2	1	1
55	2018	5	1	2	R22	30	216	250	52	250	55	0	0	0	0	0	0	0	0	0
56	2018	8	1	2	R22	30	216	260	55	240	60	1	0	1	0	0	0	1	1	0
57	2018	38	9	2	R22	29.3	216	260	55	255	65	1	0	1	1	0	1	2	1	1
58	2018	15	3	2	R22	30	216	235	60	250	60	0	0	0	0	0	0	0	0	0
59	2018	27	6	2	R22	30.1	216	250	65	255	70	0	0	0	0	0	1	1	1	0
60	2018	42	13	2	R22	29.3	216	250	70	250	65	0	0	0	0	0	0	0	0	0
61	2018	27	6	2	R407C	30.1	216	260	65	260	65	0	0	0	0	0	0	0	0	0
62	2018	1	0	2	R410A	30	216	250	50	265	65	0	0	0	0	0	0	0	0	0
63	2018	23	5	2	R407C	31.4	216	280	50	255	50	0	1	1	0	1	2	1	1	1
64	2018	15	3	2	R410A	30.1	216	340	130	350	135	0	0	0	0	0	0	0	0	0
65	2018	27	6	2	R410A	30.1	216	380	140	400	150	0	0	0	0	0	1	1	1	0
66	2018	37	8	2	R410A	30.1	216	375	150	368	145	0	0	0	0	0	0	0	0	0
67	2018	39	9	2	R410A	30.1	216	380	150	375	148	0	0	0	0	0	0	0	0	0
68	2018	27	6	2	R410A	30.1	216	390	150	390	150	1	0	1	1	0	1	2	1	1
69	2018	2	0	2	R22	30	216	260	65	250	55	1	0	1	0	0	1	1	1	0
70	2018	27	6	2	R22	30.1	216	230	60	240	65	0	0	0	0	0	0	0	0	0
71	2018	27	6	2	R407C	30.1	216	260	55	260	50	0	1	1	0	1	1	2	1	1
72	2018	9	2	2	R410A	31.4	216	300	115	305	110	0	0	0	0	0	0	0	0	0
73	2018	10	2	2	R410A	31.2	216	300	115	295	120	0	0	0	0	0	0	0	0	0
74	2018	6	1	2	R410A	31.4	216	300	120	295	115	0	0	0	0	0	0	0	0	0
75	2018	2	0	2	R407C	30	216	290	55	265	65	0	1	1	0	0	1	2	1	1
76	2018	18	4	2	R407C	30	216	270	65	265	65	1	0	1	1	0	1	2	1	1
77	2018	5	1	1	R22	30	216	260	65	245	58	1	0	1	0	0	0	1	1	0
78	2018	10	2	2	R22	31.2	216	240	65	235	65	0	0	0	0	0	0	0	0	0
79	2018	1	0	2	R22	30	216	230	63	235	65	0	0	0	0	0	0	0	0	0
80	2018	9	2	2	R410A	31.4	216	405	105	430	160	1	0	1	1	0	1	2	1	1
81	2018	9	2	2	R410A	31.4	216	415	125	400	120	1	0	1	0	0	1	2	1	1
82	2018	21	5	2	R410A	30	216	380	120	380	115	0	0	0	0	0	0	0	0	0
83	2018	38	9	2	R410A	30.1	216	305	115	300	120	0	0	0	0	0	0	0	0	0
84	2018	9	2	2	R410A	31.4	216	400	120	410	125	1	0	1	1	0	1	2	1	1
85	2018	21	5	2	R410A	30	216	380	115	380	115	0	0	0	0	0	0	0	0	0
86	2018	39	9	2	R410A	30.1	216	310	120	310	120	0	0	0	0	0	0	0	0	0
87	2018	71	5	2	R410A	30	216	390	170	390	170	0	0	0	0	0	0	0	0	0

Query executed successfully.

MATEBOOK-X-PROWINCC (13.0... MATEBOOK-X-PROjaq89 (55) Project 0:00:00 695 rows

Fuente. Los autores, 2023. Adaptado de Microsoft. (2022c, December 5).


✓ **IDE (Entorno de desarrollo integrado) Microsoft Visual Studio**

Con una interfaz un poco más compleja, este IDE es considerado uno de los referentes en la creación de aplicaciones de escritorio, permite una gran integración con diversos lenguajes de programación y posee una versión gratuita (Community) para pequeños desarrollos. (Microsoft, 2022).

✓ **API (Interfaz de programación de aplicaciones) ML.NET Model Builder.**

Desarrollada por Microsoft, esta API ofrece un completo acceso a desarrollo de aplicaciones de machine learning con una interfaz visual intuitiva y agradable. Su uso en el mercado no es tan prominente, principalmente porque el lenguaje de trabajo en C# y no Python como la mayoría de aplicaciones similares. (Microsoft, 2022). Como se indica la figura 14.

Figura 14. Microsoft Visual Studio 2022 y ML.NET Model Builder.



Fuente. Los autores, 2023. Adaptado de Microsoft. (2022a).

La API ML.NET presenta cuatro (4) escenarios o ambientes de entrenamiento de modelos de machine learning;

- ✓ **Clasificación de datos.** Opera tanto para valores binarios como multiclase, tal es el caso de oraciones. Permite realizar un análisis clasificatorio, mediante teorías de conjuntos.

- ✓ Predicción de valor. Como su nombre lo indica, predice valores a raíz de tendencias previamente incorporadas.
- ✓ Recomendaciones. Muy utilizado en campañas de marketing y contenido digital, basándose en tu navegación e información de usuario predice las publicaciones que te resultan de mayor interés.
- ✓ Estimaciones. Presenta una regresión en el dominio del tiempo, tal que se pueda realizar una estimación en el futuro tomando como base comportamientos previos incorporados.

9.3.3. Requisitos mínimos para ejecución

De igual forma se establecen unos requisitos mínimos de operación, siendo el poco uso de recursos tecnológicos la principal característica.

- ✓ Sistema operativo Microsoft Windows 7 de 64 bits o superior.
- ✓ 1 GB de espacio en disco duro.
- ✓ 4 GB de Memoria RAM.
- ✓ Microsoft .Net Framework 4.8.
- ✓ Local BD SQL Server 2019.


9.4. Desarrollo del algoritmo y flujo de trabajo de la aplicación

El uso de la API ML.NET Modelo Builder se realiza de forma secuencial y con la ayuda de una intuitiva interfaz gráfica.

✓ Selección del escenario de trabajo.

Tal como indica la figura 15. La aplicación posee varias formas de trabajo, sin embargo, para este caso puntual se usara el modelo de predicción de valor, muy útil no solo en soluciones de mantenimiento predictivo, sino también en modelos económicos y bursátiles.

Figura 15. Selección de escenario de trabajo.



Fuente. Los autores, 2023. Adaptado de Microsoft. (2022).

✓ **Selección del ambiente de entrenamiento.**

La API permite el uso de varios ambientes de entrenamiento o hardware, siendo estos; local CPU (Procesadores), local GPU (Tarjetas gráficas) o servicios cloud (Microsoft Azure) tal como indica la tabla 19, según el escenario seleccionado. (Microsoft, 2022).


Tabla 19. Ambientes de entrenamiento disponibles según el escenario seleccionado.

Escenario	Local CPU (Procesadores)	Local GPU (Tarjetas Gráficas)	Cloud (Microsoft Azure)
Clasificación de datos	Si	No	No
Predicción de valor	Si	No	No
Recomendación	Si	No	No
Pronósticos	Si	No	No
Clasificación de imágenes	Si	Si	Si
Detección de objetos	No	No	Si
Clasificación de textos	Si	Si	No

Fuente. Los autores, 2023. Adaptado de Microsoft. (2022).

Para nuestro caso particular en la figura 16, podemos ver los servicios disponibles para el escenario Predicción de valor.

Figura 16. Ambiente de entrenamiento para el escenario predicción de valor.




Fuente. Los autores, 2023.

✓ **Adición de la información.**

La información previamente tratada y optimizada en el gestor de base de datos, se incorpora en la herramienta mediante un archivo CVS. De igual manera, se realiza la disposición del tipo de dato (Booleano, String, Single, etc) como se muestra en la figura 17.

Figura 17. Incorporación de datos en la aplicación.




Fuente. Los autores, 2023.

✓ Entrenamiento de la solución

El siguiente paso es entrenar la solución, donde se debe establecer el tiempo de dicho entrenamiento como se muestra en la figura 18.

Un mayor tiempo de entrenamiento, no significa mayor precisión en el proceso, pues las iteraciones pueden tomar desviaciones, disminuyendo la precisión.

Figura 18. Entrenamiento de la solución.




Fuente. Los autores, 2023.

✓ **Evaluación de la solución.**

La evaluación de la solución esta anidada dentro de la herramienta, entregando la posibilidad de retroceder y realizar cambios en el proceso. Tal como se muestra en la figura 19.

Figura 19. Evaluación de la solución.




Fuente. Los autores, 2023.

✓ **Incorporación de información a la database (Consumo) y construcción de la interfaz de usuario.**

El consumo de la información, o incorporación en la base de datos es un proceso que permite la mejora continua del proceso. De igual manera a partir de este punto se construye la solución ya sea mediante una aplicación de consola o aplicación con interfaz de usuario². Tal como se muestra la figura 20.

Figura 20. Consumo de nueva información.




Fuente. Los autores, 2023.

² La construcción de la interfaz de usuario no representa ningún valor agregado investigativo, por ende, no tiene lugar en el documento.

✓ **Despliegue y fortalecimiento de la aplicación para uso por terceros.**

La figura 21, muestra las opciones de despliegue y fortalecimiento de la aplicación. Ya sea mediante la incorporación de servicios cloud o aplicaciones de escritorio.

Figura 21. Opciones de despliegue y fortalecimiento de la aplicación.




Fuente. Los autores, 2023.

9.5. Configuración de la interfaz de usuario

✓ Nombre y logo

Usando como referencia las palabras Predictivo y Confort térmico, se establece PREDICONFORT (Versión 1.0) como el nombre de la aplicación. Usando como icono una imagen propia y de libre uso en Windows, como se muestra en la figura 22.


Figura 22. Icono de la aplicación PREDICONFORT 1.0



Fuente. Microsoft Windows 10, 2022.

También se establece como imagen de marca, para uso en publicaciones e informes del producto, la figura 23 que contiene un sin número de engranajes dentro de un bombillo.

Figura 23. Imagen de la marca PREDICONFORT 1.0.




Fuente. https://www.freepik.es/vector-gratis/bombilla-concepto-engranajes-engranajes_10603580.htm

✓ **Paleta de colores**

La paleta de colores utilizada en la aplicación comprende la gama del azul y gris, como muestra la figura 24. Colores comúnmente utilizados por marcas, empresas y aplicaciones de la industria HVAC&R por sus siglas en inglés (Heating, Ventilation, Air Conditioning and Refrigeration).

Figura 24. Paleta de colores utilizados.




Fuente. Los autores, 2023.

✓ **Interfaz de usuario**

La interfaz de usuario está constituida por una (1) ventana inicial mostrada en la figura 23 de solo uso mientras abre la aplicación y una (1) de ventana principal, sobre la cual se identifican las tres (3) secciones de la herramienta, como muestra la figura 25.

Figura 25. Ventana inicial.




Fuente. Los autores, 2023.

MAESTRIA EN INGENIERIA

DOCUMENTO FINAL DE TRABAJO DE GRADO

La ventana principal tiene como propósito presentar un panel lateral izquierdo donde se disponen las tres (3) secciones y disponer del área de trabajo.

Figura 26. Ventana principal.



Fuente. Los autores, 2022.

✓ Sección Inspección

Tiene como propósito revisar la data con la cual trabaja el algoritmo de predicción, haciendo énfasis en que la información faltante o no correspondiente con el rango de valores predeterminado se ve resaltado en un color diferente y así poder ser revisado o corregido, como muestra la figura 27. (Alfonso Diaz et al., 2022)

Figura 27. Sección inspección.

Id	Fecha	Equipo	Refrig...	T Ext	T Int	PAlta 01	PBaja ...	PAlta02	PBaja ...	A1	A2	A3	Tensión	Cap	Observ
1		AA40...	R407C	30	28	265	60	260	60	8,1	7,4	7,6	470	8	
2		AA40...	R407C	28,8	22	250	60	240	60	7,7	7,5	8	476	8	
3		AA40...	R410A	29,3	21	230	60	240	60	12,2	11,3	11,5	472	15	
4		AA40...	R410A	28,8	22	260	65	265	70	12,7	12	11,4	476	15	
5		AA48...	R407C	30		275	65	275	65	16,5	15,4	15,6	473	34	
6		AA48...	R407C	30		270	65	270	63	18,3	17,3	18,7	476	50	
7		AA48...	R407C	30		260	60	265	63	16,5	17,2	16,7	470	50	
8	8/11/...	SAA1...	R22	28,8		360	125			11,2	12	11,7	470	20	
9	9/11/...	SAA1...	R22	28,8		240	75	240	75	15,4	7	9,1	206	10	
10	7/11/...	SAA1...	R22	28,8		350	125			5,5	6	6	470	13	
11	8/11/...	SAA1...	R410A	28,8		380	130	370	125	11,7	10,9	10,2	465	20	
12	10/11/...	SAA1...	R22	28,8		280	70	270	65	8,6	8	9	475	12	
13		SAA200	R407C	30		250	50	265	65	20,3	21,5	19,9	460	30	
14	20/10/...	SAA2...	R410A	29,3		400	125	380	115	7,8	8	7,9	472	10	
15	9/11/...	SAA2...	R22	28,8		250	50	250	50	11	11	10,8	460	15	
16		SAA2...	R407C	30		250	60	265	65	5	5	5	470	8	
17		SAA2...	R407C	30		250	60	265	65	5,6	5,8	5,5	470	8	

Fuente. Los autores, 2023.

MAESTRIA EN INGENIERIA

DOCUMENTO FINAL DE TRABAJO DE GRADO

✓ Sección Modelo de Predicción

En la figura 28 de esta sección se encuentran dos apartados, uno de ellos es la información del modelo y el otro la predicción del valor. La primera de estas trata sobre los datos utilizados por el modelo, el algoritmo seleccionado y la tasa de confiabilidad o R cuadrado. (Alfonso Diaz et al., 2022)

Figura 28. Información del Modelo.

Arrastre una columna aquí para agrupar por dicha columna																									
Año	Mes	Sem.	Num.	Ref.	Tem.	Tem.	PAIt.	PBaj.	PAIt.	PBaj.	A1...	A2...	A3...	Tens.	Cap.	Alert.	Alert.	Alert.	Alert.	Alert.	Alert.	Total	Alert.	Alert.	Alert.
2017	11	45	1	R22	28,8	21,6	240	75	240	75	15,4	7	9,1	206	10	0	0	0	0	0	0	0	0	0	0
2017	11	45	1	R410A	28,8	21,6	380	130	370	125	11,7	10,9	10,2	465	20	0	0	0	0	0	0	0	0	0	0
2017	11	45	1	R22	28,8	21,6	280	70	270	65	8,6	8	9	475	12	1	0	1	1	0	1	2	1	1	1
2017	10	42	1	R410A	29,3	21,6	400	125	380	115	7,8	8	7,9	472	10	1	0	1	0	1	1	2	1	1	1
2017	11	45	1	R22	28,8	21,6	250	50	250	50	11	11	10,8	460	15	0	0	0	0	0	1	1	0	1	0
2017	10	44	1	R410A	29,3	21,6	400	120	350	115	20,1	21,3	19,7	474	20	1	0	1	0	1	1	2	1	1	1
2017	11	48	1	R410A	28,8	21,6	400	120	350	115	17,5	17,6	11,7	471	20	1	0	1	0	1	1	2	1	1	1
2017	10	44	1	R410A	29,3	21,6	340	110	400	120	19,9	20,2	18,9	474	20	0	1	1	1	0	1	0	1	1	1
2017	12	52	1	R407C	29,1	21,6	272	65	270	62	6,5	6,7	6,8	470	10	1	0	1	1	0	1	2	1	1	1
2017	12	52	1	R22	30,5	21,6	250	45	250	55	22,8	23,4	23,5	460	40	0	0	0	0	0	1	1	0	1	0
2017	11	45	1	R22	30,5	21,6	210	55	225	62	23,3	22,4	21,8	460	40	0	0	0	0	0	0	0	0	0	0
2017	10	41	1	R22	30,5	21,6	270	60	270	60	26,1	27,7	29,6	220	20	1	0	1	1	0	1	2	1	1	1
2017	10	42	1	R22	30,5	21,6	240	65	230	65	22,5	19	21,1	220	20	0	0	0	0	0	0	0	0	0	0
2017	2	7	1	R22	30,5	21,6	250	80	240	80	10,4	10	11,5	220	8	0	0	0	0	0	0	0	0	0	0
2017	12	52	1	R22	30,5	21,6	260	50	250	50	23,7	24,2	25	223	15	1	0	1	0	1	1	2	1	1	1
2017	10	42	1	R22	30,5	21,6	230	65	235	65	13,5	14,8	14,9	463	20	0	0	0	0	0	0	0	0	0	0
2017	10	42	1	R407C	30,5	21,6	300	40	280	60	24,1	25,2	23,3	468	30	1	1	2	1	0	1	2	1	1	1
2017	10	42	1	R407C	30,5	21,6	300	58	280	60	23,1	24,5	22,6	468	30	1	1	2	1	0	1	2	1	1	1
2017	11	47	1	R410A	30,5	21,6	340	120	340	110	10,5	10,3	9,4	476	40	0	0	0	0	1	1	0	1	0	1
2017	11	47	1	R410A	30,5	21,6	340	110	340	110	10,5	10,7	9,8	476	40	0	1	1	0	1	1	0	1	1	1
2017	12	49	1	R410A	29,1	21,6	380	120	375	115	16,9	16,5	17,4	472	20	0	0	0	0	0	1	1	0	1	0
2017	11	47	1	R410A	30,5	21,6	360	130	320	120	13,6	13,5	12,4	460	20	0	0	0	0	0	0	0	0	0	0

Dataframe y datos del modelo

Cantidad de Filas: 526

Cantidad de Columnas: 26

Cantidad de Registros: 13676

Algoritmo: FastForestRegression

R Cuadrado: 0.9883

Fuente. Los autores, 2023.

Por otra parte, la figura 29 muestra la interfaz de predicción del valor, el Cliente ingresa la información operacional del equipo para su procesamiento y consumo por el modelo. (Alfonso Diaz et al., 2022)

Figura 29. Predicción de valor.

Valores de entrada

Fecha: 24/10/2022

Equipo:

Refrigerante: R407C

Temp Exterior (°C):

Temp Interior (°C): 0

Presión Alta01: 0

Presión Baja 01: 0

Presión Alta02: 0

Presión Baja02: 0

A1: 0

A2: 0

A3: 0

Tensión: 0

Capacidad: 0

Procesar

Datos Procesados

Atributo	Valor

Consumir

Semana de alerta

Score

Algoritmo

Trees

Leaves


Feature Fraction

Fuente. Los autores, 2023.

✓ Sección datos

Tiene como propósito principal, presentar de forma gráfica los datos contenidos en el dataset. Tal que se puedan identificar desviaciones con facilidad. Presentando un gráfico por cada variable analizada. En la figura 30 podemos ver los datos de presión de baja (Alfonso Diaz et al., 2022)

Figura 30. Validación de datos.



Fuente. Los autores, 2023.

9.6. Costos del desarrollo y la implementación.

Partiendo del objetivo principal, donde la herramienta desarrollada es para uso de escritorio. Se establecen de acuerdo con una metodología *Lean software development* (Ebert et al., 2012) los tres principales costos asociados a su elaboración para uso comercial; costos por hardware, costos por software y costos por mano de obra.

Siguiendo lo indicado en la sección 9.2.3 *Requisitos mínimos de ejecución*, se realiza la búsqueda comercial de un computador con dichas características. Evidenciando dos (2) posibles opciones con valores comerciales muy similares en la tabla 20.

Tabla 20. Costos asociados a Hardware

Modelo	Características	Valor comercial
Lenovo IdeaPad 14ADA05	AMD Athlon Silver 3050U 8GB de RAM 256GB SSD, AMD Radeon RX Vega 2	\$1.145.017
Asus L210	INTEL Celeron 4020, 4GB de RAM, 256GB.	\$1.194.000

Fuente. Katronix 2023

MAESTRIA EN INGENIERIA
DOCUMENTO FINAL DE TRABAJO DE GRADO

Continuando con las requisiciones de software, se emplearon aplicaciones con licencia gratuita, como; Microsoft SQL Server Management Studio 18 (Administrador de base de datos), Microsoft Visual Studio (Interfaz de desarrollo integrado) y Figma (Prototipado y diseño gráfico), por lo tanto, el costo económico invertido en estos componentes es nulo.

Las características especiales de las personas responsables del proceso y los salarios aproximados del mercado se reflejan en la tabla 21.

Tabla 21. Salarios aproximados de mano de obra

Cargo	SMMLV	Salario Mensual	Salario diario	Responsabilidades
Administrador de producto	5	\$6.500.000	\$217.000	Administrar cada uno de los Sprints del Scrum, entregar indicaciones y mantener un enfoque claro de las necesidades del cliente, son sus principales características.
Ingeniero HVAC&R	3.5	\$4.550.000	\$152.000	Proporcionar la información digitalizada al Ingeniero de Datos. De igual forma realiza las pruebas de la aplicación final, identificando vulnerabilidades y oportunidades de mejora. Velar por la correcta ejecución de los procesos de mantenimiento, gestión de tiempos y recursos.
Ingeniero de Datos	3,5	\$4.550.000	\$152.000	Realizar el filtrado de la información recopilada, creación de la base de datos y estructurarlos para su análisis dentro del Model Builder.
Desarrollador	3	\$3.900.000	\$130.000	Tomar los datos filtrados y construir el modelo de machine learning. Establecer los parámetros de entrada y salida de la herramienta.

MAESTRIA EN INGENIERIA
DOCUMENTO FINAL DE TRABAJO DE GRADO

Diseñador UI/UX	3	\$3.900.000	\$130.000	Entregar al usuario una interfaz intuitiva, que permita una respuesta adecuada a las necesidades planteadas en las historias de usuario.
Técnico HVAC&R	1,5	\$1.950.000	\$65.000	Ejecutar las labores de mantenimiento correctivo y preventivo, adquirir de forma manual la información relevante para el proceso de desarrollo de la herramienta.
Ayudante técnico HVAC&R	1	\$1.300.000	\$43.400	Prestar colaboración en las labores de mantenimiento correctivo y preventivo.

Fuente. LinkedIn, 2023.

Un método de estimación de los recursos requeridos para el desarrollo de la herramienta de analizando uno a uno los procesos contenidos en los sprints constituidos en la tabla 8, y bajo los cuales se construyó el proyecto.

Tabla 22. Cálculo de recursos asociados a mano de obra.

Proceso	Sprint	Recursos consumidos				
		Administrador del producto	Ingeniero HVAC&R	Ingeniero de Datos	Desarrollador	Diseñador UI/UX
Planteamiento del problema y descripción de la solución planteada	1	1	3			
Recopilación de la información	2	1	15	15		
Identificación de parámetros operacionales significativos al proceso.	3	1	15	3	3	3
Prefiltrado, revisión y optimización de la información.	3	1	3	15		
Construcción de la base de datos	4	1		3		

MAESTRIA EN INGENIERIA
DOCUMENTO FINAL DE TRABAJO DE GRADO

Identificación y selección de las herramientas tecnológicas a utilizar	4	1		3	3	3
Diseño del algoritmo de procesamiento de la información y flujo de trabajo de la aplicación	5	1			5	
Configuración de la interfaz conforme a las historias de usuario	6	1				3
Selección de plantillas de uso, colores y logos	6	1				3
Programación del proceso de preproceso, análisis y retroalimentación	6	1			3	
Realización de pruebas, retroalimentación y corrección	7	1	1	1	5	5
Desarrollo de la documentación	8	1		1	3	1
Subtotal		12	37	41	22	18
Salario diario		\$217.000	\$152.000	\$152.000	\$130.000	\$130.000
Costo recurso		\$2.604.000	\$5.624.000	\$6.232.000	\$2.860.000	\$2.340.000

Fuente. Los Autores, 2023

Así pues, el desarrollo de una herramienta de machine learning según los objetivos planteados, tiene un costo asociado a mano de obra aproximado \$19.660.000.

Siendo el mayor impacto económico del desarrollo de la aplicación de machine learning la mano de obra, como se muestra en la tabla 23.

Tabla 23. Costos directos de desarrollo de aplicación para mantenimiento predictivo

Detalle	Valor
Costos asociados a hardware	\$1.145.017
Costos asociados a software	\$0
Costos asociados a mano de obra	≈\$19.660.000
Total	≈\$20.805.000

Fuente. Los autores, 2023.

Quizás un costo elevado si no se observa dentro de un proceso de gestión de activos completo y es que cada una de las filosofías de mantenimiento trazadas en la Sección 5.1 posee sus características especiales y su implementación está sujeta tanto a factores de economía, calidad, seguridad, viabilidad y valor agregado a la producción. (Ohta, 2018).

MAESTRIA EN INGENIERIA
DOCUMENTO FINAL DE TRABAJO DE GRADO

Sin embargo, su comparativa bajo el marco de costo económico, presenta una sólida base a la hora de justificar la implementación de la metodología de mantenimiento predictivo en sistemas de aire acondicionado y refrigeración industrial. Tal como se indica en la tabla 24, tomando como lineamiento la mayor frecuencia de fallas por fugas de gas refrigerante sustentada en el Capítulo 2.

Tabla 24. Comparación de costos asociados a las metodologías de mantenimiento

Metodología de mantenimiento	Detalle de costos asociados	Costos asociados
Mantenimiento correctivo	✓ Honorarios de un (1) Técnico HVAC&R y un (1) Ayudante técnico HVAC&R, por un lapso promedio de tres (3) días. ✓ Honorarios de un (1) Ingeniero HVAC&R, por un lapso promedio de un (1) día. ✓ Gas Refrigerante, Lubricantes, Gases inertes y Consumibles para soldadura. Altas afectaciones en la producción por la novedad presentada, costo administrativo asociado a la atención de la actividad no programada.	MO: \$477.000 Materiales: \$850.000
Mantenimiento preventivo	✓ Honorarios de un (1) Técnico HVAC&R y un (1) Ayudante técnico HVAC&R, por un lapso no superior a un (1) día. ✓ Honorarios de un (1) Ingeniero HVAC&R, no superiores a una (1) hora por intervención. ✓ Consumibles de limpieza y lubricación. Baja afectación en la producción debida principalmente al planeamiento de las actividades con anterioridad.	MO: \$127.400 Materiales: \$150.000
Mantenimiento predictivo	✓ Honorarios de Ingeniero HVAC&R, no superiores a una (1) hora por intervención. ✓ Capacidad computacional para administrar la información y desplegar el modelo. Nula afectación en la producción, al constituirse como un proceso independiente y con mínima intervención para el diagnóstico.	MO: \$19.000 Materiales: \$0

Fuente. Los autores, 2023

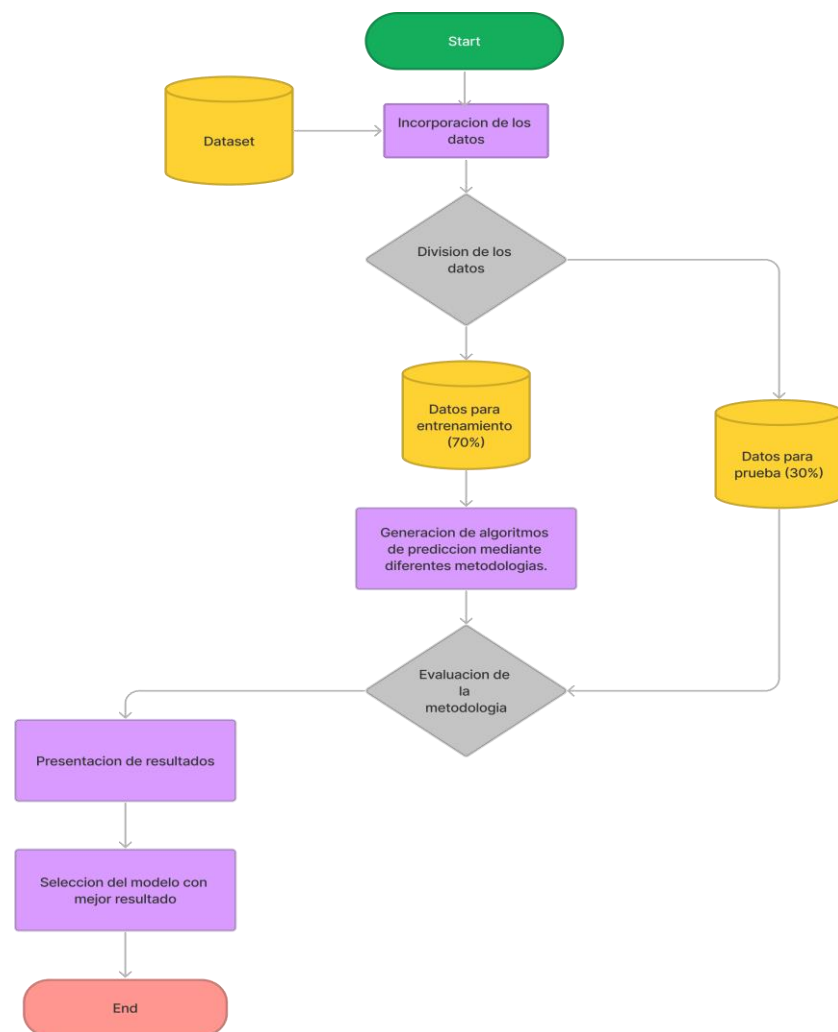
10. VALIDACIÓN DE LA PRECISIÓN DE LA SOLUCIÓN

Sin duda alguna el campo del aprendizaje automático cuenta con incontables aplicaciones, tan distintas entre sí como los datos analizados, por ende, la implementación de los modelos no siempre puede darse de forma predeterminada, es necesario validar los resultados esperados entre modelos y con el proceso en sí. Dicha validación permite; escoger la mejor opción, reforzar el uso de estas tecnologías con un enfoque responsable (Panesar, 2021), de allí la connotación de este análisis como la Fase IV y uno de los objetivos del proyecto

Para el desarrollo de la solución se utilizaron cuatro (4) métricas de precisión que permitieron escoger no solo el mejor algoritmo, sino establecer la certeza de la respuesta del modelo predictivo.

La implementación de validación de la precisión va de la mano de un proceso ordenado y secuencial. Que ofrece al final la validación del método con mejor resultado predictivo.

Figura 31. Proceso de validación de la solución.



Fuente. Los autores, 2023. Adaptado de Microsoft. (2022a).

Dicho proceso puede ser desarrollado de forma automática, evaluando el modelo predictivo según las siguientes métricas, y el resultado del proceso se observa en la figura 32;

- ✓ Error promedio al cuadrado (R^2).
- ✓ Error absoluto promedio.
- ✓ Raíz cuadrada del error promedio.
- ✓ Error cuadrado promedio.

Figura 32. Resultado de análisis de validación de métricas (Desarrollo de consola).

```
===== Create and Train the Model =====
===== End of training =====

*****
*           Model quality metrics evaluation
* -----
*      RSquared Score:           0,92
*      Mean Absolute Error:      3,18
*      Root Mean Squared Error:  3,89
*      Mean Squared Error:       15,14
*****
===== End of process, hit any key to finish =====
```

Fuente. Los autores, 2023.

Siendo así, se analizan las métricas utilizadas para la validación de la solución, haciendo hincapié en la finalmente implementada.

10.1. Error promedio al cuadrado (R^2).

Con uso principalmente en el sector financiero, tiene la particularidad que determina la rata de cambio de la variable dependiente en función de la independiente, siendo estimado entre (0 – 1) donde la unidad es el punto donde el modelo entrega mayor exactitud. (Fernando, 2021).

Su fórmula está estrechamente ligada al error de la predicción del modelo, aquellos valores que dentro de los datos de prueba no se pueden calcular al realizar el proceso de regresión (Allison, 2013). Siendo la formula general descrita en la ecuación 1;

Ecuación 1. Cálculo de error promedio al cuadrado.

$$R^2 = 1 - \left(\frac{f_1}{f_2} \right)$$

Fuente. Los autores, 2022. Adaptado de. Fernando, J. (2021, September 12).

Donde;

$f_1 \rightarrow$ Tasa de cambio de los valores de prueba que no coinciden con la regresión del modelo.

$f_2 \rightarrow$ Tasa de cambio de los valores de prueba que coinciden con la regresión del modelo.

A medida que los valores de prueba excluidos de la regresión disminuyen. El valor de R^2 se hace cercano a uno (1) y por lo tanto el modelo de predicción aumenta su certeza (Gelman et al., 2019).

10.2. Error absoluto promedio (MAE)

Como su nombre lo indica, este tipo de métrica computa el promedio de la sumatoria de errores absolutos, sobre la cantidad de errores registrado. Su uso es muy común en la evaluación de modelos estadísticos. (Chai & Draxler, 2014).

Ecuación 2. Cálculo del error absoluto promedio.

$$MAE = \left(\frac{\sum_{i=1}^n |e_i|}{n} \right)$$

Fuente. Los autores, 2022. Adaptado de Chai, T., & Draxler, R. R. (2014).

Donde;

$e \rightarrow$ Valor del error calculado

$n \rightarrow$ Cantidad de errores computados

Los valores obtenidos dentro del MAE varían entre cero (0) e infinito (∞), siendo la cercanía al primero la prueba de la veracidad del modelo predictivo.

10.3. Raíz cuadrada del error promedio (RMSE)

Parte principalmente del MAE y su uso es dado proporciona mejor exactitud dado que el análisis estadístico del RMSE proporcional el sector del modelo donde se acumulan la mayor cantidad de errores. Permitiendo su mejora. Su cálculo, consiste en la raíz cuadrada de la sumatoria del error al cuadrado dividida en la cantidad de muestras analizadas. (Chai & Draxler, 2014a)

Ecuación 3. Raíz cuadrada del error promedio.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n e_i^2}{n}}$$

Fuente. Los autores, 2022. Adaptado de Chai, T., & Draxler, R. R. (2014).

Donde;

e → Valor del error calculado

n → Cantidad de errores computados

10.4. Error cuadrado promedio (MSE)

Se constituye como la medición de la diferencia cuadrática promedio entre los valores estimados y el valor real. Siendo los valores estimados, producto de la ecuación de regresión de los valores de entrenamiento.(Das et al., 2004) Tal como se describe en la ecuación 4.

Ecuación 4. Error cuadrado promedio

$$MSE = \frac{\sum_{i=1}^n e^2}{n}$$

Fuente. Los autores, 2022. Adaptado de Das, K., Jiang, J., & Rao, J. N. K. (2004).

Donde;

e → Valor del error calculado

n → Cantidad de errores computados

11. DEMOSTRACION DE LA SOLUCION

Con el desarrollo de la herramienta y se describe un ejemplo. Enfatizando cada una de las fases hasta la predicción de la falla. Los otros apartados de la herramienta se encuentran descritos en el manual del usuario.

En el apartado de “predicción de valor” se despliega la ventana donde se introducen los principales datos operacionales, siendo el siguiente paso su procesamiento y finalizando con su consumo para la herramienta de predicción. Tal como muestra la figura 33.

Figura 33. Predicción de evento de fugas en EQUIPO_PRUEBA

The screenshot shows the PREDICONFORT software interface. The sidebar on the left contains navigation options: 'Inspección' (with sub-options 'Agregar datos de inspección' and 'Vizualizar datos'), 'Modelo de Predicción' (with 'Información del modelo' and 'Predicción de Valor'), and 'Datos' (with 'Validación de Datos'). The main window is titled 'Predicción' and is divided into several sections:

- Valores de entrada:** A form with input fields for 'Fecha' (25/04/2023), 'Equipo' (EQUIPO_PRUEBA), 'Refrigerante' (R407C), 'Temp Exterior (°C)' (30), 'Temp Interior (°C)' (20), 'Presión Alta01' (380), 'Presión Baja 01' (85), 'Presión Alta02' (386), 'Presión Baja02' (85), 'A1' (12), 'A2' (12), 'A3' (12), 'Tensión' (463), and 'Capacidad' (15).
- Datos Procesados:** A table showing processed data attributes and their values.
- Procesar:** A button with a gear icon to process the input data.
- Consumir:** A button with a document icon to consume the processed data.
- Summary Results:** A series of colored boxes displaying the final prediction results.

Atributo	Valor
Refrigerante	R407C
Temp_E	30
Temp_I	20
PAIta01	380
PBIja01	85
PAIta02	386
PBIja02	85
A1_Amp	12
A2_Amp	12
A3_Amp	12
Tensión	463
Cap	15

Summary Results:

- Semana de alerta:** 17
- Score:** 98.83%
- Algoritmo:** Fast Forest Regression
- Trees:** 115
- Leaves:** 4
- Feature Fraction:** 1

Fuente. Los autores, 2023.

El resultado obtenido es un suceso de falla en la próxima semana 17 del año. La cual puede ser en el año en curso o en el siguiente. Dependiendo de la fecha en la cual se realiza el ejercicio de predicción.

12. OPORTUNIDADES DE MEJORA EN LA IMPLEMENTACION DE LA SOLUCION

Descrito en la figura 11, el proceso de desarrollo de la solución atraviesa por múltiples etapas. Cada una de estas con sus debidas características y propósito. Por ende, se plantean oportunidades de mejora que abordan dos (2) de las fases sobre las cuales se estableció la herramienta; la adquisición de la información operacional en sitio y la predicción de la falla (Bartodziej, 2017).

12.1. Adquisición de la información mediante tecnologías IoT


Sin duda alguna, la toma de la información de forma manual infiere un gran riesgo y tiempo descrito en la Sección 9.2, y no existe un argumento que refute la implementación de nuevas tecnologías como; sensores conectados a la nube, transmitiendo en tiempo real datos operacionales de campo, logrando con esto; asegurar la transparencia de la información, disminuir el tiempo entre la adquisición y el almacenamiento (Vijayaraghavan & Rian Leevinson, 2019).

La implementación de tecnologías IoT (Internet de las cosas por su traducción en inglés) de adquisición y monitoreo de parámetros operacionales de motores eléctricos, potenciadas mediante IA están siendo usadas abiertamente en la industria por SIEMENS mediante su nube llamada MindSphere (SIEMENS, 2023) y WEG mediante WEG IOT Platform (WEG, 2023). Siendo estas, casos de éxito de combinar estas tecnologías.

12.2. Acceso remoto a la herramienta de predicción

La posibilidad de acceso a la herramienta desde cualquier lugar y en cualquier momento mediante una conexión internet, permite un mejor monitoreo por parte de los interesados en el proceso productivo. Elimina el riesgo de perder información al estar almacenada en hardware local. Las aplicaciones online, presentan robustez y fiabilidad con las ventajas de un acceso completamente remoto (L'Esteve, 2021).

Figura 34. Desarrollo de la solución bajo un entorno cloud.



Fuente. Los autores, 2023.

13. ANÁLISIS Y DISCUSIÓN DE RESULTADOS

- ✓ El aumento de la producción tecnológica e investigativa a partir del 2016 tanto en la implementación de machine learning en procesos de mantenimiento predictivo de sistemas HVAC&R, como en el uso de metodologías ágiles (scrum) e historias de usuario como herramientas de forma de construcción de proyectos, refleja la y correlación de la incorporación de un proceso productivo en la generación de software de uso industrial y la cada vez mayor implementación de estas tecnologías en la industria.
- ✓ La incorporación de la producción científica encontrada a través del análisis del estado del arte, permitió clasificar las historias de usuario de acuerdo a sus atributos de calidad, y su posterior validación bajo el mismo marco observando su cumplimiento y desviaciones.

Siendo así, los atributos mencionados fueron; fiabilidad, facilidad de uso, corrección y posibilidad de ser evaluado.

La estipulación diferentes métricas de evaluación del algoritmo entrega una solución robusta y fiable. Pues puede verificarse numéricamente el comportamiento tanto del algoritmo como la calidad de la información.

Por otro lado, la incorporación de la información de predicción del evento consiste en alimentar solo una ventana (ver figura 33), permitiendo con esto un proceso limpio y de fácil uso.

Dado que se presentan tanto ventanas de acceso a la data (figura 27) como gráficos de dispersión (figura 30), que permiten identificar las desviaciones o campos vacíos para su posterior corrección, se satisface con esto el atributo identificado.

Por último, al analizarlos de forma independiente el flujo de trabajo de la herramienta permite identificar la semana de predicción de la falla y el equipo en cuestión. Facilitando las labores no solo administrativas, sino también de retroalimentación y evaluación.

- ✓ Buscando un tratamiento limpio de las condiciones planteadas en las historias de usuario, se establecieron criterios de validación individuales (ver tablas 10 - 14), sobre las cuales se presenta un análisis en la tabla 25.

Tabla 25. Validación de los criterios de las historias de usuario

HISTORIA DE USUARIO	CRITERIO DE VALIDACION	CUMPLIMIENTO
Como usuario quiero disponer de una herramienta informática que disminuya las labores de mantenimiento no programados	¿La implementación de la herramienta facilita la gestión de mantenimiento preventivo y correctivo?	A través de la predicción de la falla se pueden adelantar actividades de mantenimiento preventivo y administrativas referentes al mantenimiento correctivo.

MAESTRIA EN INGENIERIA
DOCUMENTO FINAL DE TRABAJO DE GRADO

Como usuario quiero usar la información operacional para predecir fugas de gas refrigerante en sistemas HVAC&R.	¿La herramienta predice fugas, día o semana aproximada del evento?	Se valida de forma afirmativa, al evidenciarse los resultados de la predicción.
Como usuario quiero saber que tan fiable es la predicción realizada por la aplicación informática.	¿La predicción realizada, cumple un marco de evaluación transparente?	El uso de diferentes métricas de evaluación permite observar el comportamiento desde varios puntos de vista, identificando debilidades y fortalezas.
Como usuario quiero ver, revisar y mejorar la información recopilada	¿La información de consumo del algoritmo es accesible?	Dado que permite la evaluación de la información y los datasets para su mejora. Es posible dar cumplimiento.
Como usuario quiero identificar desviaciones en la información utilizada	¿Puedo identificar desviaciones en la información fácilmente?	Presentar información por gráficos de dispersión permite la identificación fácil de desviaciones en los datos.

Fuente. Los autores, 2023.

- ✓ El modelo administrativo de proyectos Scrum, permite que los procesos sean implementados con un uso óptimo de tiempo, el desarrollo de los sprints debe ser centrada en el cliente y sus necesidades. Y la evaluación de su cumplimiento es fácilmente realizable al evaluar los criterios de validación expuestos inicialmente en la tabla 26.

Tabla 26. Validación de los criterios de los Sprints

SPRINT	CRITERIO DE VALIDACION	CUMPLIMIENTO
Planteamiento del problema y descripción de la solución planteada	¿La solución planteada atiende las necesidades del cliente?	Dada la situación planteada en el capítulo 3 de la investigación, es viable la justificación de la solución ante la situación planteada. Debido a que presenta una alternativa ante la cual se establece como la mayor falla de los sistemas de aire acondicionado industrial.

MAESTRIA EN INGENIERIA
DOCUMENTO FINAL DE TRABAJO DE GRADO

Recopilación de la información	¿Se establece una perspectiva de la investigación dentro de la comunidad académica y un soporte bibliográfico fiable?	Durante la investigación se dividieron los temas en fondo (técnico) y forma (desarrollo del proyecto) tal que ambos tengan igual prioridad.
Revisión y selección de los parámetros operacionales.	¿La información entregada está optimizada y obedece a las necesidades del algoritmo?	De acuerdo con los resultados obtenidos durante la predicción, se evidencia que la información suministrada fue la adecuada, sin embargo, no limita las oportunidades de mejora respecto a lo que se define como uno de los pilares de la industria 4.0, los datos.
Análisis y selección del método utilizado para el análisis de datos	¿Se tiene una base de datos adecuada para el consumo por el algoritmo? ¿Las herramientas seleccionadas cumplen con los requerimientos a un bajo costo?	Dada la población y características de activos descritos en el capítulo 2. Es viable validar que se cuentan con la información suficiente para la construcción de una base de datos sólida, como primer paso en la construcción de la solución tecnológica. La cual fue desarrollada bajo un marco de optimización de costos y recursos.
Diseño del algoritmo de procesamiento de la información y flujo de trabajo de la aplicación	¿Se implementan las historias de usuario dentro de la solución?	De acuerdo con lo retroalimentado en la tabla 25, se establecen soluciones de los requerimientos del cliente.
Desarrollo de la aplicación de escritorio	¿El resultado es un producto mínimo viable? ¿Esta optimizada la solución?	Tanto la validación a través de un registro de patente como la validación con información real, tomada en sitio, entrega razones de peso para contar con el potencial de uso de la herramienta.

MAESTRIA EN INGENIERIA
DOCUMENTO FINAL DE TRABAJO DE GRADO

Realización de pruebas, retroalimentación y corrección	¿La solución cumple con los criterios de calidad planteados? ¿El análisis numérico de la solución cumple con los estándares?	Las métricas de validación presentadas en el capítulo 10 nos entregan a través de cuatro (4) medios independientes una radiografía del trabajo del algoritmo.
Desarrollo de la documentación	¿La documentación proporciona información de desarrollo y uso de la solución?	Tanto el manual de usuario encontrado en la sección de anexos como este documento en si, presenta la información completa de concepción, construcción validación y uso de la herramienta tecnológica.

Fuente. Los autores, 2023.

- ✓ Según lo descrito en la Sección 5.2. se permite determinar que el modelo predictivo realizado obedece a un proceso de aprendizaje supervisado, pues se conocen plenamente los valores de entrada y salida utilizados para su construcción.

De igual manera, la estructura no posee un comportamiento lineal claro, pues factores tanto externos (temperatura ambiental) (ANSI/ASHRAE 55 - 2020. Thermal Environmental Conditions for Human Occupancy, 2020), como internos (suciedad de los intercambiadores) pueden afectar seriamente las condiciones operacionales del equipo (Stanfield & Skaves, 2013), por ende, su linealidad.

- ✓ La implementación de cuatro (4) métricas de evaluación, nos permite obtener una visión más amplia del funcionamiento del algoritmo de predicción, es decir.

Mientras el *error promedio al cuadrado* (R^2) y el *error absoluto promedio* (MAE) nos entregan valores cercanos a uno (1) y cero (0) respectivamente, mostrando con ello la validez del modelo predictivo (Chai & Draxler, 2014).

El cálculo de la *raíz cuadrada del error promedio* (RMSE) y el *error cuadrado promedio* (MSE) tiene como resultados valores alejados del punto óptimo de la unidad (1) (Das et al., 2004), lo cual significa que el proceso desde la adquisición y preprocesamiento de los datos hasta la predicción de los eventos tiene lugar a la mejora.

Siendo este objetivo de la investigación el pilar hacia el fortalecimiento de futuros proyectos que giren en torno a la optimización del proceso desarrollado.

Como se indicó en la Sección 9.2, un equipo de aire acondicionado en avanzado estado de suciedad puede generar lecturas erróneas o falsas alarmas, constituyendo la principal causa en la incorporación de información equivocada en el modelo, por ende, se plantean métodos de mejora de la información que ingresa al algoritmo:

- ✓ El filtrado de dichos parámetros antes de su análisis y la administración de la herramienta por parte de un Ingeniero HVAC&R que este interprete los valores antes de ser ingresados.
- ✓ La inclusión de una nueva variable en la herramienta predictiva, la cual va directamente relacionada con el nivel de limpieza del sistema de intercambio de calor.

14. OBSERVACIONES Y RECOMENDACIONES

- ✓ La incorporación de la información en la aplicación puede convertirse en un proceso metódico y rutinario, por ende, automatizable. Sin duda un nuevo escalón en el fortalecimiento de la solución.
- ✓ La API ML.NET Modelo Builder posee una interfaz intuitiva y cómoda, sin embargo, presenta grandes limitaciones en su proceso de creación de herramientas de tipo industrial y/o comercial. Debido principalmente a que los diferentes escenarios que posee son en su mayoría de uso local, dificultando el despliegue de una aplicación basada en servicios cloud.

15. CONCLUSIONES

- ✓ La incorporación de metodologías de Machine learning en prácticas fundamentales de la industria como el mantenimiento es un paso obligatorio en el desarrollo de la industria, sin embargo, el gran cuello de botella como en muchos campos donde se usan estas tecnologías es la adquisición de los datos y el acceso remoto a dichas herramientas. Es allí donde tecnologías como el IIOT (Internet industrial de las cosas) y servicios cloud, se ofrecen como grandes candidatos a solucionar dicha problemática. Siendo sin duda un fortalecimiento en la implementación real de una aplicación con similares características, en concordancia a lo estipulado en el capítulo 12.
- ✓ La incorporación de tecnologías propias de la industria 4.0 en los sistemas HVAC&R no es algo nuevo, fabricantes como DAIKIN (Intelligent Equipment™), BELIMO (Digital Ecosystem™), DANFOSS (Alsense™), EMERSON (Plantweb™ Digital Ecosystem) ya están gestionando sus plataformas de tecnologías IIOT en la adquisición de información (Sandoval, 2022). Estableciendo el puente por el cual los datos llegan rápidamente a la construcción de las herramientas para situaciones específicas.
- ✓ La poca información encontrada acerca de la implementación de aplicaciones de machine learning en el mantenimiento predictivo de sistemas de aire acondicionado y refrigeración industrial es un claro ejemplo que queda mucho camino por recorrer; investigaciones, modelamientos digitales, revisiones y actualizaciones. Sin duda, hoy se da un nuevo paso en la incorporación de las nuevas tecnologías en la industria con un mejoramiento de la calidad de vida directamente relacionada.
- ✓ Adicionar parámetros operacionales como el Sobrecalentamiento y el Subenfriamiento, e incluir otros tipos de falla como daños mecánicos en compresores y motores, constituyen un gran avance en próximas entregas. Garantizando un mayor alcance dentro del abanico de problemáticas relacionadas con la mantenibilidad dentro de los sistemas de aire acondicionado industrial. Y la transformación del modelo desarrollado hacia uno de aprendizaje reforzado.
- ✓ La incorporación de datos operacionales entregados por los fabricantes permite general procesos predictivos más personalizados, por ejemplo, las curvas operativas de los compresores posibilitan evidenciar cuando el compresor decae en su operación por agentes externos como fugas de gas refrigerante o por desgaste por horas de uso. Se comprende como un trabajo de gran envergadura principalmente por la variedad de componentes del mercado nacional e internacional.
- ✓ Establecer unas historias de usuario claras, que permitan determinar condiciones mínimas de operación de la herramienta de predicción, permite la posterior evaluación de esta, evidenciando y corrigiendo desviaciones en el proceso productivo. Siendo la validación de sus atributos de calidad, seleccionada como prueba de su cumplimiento y análisis imparcial.
- ✓ Es posible identificar que cada una de las historias de usuario diseñadas en el inicio del proyecto fueron interpretadas y desarrolladas dentro de la solución, mediante la validación de su respectivo criterio de calidad. Facilitando su uso por personas sin conocimiento específico en machine learning y dando cumplimiento con los objetivos planteados.

MAESTRIA EN INGENIERIA
DOCUMENTO FINAL DE TRABAJO DE GRADO

- ✓ Una comparativa estadística, cualitativa y cuantitativa del uso de cada una de las métricas, puede otorgar un nuevo paso en el fortalecimiento de modelos de mantenimiento predictivos para sistemas de aire acondicionado.
- ✓ A través del proceso de investigación, innovación y desarrollo fue posible lograr los objetivos trazados como lineamientos fundamentales. Tales metas, permiten obtener una solución funcional, con mucho que ofrecer y camino por recorrer.

REFERENCIAS

- Aamir, M., & Khan, M. N. A. (2017). Incorporating quality control activities in scrum in relation to the concept of test backlog. *Sadhana - Academy Proceedings in Engineering Sciences*, 42(7), 1051–1061. <https://doi.org/10.1007/s12046-017-0688-7>
- Alfonso Diaz, A. L., Barrera Gomez, M. R., & Quiroga Niño, J. A. (2022). *PREDICONFORT 1.0* (No. 1). Universidad Santo Tomas.
- Allison, P. (2013). What's the best R-squared for logistic regression. *Statistical Horizons*, 13. <https://statisticalhorizons.com/r2logistic/>
- Al-Tal, M., Al-Aomar, R., & Abel, J. (2021). A predictive model for an effective maintenance of hospital critical systems. *Proceedings of the 33rd European Modeling & Simulation Symposium*, 1–8. <https://doi.org/10.46354/i3m.2021.emss.001>
- American Society of Heating, R. and A.-C. E. (2021). *ASHRAE Handbook: Vol. Fundamentals*.
- ANSI/ASHRAE 55 - 2020. Thermal Environmental Conditions for Human Occupancy, ASHRAE (2020).
- Bartodziej, C. J. (2017). *The Concept Industry 4.0. An Empirical Analysis of Technologies and Applications in Production Logistics*. Springer Gabler.
- Boero, C. (2020). *Mantenimiento industrial*. Jorge Sarmiento Editor - Universitas. <https://elibro.net/es/lc/usta/titulos/172523>
- Bouabdallaoui, Y., Lafhaj, Z., Yim, P., Ducoulombier, L., & Bennadji, B. (2021). Predictive Maintenance in Building Facilities: A Machine Learning-Based Approach. *Sensors*, 21(4), 1044. <https://doi.org/10.3390/s21041044>
- Braun, J., Claridge, D. E., Katipaluma, S., Liu, M., & Pratt, R. G. (2001). Operation and Maintenance. In J. F. Kreider (Ed.), *Handbook of heating, Ventilation, and Air Conditioning*. CRC Press LLC.
- Candanedo, I. S., Nieves, E. H., González, S. R., Martín, M. T. S., & Briones, A. G. (2018). Machine Learning Predictive Model for Industry 4.0. In L. Uden, B. Hadzima, & I.-H. Ting (Eds.), *Knowledge Management in Organizations* (pp. 501–510). Springer International Publishing.
- Cerquitelli, T., Nikolakis, N., O'Mahony, N., Macii, E., Ippolito, M., & Makris, S. (Eds.). (2021). *Predictive Maintenance in Smart Factories*. Springer Singapore. <https://doi.org/10.1007/978-981-16-2940-2>
- Chai, T., & Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE). *Geoscientific Model Development Discussions*, 7(1), 1525–1534.
- Danfoss A/S. (2017). Datasheet. Pressure Switch and Thermostat. In *AI000086439001en-001001* (pp. 1–20).
- Das, K., Jiang, J., & Rao, J. N. K. (2004). Mean squared error of empirical predictor. *The Annals of Statistics*, 32(2), 818–840.
- del Val Román, J. L. (2016). Industria 4.0: la transformación digital de la industria. *Valencia: Conferencia de Directores y Decanos de Ingeniería Informática, Informes CODDII*.
- Diercks, P., Gläser, D., Lünsdorf, O., Selzer, M., Flemisch, B., & Unger, J. F. (2022). *Evaluation of tools for describing, reproducing and reusing scientific workflows*.

MAESTRIA EN INGENIERIA
DOCUMENTO FINAL DE TRABAJO DE GRADO

- Ebert, C., Abrahamsson, P., & Oza, N. (2012). Lean software development. *IEEE Software*, 29(05), 22–25.
- Echavarria Ortiz, H. N. (2022). *Aplicación de machine learning para la enseñanza – aprendizaje de competencias ciudadanas en educación media del Colegio de Boyacá*. <https://repository.usta.edu.co/handle/11634/47603#.Y4pGaRabz-o.mendeley>
- ECOPETROL S.A. (2018). *Especificaciones tecnicas para el servicio de mantenimiento de sistemas de aire acondicionado de la Gerencia Refineria de Barrancabermeja de ECOPETROL S.A.*
- Elallaoui, M., Nafil, K., & Touahni, R. (2018). Automatic Transformation of User Stories into UML Use Case Diagrams using NLP Techniques. *Procedia Computer Science*, 130, 42–49. <https://doi.org/10.1016/j.procs.2018.04.010>
- Es-sakali, N., Cherkaoui, M., Mghazli, M. O., & Naimi, Z. (2022). Review of predictive maintenance algorithms applied to HVAC systems. *Energy Reports*, 8, 1003–1012. <https://doi.org/10.1016/j.egyr.2022.07.130>
- Esteki, M., Javdani Gandomani, T., & Khosravi Farsani, H. (2020). A risk management framework for distributed scrum using PRINCE2 methodology. *Bulletin of Electrical Engineering and Informatics*, 9(3), 1299–1310. <https://doi.org/10.11591/eei.v9i3.1905>
- Fernando, J. (2021, September 12). *R-Squared Formula, Regression, and Interpretations*. Investopedia.Com/ Corporate Finance / Financial Analysis. [https://www.investopedia.com/terms/r/r-squared.asp#:~:text=R%2Dsquared%20values%20range%20from,\)%20you%20are%20interested%20in](https://www.investopedia.com/terms/r/r-squared.asp#:~:text=R%2Dsquared%20values%20range%20from,)%20you%20are%20interested%20in).
- Gelman, A., Goodrich, B., Gabry, J., & Vehtari, A. (2019). R-squared for Bayesian Regression Models. *The American Statistician*, 73(3), 307–309. <https://doi.org/10.1080/00031305.2018.1549100>
- Gonzalez Ajuech, V. L. (2017). *Mantenimiento: tecnicas y aplicaciones industriales*. Grupo Editorial Patria. <https://elibro.net/es/lc/usta/titulos/40508>
- Heras del Dedo, R. de las, & Alvarez Garcia, A. (2017). *Metodos agiles: Scrum, Kanban, Lean*. Difusora Larousse - Anaya Multimedia. <https://elibro.net/es/lc/usta/titulos/122933>
- Hosamo, H. H., Svennevig, P. R., Svidt, K., Han, D., & Nielsen, H. K. (2022). A Digital Twin predictive maintenance framework of air handling units based on automatic fault detection and diagnostics. *Energy and Buildings*, 261, 111988. <https://doi.org/10.1016/j.enbuild.2022.111988>
- Instituto de Hidrología, M. y E. A.-I. (2023). *Altas Climatologico*. <Http://Atlas.Ideam.Gov.Co/VisorAtlasClimatologico.Html>.
- Jimenez Raya, F. (2015). *Mantenimiento preventivo de sistemas de automatizacion industrial*. ELEM0311. IC Editorial. <https://elibro.net/es/lc/usta/titulos/59239>
- Joshi, A. V. (2020). *Machine Learning and Artificial Intelligence*. Springer International Publishing. <https://doi.org/10.1007/978-3-030-26622-6>
- Ke, Y., Mulumba, T., Shen, W., & Afshari, A. (2014, May 18). Model-based predictive maintenance of chillers. *ACRA 2014 - Proceedings of the 7th Asian Conference on Refrigeration and Air Conditioning*.
- Kubat, M. (2017). *An Introduction to Machine Learning*. Springer International Publishing. <https://doi.org/10.1007/978-3-319-63913-0>

MAESTRIA EN INGENIERIA
DOCUMENTO FINAL DE TRABAJO DE GRADO

- L'Esteve, R. C. (2021). *The Definitive Guide to Azure Data Engineering*. Apress.
<https://doi.org/10.1007/978-1-4842-7182-7>
- Martínez, R., Parkinson, C., Caruso, M., López, D., Vargas, R., & Rojas, N. (2022). Propuesta de técnicas de validación para la calidad de datos abiertos e identificación de patrones para predicciones con Machine Learning. *XXIV Workshop de Investigadores En Ciencias de La Computación (WICC 2022, Mendoza)*.
- Microsoft. (2022a). *Documentación de ML.NET*. <https://learn.microsoft.com/es-es/dotnet/machine-learning/>
- Microsoft. (2022b). *Documentación de Visual Studio*. <https://learn.microsoft.com/es-es/visualstudio/>
- Microsoft. (2022c, December 5). *Documentacion SQL Server Management Studio (SSMS)*. <https://learn.microsoft.com/es-es/sql/ssms/sql-server-management-studio-ssms>
- Monroy Mejia, M. de los A., & Nava Sanchezllanes, N. (2018). *Metodologia de la investigacion*. Grupo Editorial Exodo. <https://elibro.net/es/lc/usta/titulos/172512>
- Oficina Asesora de Planeacion y Estudios Sectoriales. (2019). *Aspectos Basicos de la Industria 4.0*. Ministerio de Tecnologias de la Informacion y las Comunicaciones. Republica de Colombia.
- O'hEocha, C., & Conboy, K. (2010). *The Role of the User Story Agile Practice in Innovation* (pp. 20–30). https://doi.org/10.1007/978-3-642-16416-3_3
- Ohta, R. (2018). SELECTION OF INDUSTRIAL MAINTENANCE STRATEGY: CLASSICAL AHP AND FUZZY AHP APPLICATIONS. *International Journal of the Analytic Hierarchy Process*, 10(2). <https://doi.org/10.13033/ijahp.v10i2.551>
- Panesar, A. (2021). Evaluating Machine Learning Models. In *Machine Learning and AI for Healthcare* (pp. 189–205). Apress. https://doi.org/10.1007/978-1-4842-6537-6_7
- Panfilov, P., & Katona, A. (2018). *Building Predictive Maintenance Framework for Smart Environment Application Systems* (pp. 0460–0470). <https://doi.org/10.2507/29th.daaam.proceedings.068>
- Periyasamy, K., & Chianelli, J. (2021). A project tracking tool for scrum projects with machine learning support for cost estimation. *EPiC Series in Computing*, 76, 86–94. <https://doi.org/10.29007/6vwh>
- Rodal Montero, E. (2020). *Industria 4.0: conceptos, tecnologias habilitadoras y retos*. Difusora Larousse - Ediciones Piramide. <https://elibro.net/es/lc/usta/titulos/216140>
- Salvaris, M., Dean, D., & Tok, W. H. (2018). *Deep Learning with Azure*. Apress. <https://doi.org/10.1007/978-1-4842-3679-6>
- Sandoval, R. (2022, September 22). IoT: La conexión con la industria del mañana. *Mundo HVAC&R*.
- Santiago, A. R., Antunes, M., Barraca, J. P., Gomes, D., & Aguiar, R. L. (2019). Predictive Maintenance System for Efficiency Improvement of Heating Equipment. *2019 IEEE Fifth International Conference on Big Data Computing Service and Applications (BigDataService)*, 93–98. <https://doi.org/10.1109/BigDataService.2019.00019>
- Santos Sanchez, G. A., & Castro Barrera, M. A. (2022). *Metodologia de valoracion de riesgo de equipo electrico: evaluacion basada en el conocimiento experto*. <https://cimga.com/>
- Sanzana, M. R., Maul, T., Wong, J. Y., Abdulrazic, M. O. M., & Yip, C.-C. (2022). Application of deep learning in facility management and maintenance for heating,

- ventilation, and air conditioning. *Automation in Construction*, 141, 104445. <https://doi.org/10.1016/J.AUTCON.2022.104445>
- Saturno, M., Pertel, V., & Deschamps, F. (2017). *Proposal of an automation solutions architecture for Industry 4.0*.
- Sedeño, J., Schön, E.-M., Torrecilla-Salinas, C., Thomaschewski, J., Escalona, M. J., & Mejias, M. (2017). Modelling agile requirements using context-based persona stories. *WEBIST 2017 - Proceedings of the 13th International Conference on Web Information Systems and Technologies*, 196–203. <https://doi.org/10.5220/0006220301960203>
- SIEMENS. (2023). *SIEMENS MindSphere*. <https://new.siemens.com/co/es/productos/software/mindsphere.html>
- Srinivasan, R., Tamzeed Islam, M., Islam, B., Wang, Z., Sookoor, T., Gnawali, O., & Nirjon, S. (2017, August 7). *Preventive Maintenance of Centralized HVAC Systems: Use of Acoustic Sensors, Feature Extraction, and Unsupervised Learning*. <https://doi.org/10.26868/25222708.2017.715>
- Stanfield, C., & Skaves, D. (2013). *Fundamentals of HVACR* (A. Vernon R, Ed.; 2nd ed.). PEARSON.
- Subih, M. A., Malik, B. H., Mazhar, I., Sabir, U., Wakeel, T., Wajid, A., Yousaf, A., Nawaz, H., & Suleman, M. (2019). Comparison of agile method and scrum method with software quality affecting factors. *International Journal of Advanced Computer Science and Applications*, 10(5).
- Sukhodolov, Y. A. (2019). The Notion, Essence, and Peculiarities of Industry 4.0 as a Sphere of Industry. In E. G. Popkova, Y. V Ragulina, & A. V Bogoviz (Eds.), *Industry 4.0: Industrial Revolution of the 21st Century* (pp. 3–10). Springer International Publishing. https://doi.org/10.1007/978-3-319-94310-7_1
- Taibi, D., Lenarduzzi, V., Janes, A., Liukkunen, K., & Ahmad, M. O. (2017). *Comparing Requirements Decomposition Within the Scrum, Scrum with Kanban, XP, and Banana Development Processes* (pp. 68–83). https://doi.org/10.1007/978-3-319-57633-6_5
- Trivedi, S., Bhola, S., Talegaonkar, A., Gaur, P., & Sharma, S. (2019). Predictive Maintenance of Air Conditioning Systems Using Supervised Machine Learning. *2019 20th International Conference on Intelligent System Application to Power Systems (ISAP)*, 1–6. <https://doi.org/10.1109/ISAP48318.2019.9065995>
- Urbietta, M., Antonelli, L., Rossi, G., & do Prado Leite, J. C. S. (2020). The impact of using a domain language for an agile requirement management. *Information and Software Technology*, 127. <https://doi.org/10.1016/j.infsof.2020.106375>
- Vijayaraghavan, V., & Rian Leevinson, J. (2019). *Internet of Things Applications and Use Cases in the Era of Industry 4.0* (pp. 279–298). https://doi.org/10.1007/978-3-030-24892-5_12
- Wautelet, Y., Gielis, D., Poelmans, S., & Heng, S. (2019). Evaluating the impact of user stories quality on the ability to understand and structure requirements. In *Lecture Notes in Business Information Processing* (Vol. 369). https://doi.org/10.1007/978-3-030-35151-9_1
- WEG. (2023). *WEG IOT Platform*. <https://iot.weg.net/#/portal/home>
- Yang, C., Chen, Q., Shen, W., & Gunay, B. (2017). Toward failure mode and effect analysis for heating, ventilation and air-conditioning. *2017 IEEE 21st International Conference on Computer Supported Cooperative Work in Design (CSCWD)*, 408–413. <https://doi.org/10.1109/CSCWD.2017.8066729>

- Yang, C., Gunay, B., Shi, Z., & Shen, W. (2021). Machine Learning-Based Prognostics for Central Heating and Cooling Plant Equipment Health Monitoring. *IEEE Transactions on Automation Science and Engineering*, 18(1), 346–355. <https://doi.org/10.1109/TASE.2020.2998586>
- Yang, C., Shen, W., Chen, Q., & Gunay, B. (2018). A practical solution for HVAC prognostics: Failure mode and effects analysis in building maintenance. *Journal of Building Engineering*, 15, 26–32. <https://doi.org/10.1016/j.jobbe.2017.10.013>
- Yang, C., Shen, W., Gunay, B., & Shi, Z. (2019). Toward machine learning-based prognostics for heating ventilation and air-conditioning systems. *ASHRAE Transactions Volume 125*, 106–115.
- YORK International. Jhonson Controls. (2004). Installation manual. Predator. Single package air conditioners and single package electric units DM090, 120 and 150. 7-1/2 TO 12 1/2 TO (380V, 3Phase, 60 HZ). In 035-17311-003-A-0704. Jhonson Controls.
- Yuliansyah, H., Qudsiah, S. N., Zahrotun, L., & Arfiani, I. (2018). Implementation of use case point as software effort estimation in Scrum Framework. *IOP Conference Series: Materials Science and Engineering*, 403(1). <https://doi.org/10.1088/1757-899X/403/1/012085>
- Zhang, J., Liu, C., & Gao, R. X. (2022). Physics-guided Gaussian process for HVAC system performance prognosis. *Mechanical Systems and Signal Processing*, 179, 109336. <https://doi.org/10.1016/j.ymssp.2022.109336>

::

MAESTRIA EN INGENIERIA
DOCUMENTO FINAL DE TRABAJO DE GRADO

ANEXOS

Anexo 1. Registro del software ante DNDA:

		MINISTERIO DEL INTERIOR DIRECCION NACIONAL DE DERECHO DE AUTOR UNIDAD ADMINISTRATIVA ESPECIAL OFICINA DE REGISTRO		Libro - Tomo - Partida 13-92-380
CERTIFICADO DE REGISTRO DE SOPORTE LOGICO - SOFTWARE				Fecha Registro 24-nov.-2022
Page 1 of 2				
1. DATOS DE LAS PERSONAS				
AUTOR				
Nombres y Apellidos	ANDRES LEONARDO ALFONSO DÍAZ		No de identificación CC	
Nacional de	COLOMBIA		Ciudad:	SOGAMOSO
Dirección				
AUTOR				
Nombres y Apellidos	MARLEN ROCIO BARRERA GÓMEZ		No de identificación CC	
Nacional de	COLOMBIA		Ciudad:	SOGAMOSO
Dirección				
AUTOR				
Nombres y Apellidos	JOSE ANDRES QUIROGA NIÑO		No de identificación CC	1098678410
Nacional de	COLOMBIA		Ciudad:	BARRANCABERMEJA
Dirección				
PRODUCTOR				
Razón Social	UNIVERSIDAD SANTO TOMÁS		Nit	8600123576
Dirección	KR 9 51 - 11		Ciudad:	BOGOTÁ D.C.
2. DATOS DE LA OBRA				
Título Original	PREDICONFORT 1.0			
Año de Creación	2022	País de Origen	COLOMBIA	Año Edición
CLASE DE OBRA	INEDITA			
CARACTER DE LA OBRA	OBRA ORIGINARIA			
CARACTER DE LA OBRA	OBRA EN COLABORACION			
ELEMENTOS APORTADOS DE SOPORTE LOGICO	PROGRAMA DE COMPUTADOR			
ELEMENTOS APORTADOS DE SOPORTE LOGICO	MATERIAL AUXILIAR			
3. DESCRIPCIÓN DE LA OBRA				
PREDICONFORT ES UN SOFTWARE PARA REPORTES DE FALLAS Y PREDICCIÓN DE ALERTAS EN COMPRESORES INDUSTRIALES. EL SISTEMA SE BASA EN UN HISTÓRICO DE DATOS OBTENIDO DE INSPECCIONES MANUALES DONDE SE REGISTRAN DATOS DE PRESIONES Y VALORES CARACTERÍSTICOS DE FUNCIONAMIENTO. ADICIONALMENTE, EL SISTEMA INTEGRA UN MODELO DE APRENDIZAJE MÁQUINA PARA ANÁLISIS DE DATOS Y PREDICCIÓN DE SUCESOS FUTUROS.				
4. OBSERVACIONES GENERALES DE LA OBRA				
5. DATOS DEL SOLICITANTE				
Nombres y Apellidos	JOSE ANDRES QUIROGA NIÑO		No de Identificación	1098678410
Nacional de	COLOMBIA		Medio Radicación	REGISTRO EN LINEA
Dirección			Ciudad	BARRANCABERMEJA
Correo electrónico	JOSEANDRESQUIROGA@GMAIL.COM		Teléfono	
En representación de	EN NOMBRE PROPIO		Radicación de entrada	1-2022-105921

MAESTRIA EN INGENIERIA
DOCUMENTO FINAL DE TRABAJO DE GRADO

	MINISTERIO DEL INTERIOR DIRECCION NACIONAL DE DERECHO DE AUTOR UNIDAD ADMINISTRATIVA ESPECIAL OFICINA DE REGISTRO <u>CERTIFICADO DE REGISTRO DE SOPORTE LOGICO - SOFTWARE</u>	Libro - Tomo - Partida 13-92-380 Fecha Registro 24-nov.-2022
Page 2 of 2  NATHALIE GRANADOS BERMEO JEFE OFICINA DE REGISTRO (E) MZP		

Nota: El derecho de autor protege exclusivamente la forma mediante la cual las ideas del autor son descritas, explicadas, ilustradas o incorporadas a las obras. No son objeto de protección las ideas contenidas en las obras literarias y artísticas, o el contenido ideológico o técnico de las obras científicas, ni su aprovechamiento industrial o comercial (artículo 7o. de la Decisión 351 de 1993).

Anexo 2. Manual de usuario:

Para el registro del software fue necesario la realización de un manual de usuario, el cual contiene la información mínima vital para que el cliente-usuario pueda hacer uso de la funcionalidad de la herramienta.

Link de visualización:

https://usantotomaseduco-my.sharepoint.com/:b:/g/personal/jose_quiroga_usantoto_edu_co/Eds6D3qrqIFPuzwDSNDy9DUBym53w8zhB_k4-II-MJJ8mA?e=wVNg3O