



Escuela de Administración  
Escuela de Ingeniería, Ciencia y Tecnología

Maestría en Business Analytics

Sistema de predicción de demanda utilizando técnicas de inteligencia artificial, enfocado en la  
línea de ritmo cardiaco en Medtronic Latinoamérica

Presentado por:

Julián David Cortés García y María Claudia García Cuenca

Bogotá, D.C. 10 de mayo de 2023



Escuela de Administración  
Escuela de Ingeniería, Ciencia y Tecnología

Sistema de predicción de demanda utilizando técnicas de inteligencia artificial, enfocado en la  
línea de ritmo cardiaco en Medtronic Latinoamérica

Presentado por:

Julián David Cortés García y María Claudia García Cuenca

Bajo la dirección de:  
John Pablo Calvo López

Maestría en Business Analytics

Escuela de Administración

17 de Junio de 2023

Bogotá, D.C., Colombia

## Contenido

Contenido .....	3
Agradecimientos.....	4
Declaración de originalidad y autonomía.....	5
Declaración de exoneración de responsabilidad .....	6
Lista de tablas.....	8
Abreviaturas (Opcional).....	9
Resumen Ejecutivo.....	10
<i>Palabras claves:</i> Ritmo Cardíaco, Modelo Predictivo, Forecast, Inteligencia artificial, Holt Winters, ARIMA, CRISP-DM, Medtronic. ....	10
Abstract .....	11
<i>Keywords:</i> Cardiac Rhythm, Predictive model, Forecast, Artificial intelligence, Holt Winters, ARIMA, CRISP-DM, Medtronic. ....	11
1. Introducción.....	12
2. Objetivos.....	17
3. Alcance .....	18
4. Metodología.....	19
5. Cronograma .....	27
6. Resultados y Analisis.....	28
7. Plan y recomendaciones de implementación y aplicación .....	37
10. Conclusiones.....	42
Referencias bibliográficas.....	44

## **Agradecimientos**

Al culmen de todo estudio Superior, se debe realizar retroalimentación en diferentes sentidos, partiendo de las circunstancias de tiempo, modo y lugar que me motivó iniciar y terminar una maestría; en ese sentido agradezco a Dios Creador y fuente inspiradora de todo lo hermoso que nos rodea, en segundo lugar, a mi familia en especial a mis padres que, con su honestidad, responsabilidad, respeto, sentido humano y perseverancia son un modelo para seguir. A Medtronic, quienes me brindaron los recursos y la oportunidad de investigar acerca de un tema propio de ellos, en beneficio de los pacientes que requieren de su tecnología. Por supuesto a mis docentes por sus enseñanzas y guía, y por último a la Universidad del Rosario mi Alma Máter quienes me formaron en pregrado y me brindaron la oportunidad de ser Magister, gracias por siempre.

*Julián David Cortés García*

Agradezco a Dios, a mi familia por el apoyo incondicional, a Medtronic por brindarme los recursos y las herramientas para desarrollar el presente proyecto, a Julian ya que, gracias a nuestro trabajo en equipo, intercambio de ideas y desafíos mutuos permitieron enriquecer mi experiencia educativa y por último al Ministerio de las TIC por permitirme ser beneficiaria de la Beca.

*María Claudia García Cuenca*

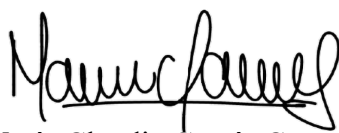
### **Declaración de originalidad y autonomía**

Declaramos bajo la gravedad del juramento, que hemos escrito el presente Proyecto Aplicado Empresarial (PAE), en la propuesta de solución a una problemática en el campo de conocimiento del programa de Maestría por nuestra propia cuenta y que, por lo tanto, su contenido es original.

Declaramos que hemos indicado clara y precisamente todas las fuentes directas e indirectas de información y que este PAE no ha sido entregado a ninguna otra institución con fines de calificación o publicación.



Julian David Cortés García



María Claudia García Cuenca

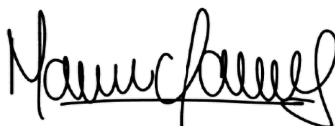
Firmado en Bogotá, D.C. el 17 de junio de 2023

### **Declaración de exoneración de responsabilidad**

Declaramos que la responsabilidad intelectual del presente trabajo es exclusivamente de sus autores. La Universidad del Rosario no se hace responsable de contenidos, opiniones o ideologías expresadas total o parcialmente en él.



Julian David Cortés García



María Claudia García Cuenca

Firmado en Bogotá, D.C. el 17 de junio de 2023

## Lista de figuras

Figura 1. <i>Dashboard Análisis descriptivo de la línea de negocio</i> .....	21
Figura 2. <i>Resultados prueba PCA</i> .....	22
Figura 3. <i>Cronograma Proyecto Empresarial</i> .....	27
Figura 4. <i>Partición de los datos de la demanda, en datos de entrenamiento y de validación</i> .....	28
Figura 5. <i>Resultados prueba parcial de autocorrelación</i> .....	30
Figura 6. <i>Gráfico de densidad de residuales</i> .....	31
Figura 7. <i>Comportamiento de la demanda precedida</i> .....	32
Figura 8. <i>Aislamiento de los componentes de la serie de tiempo</i> .....	33
Figura 9. <i>Comportamiento de la demanda precedida modelo Holt Winters</i> .....	34
Figura 10. <i>Árbol de decisiones de riesgos</i> .....	36
Figura 11. <i>Arquitectura nube propuesta</i> .....	39

**Lista de tablas**

Tabla 1 <i>Medición de exactitud para los modelos implementados metodo back test</i> .....	24
--	----

### **Abreviaturas**

ARIMA: Autoregressive Integrated Moving Average.

CDS: Cardiovascular Diagnostics and Services.

CELA: Central Latin America

CFN: Customer Facing Number.

CPT: Cardiac Pacing Therapies.

CRM: Cardiac Rhythm Management.

FCT: Forecast.

LATAM: Latin-American.

MAE: Mean Absolute Error (Error absoluto medio)

MDT: Medtronic.

MSE: Mean Squared Error (Error cuadrático medio)

NOLA: Northern Latin America.

API: Application Programming Interface

PCA: Análisis de Componentes principales.

SOLA: South Latin America.

SQL: Structured Query Language.

WMAPE: Weighted Mean Absolute Percentage Error.

VPN: Valor presente neto.

## Resumen Ejecutivo

### *Sistema de predicción de demanda utilizando técnicas de inteligencia artificial, enfocado en la línea de ritmo cardiaco en Medtronic Colombia*

Actualmente la línea de ritmo cardiaco de Medtronic Latino-America, se ha visto notablemente impactada por el desabastecimiento de componentes clave y la falta de mano de obra, para la manufactura de dispositivos médicos como lo son marcapasos y desfibriladores médicos implantables. Para el año 2022 se ha visto una disminución de la disponibilidad del producto en aproximadamente en un 15%, lo que ha afectado notablemente a las ventas y las relaciones con cada uno de los clientes de la compañía. Teniendo en cuenta el problema planteado, el presente proyecto empresarial tiene como fin desarrollar un sistema de predicción de demanda, donde se evaluó el desempeño de dos técnicas de inteligencia artificial (Holt Winters y ARIMA), teniendo como base el comportamiento de la demanda en los últimos 4 años y aplicando la metodología CRISP-DM para su desarrollo. Al comparar las dos técnicas utilizadas, se logra identificar que la ARIMA presentó una mayor eficiencia con respecto a la técnica Holt Winters, por lo cual se recomienda aplicar la misma al momento de predecir la demanda de dispositivos.

*Palabras claves:* Ritmo Cardiaco, Modelo Predictivo, Forecast, Inteligencia artificial, Holt Winters, ARIMA, CRISP-DM, Medtronic.

## Abstract

### *Artificial intelligence-based demand prediction system focused on the cardiac rhythm product line in Medtronic Colombia*

Currently, Medtronic Latin America's Cardiac Rhythm Product line has been significantly impacted by a shortage of key components and a lack of workforce for the manufacturing of medical devices such as pacemakers and implantable medical defibrillators. In 2022, there has been a decrease in product availability of approximately 15%, which has significantly affected sales and relationships with each of the company's customers. Considering the problem at hand, the aim of this business project is to develop a demand prediction system. The performance of two artificial intelligence techniques, Holt Winters and ARIMA, was evaluated based on the demand behavior over the past 4 years, using the CRISP-DM methodology for development. When comparing the two techniques used, it is identified that ARIMA demonstrated higher efficiency compared to the Holt Winters technique. Therefore, it is recommended to apply ARIMA when predicting device demand

*Keywords:* Cardiac Rhythm, Predictive model, Forecast, Artificial intelligence, Holt Winters, ARIMA, CRISP-DM, Medtronic.

## 1. Introducción

Las enfermedades cardiovasculares son la principal causa de muerte en todo el mundo, y cada año se llevan la vida de miles de personas entre los 40 y 70 años (World Health Organization, 2021). Entre los diferentes tipos de enfermedades cardiovasculares existentes, las arritmias son aquellas que afectan el ritmo cardíaco del corazón. Esta patología se caracteriza por ser un trastorno que afecta la frecuencia cardíaca, ya sea porque el corazón late demasiado rápido (taquicardia) o demasiado lento (bradicardia). Aunque esta enfermedad puede tratarse con medicamentos, en algunos casos no resultan efectivos y se recomienda recurrir a terapias alternativas como los implantes de marcapasos o desfibriladores. Estos dispositivos, que constan de un conector, un circuito integrado y una batería, ayudan a monitorizar el ritmo cardíaco, estimular el corazón y, en caso necesario, suministrar un choque eléctrico al paciente para reestablecer el ritmo del corazón en caso de fibrilación ventricular (Timperley et al., 2019).

En Estados Unidos para el año 2019 aproximadamente 870 mil personas fallecieron por insuficiencia en su ritmo cardíaco (Tsao et al., 2022), siendo esta enfermedad la principal causa de hospitalización en pacientes de más de 65 años y donde casi el 80% de pacientes que acuden a urgencias tienden a ser hospitalizados (Russell & Pang, 2019). Por esta razón es de vital importancia para los servicios de salud garantizar el acceso a esta clase de terapias en el menor tiempo posible y así mismo evitar complicaciones mayores a los pacientes, para no congestionar los sistemas de salud.

Medtronic es una empresa global líder en tecnología médica con más de 70 años de experiencia en el mercado y una presencia en más de 150 países. Su misión es mejorar la calidad de vida de las personas a través de soluciones innovadoras en tecnología médica que abordan más de 70 de las enfermedades más complejas y desafiantes del mundo (Medtronic, 2021).

La línea de ritmo cardíaco fue la primera línea de negocio que tuvo Medtronic y se originó a partir de una emergencia médica en Mineápolis en 1957. Durante un apagón, los pacientes que acababan de someterse a cirugía cardíaca abierta y que aún estaban conectados a marcapasos que dependían de una fuente de energía eléctrica estaban en riesgo de perder la vida. Ante esta situación, un cirujano cardíaco de la Universidad de Minnesota se acercó al fundador de Medtronic con la solicitud de crear un marcapasos con batería en un plazo de solo cuatro semanas. En respuesta a esta necesidad urgente, Medtronic desarrolló el primer marcapasos implantable en la historia de la medicina en un lapso sorprendentemente corto. Desde entonces, la tecnología de ritmo cardíaco de Medtronic ha revolucionado la atención médica y ha salvado innumerables vidas (Medtronic, 2023).

La empresa ha seguido liderando la industria en el desarrollo de dispositivos médicos de ritmo cardíaco avanzados y los últimos cinco años la línea de ritmo cardíaco ha logrado un crecimiento en ventas y en participación en el mercado, el cual ha aumentado del 41% al 44%. Estos resultados se han logrado a partir del continuo desarrollo de nuevas tecnologías, lo que ha resultado en lanzamientos exitosos de diferentes productos y soluciones nuevas para pacientes con trastornos del ritmo cardíaco. La presencia en los mercados emergentes ha contribuido al aumento significativo del 25% en ventas en los últimos cinco años y, a raíz de esta expansión en

el año 2019, Medtronic abre su centro de servicios compartidos en Colombia con el fin de centralizar sus operaciones en Latinoamérica y aumentar su eficiencia y brindar un mejor servicio a sus clientes en más de 10 países.

A consecuencia de la pandemia del COVID-19 y las cuarentenas implementadas en todo el mundo como medida preventiva para evitar la propagación del virus se vieron afectadas numerosas empresas, entre ellas el sector de la tecnología, cuyas principales materias primas, como las baterías de litio y los microchips, no fueron ajenas en sus inconvenientes por la dependencia de China como mayor productor y distribuidor de estos materiales (Dyatkin & Meng, 2020). Además, las restricciones de viaje nacionales e internacionales obstaculizaron el suministro de mano de obra necesaria para operar completamente todas las instalaciones de producción, igualmente no podemos desconocer el tema de la guerra que se suscita entre Rusia y Ucrania cuyas consecuencias se extienden a nivel mundial.

Para contrarrestar esta situación de desabastecimiento, las empresas que cuentan con cadenas de suministro globales han optado por incluir y adoptar nuevas metodologías y técnicas para optimizar sus operaciones, es así, que nace el concepto de la resiliencia en la cadena de abastecimientos, donde incluyen técnicas de inteligencia artificial para diferentes sub-procesos tales como gestión de transporte, almacenamiento, predicción de la demanda, optimización de rutas, entre otras (Modgil et al., 2021).

Para el año 2021, múltiples empresas a nivel mundial empezaron a presentar desabastecimientos de materias primas, para la construcción de dispositivos que necesitan de

semiconductores para su funcionamiento (Panwar et al., 2022) Medtronic no es ajena a esta situación, este desabastecimiento ha afectado la fabricación de dispositivos médicos implantables como desfibriladores y marcapasos, lo que ha impactado negativamente sobre la unidad de negocio de ritmo cardíaco, en donde los mayores damnificados son los pacientes.

Esta situación ha impactado significativamente a Medtronic, que ha visto disminuir su producción de dispositivos en un 40%. Esto significa que aproximadamente un 40% de los pacientes no han podido recibir las terapias necesarias o han tenido que someterse a una lista de espera mientras esperan acceder a los dispositivos. En un intento de mitigar la situación, la empresa ha dejado en manos del equipo de marketing regional la distribución de los dispositivos de alto y bajo poder, como resultado de esta estrategia, se ha logrado identificar que la precisión del pronóstico de la demanda actual para la línea de desfibriladores es del 42% en promedio en la primera etapa de evaluación y del 46% en la tercera etapa, después de que cada planificador de la demanda ha realizado ajustes en el transcurso del trimestre.

Como medida de contingencia, actualmente en Medtronic se están realizando las asignaciones de producto de manera manual y, es a partir de ahí, que se ha logrado identificar que el pronóstico de la demanda establecido para cada país que no coincide con la demanda real, por ejemplo, en mayo del año 2021, se tenía estipulado para Latinoamérica una predicción de demanda de 54 mil unidades y su demanda real fue de 81 mil unidades. Esta discrepancia conlleva que el proceso de producción no sea eficaz, debido a que el número de unidades que se solicitan fabricar fue mucho menor a las unidades que solicitaba el mercado, afectando directamente en la planeación para la fabricación de producto, los tiempos de entrega del

producto e impactando significativamente en el negocio, la fidelización de los clientes y, sobre todo, la salud de pacientes que requieren de estas terapias para aliviar su dolor y restaurar su salud.

Para mitigar esta problemática, se propone este proyecto, que busca desarrollar una herramienta que permita mejorar el cálculo del pronóstico de la demanda esperada incrementando su asertividad por lo menos en un 30%. Para el desarrollo del modelo se utilizarán diferentes técnicas en series de tiempo, aplicando los datos históricos de la demanda y de igual manera se calcularán diferentes tipos de errores, que nos permitirán definir cuál es la técnica optima a implementar.

## 2. Objetivos

Desarrollar un sistema de predicción de demanda a un año, para los dispositivos médicos implantables de la línea de Ritmo cardiaco (CPT-CDS) en Latinoamérica, con una precisión mínima del 70% en el cálculo del FCT, que permita optimizar los procesos de producción y garantizar el acceso a las terapias de Medtronic de una manera oportuna.

### 2.1 Objetivos Específicos

- Realizar un análisis descriptivo teniendo en cuenta el histórico de la demanda de dispositivos.
- Diseñar un dashboard en Power Bi, que permita visualizar la información de demanda y forecast para cada uno de los clusters de LATAM (NOLA – CELA – SOLA) y todas las sub-líneas de negocio de la línea de ritmo cardiaco.
- Implementar un API en el lenguaje de programación Python, que permita realizar una conexión directa entre las bases de datos utilizadas y el algoritmo a implementar.
- Evaluar la precisión de los modelos mediante tres técnicas diferentes.
- Establecer un plan de recomendaciones para para poner en producción el modelo y que sea accesible para todas las áreas interesadas.

### 3. Alcance

Esta investigación se enfocará en realizar la predicción de demanda de dispositivos médicos, de la línea de ritmo cardiaco de Medtronic Latinoamérica y se desarrollará con el fin de impactar y optimizar los procesos de planeación y distribución de producto, que se han visto afectados por el desabastecimiento de componentes esenciales para la fabricación de dispositivos; de igual manera este trabajo investigativo buscará impactar en las ventas, la fidelización con el cliente y el acceso oportuno a las terapias que ofrece Medtronic a los pacientes. Para lograr este propósito proponemos los siguientes entregables:

- Una aplicación Power BI donde se vea reflejado el FCT calculado en la empresa y la demanda para todas las sub-lineas de negocio de Ritmo cardiaco, en todas las geografías de LATAM.
- Notebook con el desarrollo paso a paso del modelo de predicción, para la sub-linea de desfibriladores.
- Plan de recomendaciones de una arquitectura nube, como propuesta para la implementación en producción del modelo predictivo.

## 4. Metodología

Con el fin de mejorar la predicción en la demanda en al menos un 30% y lograr impactar de manera significativa en los procesos de producción de los dispositivos para la línea de ritmo cardíaco, este es el punto de partida de esta investigación la cual se desarrolló a partir de los conocimientos adquiridos.

En primera instancia y con fin de entregar un escrito investigativo que ilustre de manera más eficiente y efectiva, se logró estructurar y poner en práctica las diferentes metodologías que existen, para el caso se utilizó una metodología híbrida entre la cascada y ágil, la cual tuvo una duración de 10 meses y consta de 6 fases, que se dividieron en Sprints de 2 a 3 semanas y para lo cual se tenía definido los Sprints Backlogs con sus respectivos MVPs. El estructurar el proyecto de esta manera fue de gran utilidad que a medida que terminaba un sprint, se lograba evidenciar los avances y las oportunidades de mejora para aplicar y continuar con en el siguiente.

Para definir el propósito de cada una de las fases, se decide aplicar una metodología CRISP-DM con las siguientes fases:

### 4.1 Entendimiento del negocio

La primera fase, se centra a en entender el negocio, explorando las diferentes líneas de productos de la línea de ritmo cardíaco y estudiando cómo los planeadores de la demanda, que son las personas encargadas de calcular el FCT, realizan este cálculo y en que plataformas se encuentra centralizada esa información, que para este proceso es en el programa SAP. La segunda fase, se enfoca en entender los datos, como primer paso, identifica a cuáles bases de datos se necesita acceder y en donde se encuentran las mismas, encontrando que la compañía

dentro de sus políticas de gobierno de datos maneja un ambiente para desarrollo de analítica empresarial, donde centraliza la información de los diferentes softwares que se utilizan en la compañía (SAP, Map Agile, RAD) en un servidor SQL, que para el caso de las bases de datos que se requieren, la información se actualiza en el servidor todos los lunes.

#### **4.2 Entendimiento de los datos**

Al obtener el acceso a las tres bases de datos que contienen la información necesaria para el desarrollo del proyecto (Global Supply Chain, Global Material y Global Sales) se procede a identificar cuáles son las tablas necesarias de cada una de las bases de datos, identificando las tablas de demanda, FCT, productos por líneas de negocio y ventas por productos, seleccionamos los atributos que serían relevantes para nuestro modelo, incluyendo la semana del año, el país, la sub-línea de negocio, la referencia única del material, el tipo de material, la demanda y el FCT cargado por los planeadores de la demanda. Cabe resaltar, que la tabla con la información del FCT y la demanda, al tener información semanal de todo el portafolio de productos de la compañía desde el 2019 hasta la predicción del 2026, tiene cerca de 60 millones de registros.

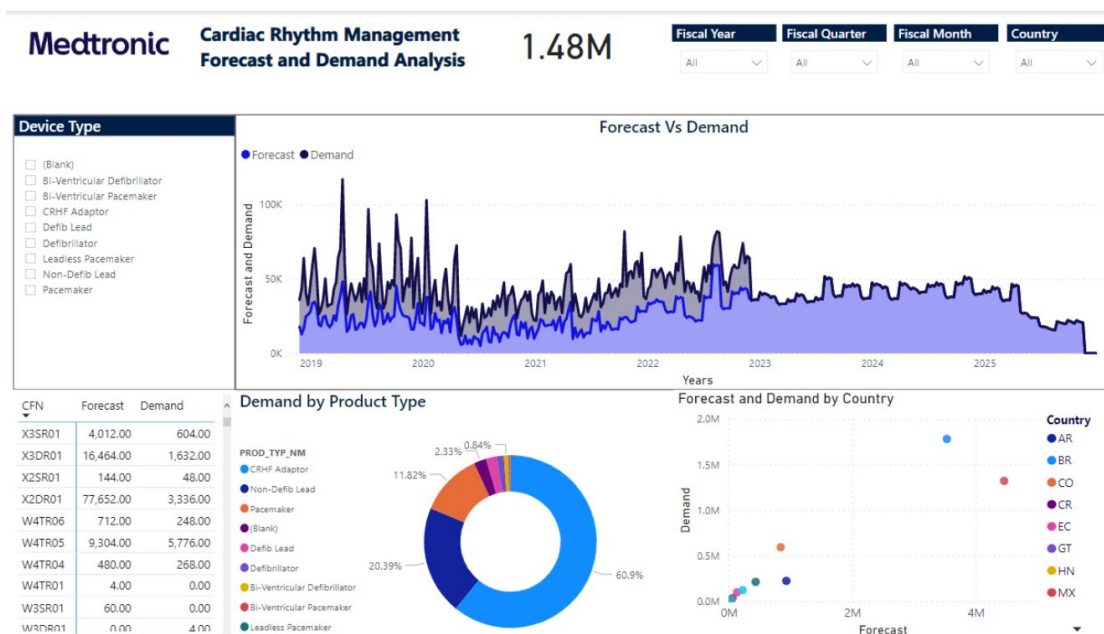
Posteriormente, se desarrolló un dashboard en Power Bi, estableciendo conexión directa con el software Oracle SQL server, para poder hacer las consultas y cargar la información al tablero; teniendo como objetivo del tablero analizar toda la información de la línea de negocio de ritmo cardiaco en todos los países de Latinoamérica, y así mismo poder observar las tendencias de la demanda por línea y por país, los posibles valores atípicos como por ejemplo demanda negativa y observar el forecast propuesto por la compañía para las mismas geografías, las cuales se pueden filtrar tanto por sub-línea de productos y así mismo por productos. A partir del tablero desarrollado se encontró que la sub-línea de desfibriladores para la geografía de Colombia es la

que menos tiene fluctuaciones abruptas en cuanto a la demanda, lo que nos permite entrenar un modelo y que este tenga una exactitud más alta.

Para poder publicar este dashboard y ponerlo en producción, fue necesario implementar un Gateway que garantizara la conexión entre nuestro tablero web y el servidor SQL, así mismo por la gran cantidad de datos, se decide implementar la opción de ‘direct query’ en la cual no se descarga el resultado de la consulta, sino que se hace la consulta en tiempo real.

**Figura 1.**

*Dashboard Análisis descriptivo de la línea de negocio*



Fuente: Elaboración propia

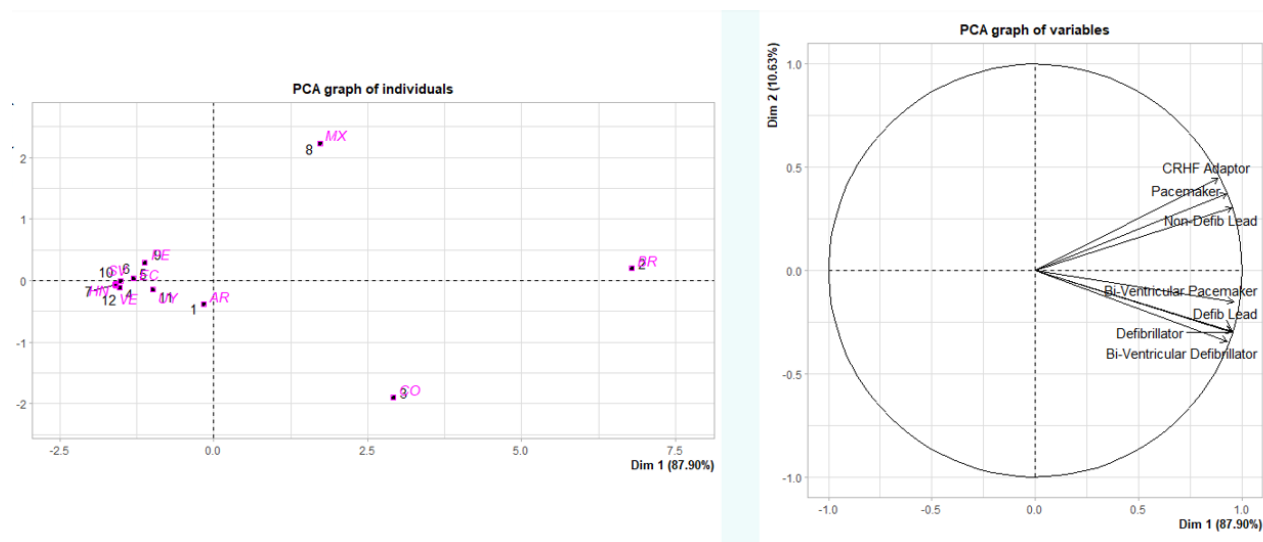
A partir del análisis de este dashboard, se pudo concluir que la sub-línea de negocio desfibriladores en la geografía de Colombia es la más óptima para el entrenamiento de los modelos, para confirmar esta hipótesis, se procede a realizar a una prueba PCA para ver la correlación entre las sub-líneas de negocio y las geografías, se decide exportar la consulta

previamente realizada a formato csv y mediante el software R studio, que tiene una librería robusta para hacer análisis PCA (pcashiny) se realiza este estudio. Con esta prueba se logra determinar qué sub-línea de negocio y que país de Latinoamérica tendría un mejor comportamiento en el entrenamiento de los modelos de predicción propuestos en la investigación que nos ocupa, es por esto por lo que usamos este software y no el software con el que entrenamos los modelos, ya que, al no entrar en un ambiente de producción, no es necesario establecer una conexión entre los mismos.

Evaluando así los resultados obtenidos y como se logra ver en la figura 1, Colombia y la sub-línea de desfibriladores fueron las dos variables que más se correlacionaban con la demanda.

**Figura 2.**

*Resultados prueba PCA*



Fuente: Elaboración propia.

### 4.3 Preparación de los datos

Al momento de realizar el cruce de información con las demás tablas y acotando la información al proyecto desarrollado, se filtran los datos para solo procesar los correspondientes a la línea de desfibriladores, para la geografía de Colombia, con el fin de cumplir el objetivo de este proyecto. El resultado de la consulta es una tabla con 42 mil registros

En esta fase, se evalúa la calidad de los datos con el fin de prepararlos para el modelamiento. Para ello, se filtra los atributos necesarios de cada una de las bases de datos y se evalúa la completitud y unicidad de estos. La completitud se evalúa como el porcentaje de registros requeridos informados respecto al total de registros, donde se obtuvo un valor del 91,8%, y la unicidad se evalúa como el porcentaje de registros únicos respecto al total de registros, donde se obtuvo un valor del 100% para el presente proyecto. En ese orden de ideas se debe medir la validez de cada atributo y, como consecuencia de ello se detectó que el atributo de fecha no contaba con un formato establecido, por lo que se procedió a transformar el formato al de día-mes-año (dd-mm-aaaa).

### 4.4 Modelación

Una vez con los datos preparados, se empieza con la etapa de modelamiento, la cual se desarrolló en el lenguaje de programación Python, como primera medida, se implementa un API que permita la conexión con el servidor mediante el programa Oracle SQL Server, mediante la librería `cx_Oracle` (Oracle, 2022), ya con esta conexión podemos hacer la consulta directamente en Python y guardar el resultado como un dataframe. El resultado de esta consulta nos trae la información del FCT y la demanda por fecha de todos los desfibriladores, por lo que se agrupa toda la información por tiempo, obteniendo la suma de toda la demanda y el FCT en cada fecha.

Ya con los datos filtrados y agrupados por fecha, tenemos un dataframe con dos columnas, la fecha filtrada hasta mayo de 2023 y la demanda para estas fechas, con esta tabla ya se pueden entrenar los dos modelos propuestos, que son el modelo ARIMA y Holt Winters.

El modelo ARIMA (Autoregressive Integrated Moving Average) es un modelo estadístico utilizado para analizar y predecir valores correspondientes de series de tiempo. Este modelo es un compendio de tres componentes principales: el modelo autorregresivo (AR), el modelo de media móvil (MA) y la diferenciación (Hyndman & Athanasopoulos, 2018).

El modelo ARIMA se especifica utilizando tres parámetros principales: p, d, q, donde:

- p: orden del modelo autorregresivo, que indica la cantidad de observaciones pasadas utilizadas para predecir el siguiente valor.
- d: orden de diferenciación, que indica el número de veces que se debe diferenciar la serie temporal para lograr estacionariedad.
- q: orden del modelo de media móvil, que indica la cantidad de términos de error pasados utilizados para predecir el siguiente valor (Ayala Castrejón & Bucio Pacheco, 2020).

El modelo Holt Winters es un método de pronóstico utilizado para modelar y predecir series temporales que tienen patrones de tendencia y estacionalidad. Fue propuesto por Charles C. Holt y Peter G. Winters en la década de 1960 (Brockwell & Davis, 2016). El método de Holt-Winters utiliza tres componentes para modelar una serie de tiempo, que son los siguientes:

- Componente de nivel (nivel): Representa el nivel medio de la serie de tiempo en un momento dado. Es una estimación del valor central en el cual fluctúan los datos.
- Componente de tendencia (tendencia): Captura el patrón de crecimiento o decrecimiento de la serie temporal a lo largo del tiempo. Puede ser lineal o exponencial, dependiendo de si la tendencia es constante o cambia.
- Componente de estacionalidad (estacionalidad): Refleja la variación periódica y recurrente que ocurre en una serie de tiempo. La estacionalidad depende de la frecuencia de muestreo de los datos.

#### 4.5 Evaluación

Para evaluar los resultados de cada técnica, utilizaremos tres mediciones de errores diferentes, el error absoluto medio, el error cuadrado medio y el error absoluto ponderado medio, siendo este último el que utiliza actualmente la compañía para evaluar el FCT.

El error absoluto medio o MAE es una medida utilizada para evaluar la precisión de un modelo de predicción o de regresión, se representa como la diferencia promedio entre los valores observados y los valores predichos. su cálculo se realiza sumando las diferencias absolutas entre cada valor observado y su correspondiente valor de predicción, posteriormente se divide el resultado anterior por el número total de observaciones (Montgomery et al., 2008).

$$MAE = \frac{1}{n} * \sum Y_{observed} - Y_{predicted}$$

El error cuadrado medio o MSE representa la diferencia entre los valores observados y los valores predichos, se calcula sumando los cuadrados de las diferencias entre cada valor observado y su correspondiente valor de predicción, y luego dividiendo esta suma por el número total de observaciones(De Livera et al., 2011)

$$MSE = \frac{1}{n} * \sum (Y_{observed} - Y_{predicted})^2$$

El error porcentual absoluto medio ponderado o WMAPE se calcula a partir de dividir la diferencia entre la suma de los valores observados y los predichos sobre la sumatoria en los valores observados (Makridakis et al., 1997).

$$WMAPE = \frac{\sum(Y_{observed} - Y_{predicted})}{\sum Y_{Observed}}$$

#### 4.6 Despliegue

En la metodología CRISP-DM, la etapa final se enfoca en el despliegue del sistema de predicción. Sin embargo, debido a preocupaciones relacionadas con la ciberseguridad y procesos de aprobación para las licencias requeridas en la implementación del proyecto en la compañía, no fue posible llevar a cabo esta etapa. Como resultado, se recomienda incluir un plan detallado y la arquitectura necesaria para implementar el modelo en producción.

### 5. Cronograma

Figura 3.

Cronograma Proyecto Empresarial

Actividades	jul-22		ago-22		sep-22		oct-22		nov-22		dic-22		ene-23		feb-23		mar-23		abr-23		may-23	
	1 al 15	16 al 31	1 al 15	16 al 31	1 al 15	16 al 30	1 al 15	16 al 31	1 al 15	16 al 30	1 al 15	16 al 31	1 al 15	16 al 31	1 al 15	16 al 28	1 al 15	16 al 28	1 al 15	16 al 28	1 al 15	
Fase 1: Entendimiento del Negocio																						
Planeación Product Backlog	☑																					
Entendimiento del negocio - Procesos de Supply Chain	☑																					
Identificar el Origen de los datos		☑																				
Fase 2: Entendimiento de los datos																						
Recolección de Datos		☑	☑																			
Entendimiento y Exploración de los datos		☑	☑																			
Fase 3: Preparación de los datos																						
Pruebas de Calidad de los datos			☑	☑																		
Limpieza de los datos			☑	☑	☑																	
Pruebas de validación de los datos				☑	☑	☑																
Fase 4: Modelación del sistema.																						
Desarrollo Analisis Descriptivo						☑	☑															
Diseño dashboard Hallazgos							☑	☑														
Algoritmo de Modelamiento								☑	☑	☑	☑	☑										
Fase 4: Evaluación																						
Entrenamiento y Pruebas del Algoritmo									☑	☑	☑	☑										
Calculos del Error del sistema										☑	☑	☑	☑									
Fase 5: Despliegue																						
Diseño de aplicación en Power BI																						
Implementación del modelo																						
Fase 6: Pruebas y aceptación del área impactada																						
Validación del sistema con el Product Owner																						☑
Ajustes y correcciones del sistema																					☑	☑
Entrega final																						
Retrospectiva																						


Fuente: Elaboración propia.

## 6. Resultados y análisis

Una vez culminadas las diferentes etapas relacionadas anteriormente, se procede a el entrenamiento de los modelos, para la cual se implementa la técnica de validación cruzada, donde particionamos nuestros datos de la demanda en dos grupos, el 80% de la información es utilizada para entrenar nuestros modelos y el 20% restante lo usamos para probar el mismo, obteniendo así que nuestros datos de entrenamiento van desde junio de 2019 hasta agosto del año 2022 y nuestros datos de prueba van desde agosto del 2022 hasta mayo del 2023, como lo podemos ver en la figura 4:

**Figura 4.**

*Partición de los datos de la demanda, en datos de entrenamiento y de validación*



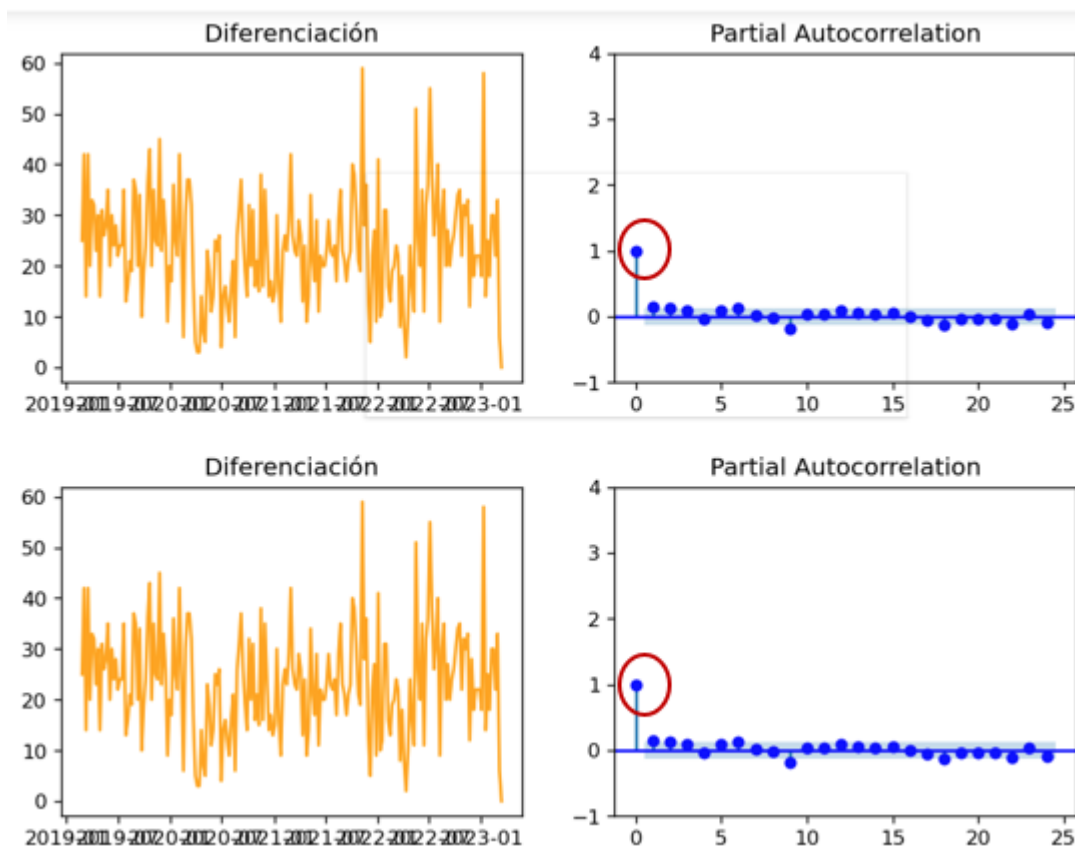
Fuente: Elaboración propia.

Posteriormente, implementamos dos técnicas de modelamiento, un modelo Holt Winters y una ARIMA. La ARIMA es un modelo autorregresivo integrado de media móvil que se desarrolló después de validar nuestro conjunto de datos y determinar su estacionalidad, para dicho fin, utilizamos la prueba de Augmented Dickey Fuller. Esta prueba nos permitió confirmar que los datos cumplían con los requisitos necesarios para ser aplicados en el modelo, lo que significa, que nuestros datos deben tener una varianza significativa y constante, de no ser así, se debe determinar el número de diferenciaciones necesarias para cumplir este requerimiento (en nuestro caso, cero) (Ersöz et al., 2022).

Posteriormente, se realizó una prueba de autocorrelación parcial para determinar los valores  $\rho$  y  $q$ , los cuales resultaron ser 1 para ambos criterios y como se observa en la figura 5 (Banerjee, 2020).

**Figura 5.**

*Resultados prueba parcial de autocorrelación*




Fuente: Elaboración propia.

Una vez entrenado el modelo, utilizamos la hipótesis de “Jung box” con el fin de validar si nuestro modelo se ajustaba bien y de igual manera determinar si este presenta ruido blanco, el resultado para nuestro modelo fue de 0.93, por lo que aceptamos la hipótesis y confirmamos la presencia de ruido blanco.

Para tener un modelo 100% validado, también realizamos un gráfico de densidad de residuales, para lo que encontramos que los errores residuales tienen un promedio cercano a 0 y una varianza uniforme, como se logra visualizar en la figura 6.


**Figura 6.**

*Gráfico de densidad de residuales*



Fuente: Elaboración propia.

En la figura 7 se logra evaluar las diferencias entre, la demanda real, el FCT reajustado de la compañía y el resultado de nuestro modelo (Demand predicted).


**Figura 7.***Comportamiento de la demanda precedida*

Fuente: Elaboración propia.

Para el entrenamiento del modelo Holt Winters, que es un método de suavizado exponencial, basado en tres principales componentes, la estacionalidad, la serie y su tendencia, donde se calcula la serie exponencial suavizada, la tendencia estimada y el componente de estacionalidad estimado (Rodríguez et al., 2022). Para esto es necesario descomponer la serie de tiempo, para así aislar estos tres componentes mencionados, empezamos a preparar los datos para entrenar el modelo, aislando los componentes como lo podemos ver en la figura 8:

**Figura 8.**

*Aislamiento de los componentes de la serie de tiempo*

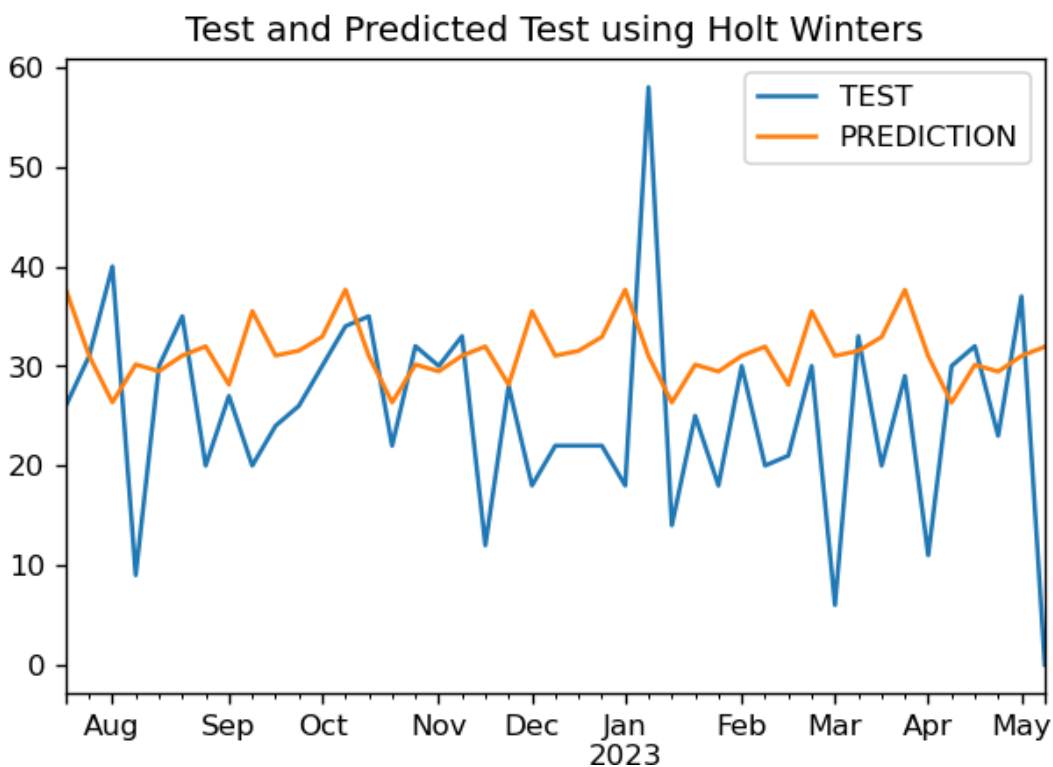


Fuente: Elaboración propia.

De acuerdo con este resultado, podríamos aplicarle una doble o incluso una triple suavización para antes de entrenar el modelo, sin embargo, para este caso, no se logró observar ningún un cambio significativo entre la primer, segunda y tercera suavización, por lo que se entrenó el modelo con la primera suavización, escogiendo como valor de estacionalidad 12, lo que significa que asumimos que la estacionalidad se repite cada 12 meses. El entrenamiento del modelo lo hicimos con la misma técnica de validación cruzada y los mismos datos que para el modelo ARIMA, obteniendo el resultado del entrenamiento que podemos ver en la figura 7.

**Figura 9.**

*Comportamiento de la demanda precedida modelo Holt Winters*



Fuente: Elaboración propia.

Luego de evaluar los resultados de cada técnica, mediante tres mediciones de errores el error absoluto medio, el error cuadrado medio y el error absoluto ponderado medio, siendo este último el que utiliza actualmente la compañía para evaluar el FCT. La siguiente tabla nos muestra la relación de medidas de error por modelo:

**Tabla 1**

*Medición de exactitud para los modelos implementados método back test*

Método de predicción	Error cuadrado medio	Error absoluto medio	Error porcentual absoluto medio ponderado
Arima	94.32	7.34	0.30
Holt Winters	126.84	8.70	0.34
Estadístico, implementado actualmente	No Disponible	No Disponible	0.60

Fuente: Elaboración propia.

Como se puede observar, el modelo que presento una mayor exactitud es el modelo ARIMA y es por esto por lo que es el modelo que se recomienda usar en la fase de producción de nuestra solución, haciendo notación, el método de Holt Winters también tiene un desempeño destacado y se ajusta bien su predicción, superando los estándares actuales que maneja la compañía.

Realizamos una evaluación del costo financiero que implica tener un bajo FCT accuracy para la compañía. Para ello, calculamos el VPN utilizando el FCT calculado por nuestro modelo hasta mayo de 2025 y el precio de venta promedio establecido por el departamento de finanzas, lo que arrojó un valor de \$55,302 USD. Este valor representa la cantidad promedio anual que la compañía se está dejando de ganar al no tener un FCT accuracy del 70% sabiendo que el forecast actual es del 40 %, por lo que permite concluir que mejorando en 30 puntos porcentuales el cálculo del forecast, la compañía podría generar dichos ingresos.

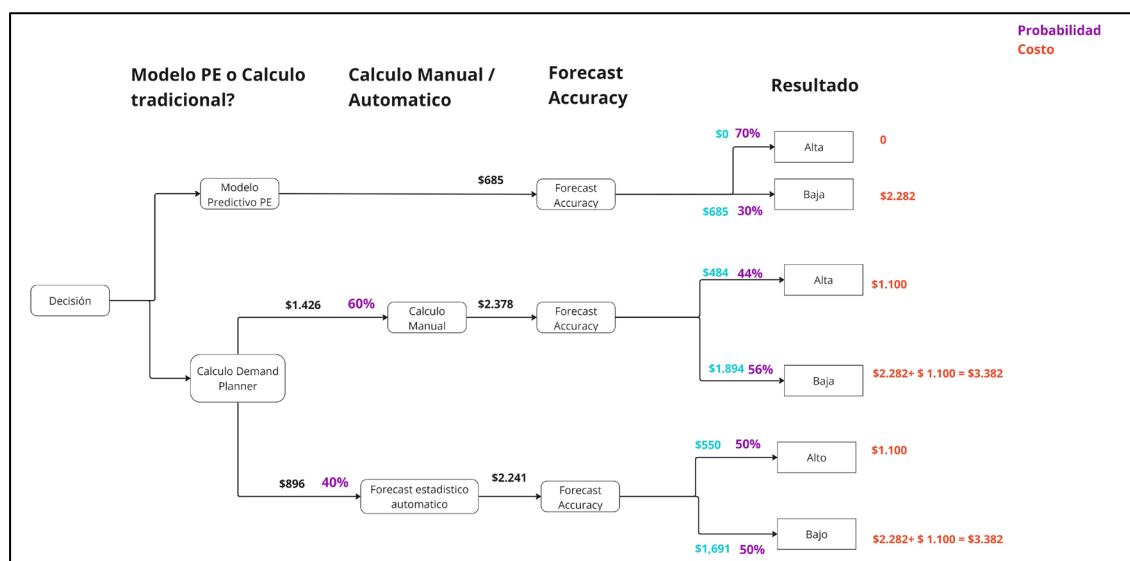
Posteriormente realizamos el análisis de riesgos que afectan a nuestro proyecto, donde identificamos que existen dos alternativas de decisión, la primera es utilizar el FCT de la

empresa y la segunda es emplear el modelo de predicción desarrollado para el Proyecto Empresarial (PE). Es importante tener en cuenta que sí, se opta por utilizar el FCT de la empresa, posteriormente se debe decidir entre aplicar el FCT calculado por el Demand Planner o el estadístico calculado automáticamente.

Una vez establecidas las alternativas de decisión y la secuencia de eventos, se crea un árbol de decisión que estructuró los costos y riesgos asociados a cada opción, particularmente en relación con la precisión del FCT accuracy. Se concluye que gracias a las mejoras significativas en el FCT accuracy aportadas por esta investigación, los costos asociados a los riesgos disminuyen, como se muestra en la Figura 10 a continuación:

**Figura 10.**

*Árbol de decisiones de riesgos*



Fuente: Elaboración propia.

## **7. Plan y recomendaciones de implementación y aplicación**

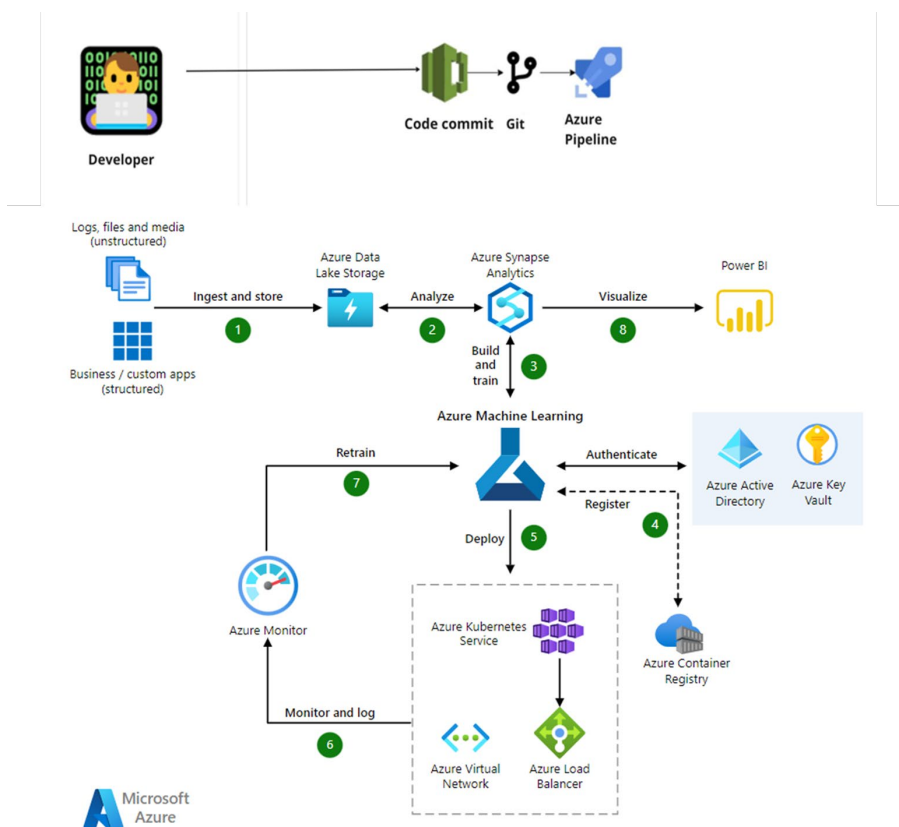
Para implementar el modelo resultado de la investigación, de forma que las áreas interesadas puedan acceder a los resultados del modelo de predicción y puedan reentrenar el modelo con los nuevos datos que se van generando, es necesario en primera medida, ver cuáles son las capacidades tanto financieras como técnicas con las que cuenta la empresa, dado que al ser esta una solución en la que se necesita una maquina dispuesta para ejecutar la labor de entrenamiento, procesamiento y llamado de la información resultante del modelo, además, de un capital humano capacitado para hacer las labores de soporte del modelo, para esto se tiene que incurrir en gastos, bien sea si la solución se maneja on premise o cloud service.

Las soluciones en cloud service tienen una mayor flexibilidad en cuanto a la infraestructura y la disposición de diferentes servicios que se pueden acoplar y ser útiles en el desarrollo de una solución, además de tener soporte por parte de la empresa que ofrece el servicio, documentación de cada uno de los servicios y actualización de los mismos, teniendo menor costo que el desarrollo de una solución on premise, todo depende de las necesidad que tenga la empresa, la escalabilidad de la solución y el conocimiento técnico que tenga el personal (Tachu, 2022). Para el caso de soluciones que implementan inteligencia artificial, existen servicios en nube en los cuales se puede interactuar con el entrenamiento de diferentes modelos y automatizar su puesta en producción, definiendo parámetros de reentrenamiento, interacción con las diferentes fuentes de datos y así mismo con otros servicios para mostrar los resultados, disminuyendo así los riesgos es su producción y mantenimiento.

Para este caso en específico, se recomienda implementar una solución cloud, dado que la empresa cuenta con licencia Microsoft corporativa, además de tener un grupo de desarrollo nube, es así, como al tener acceso a la nube de Microsoft (Azure), podemos tener nuestro modelo en producción. Microsoft Azure es una plataforma de computación en la nube, diseñada para construir, implementar y gestionar diferentes aplicaciones y servicios a través de una red global de centros de datos, proporcionando diferentes aplicaciones y servicios que pueden ser utilizados en conjunto para el desarrollo de una solución y poner está en la red, para así ser usado por diferentes usuarios autorizados en cualquier parte del planeta(Haffner et al., 2020). Uno de estos servicios y en el cual se basa nuestra recomendación de implementación, es Azure Machine Learning, el cual permite al usuario, crear y administrar modelos con mayor confianza y rapidez, permitiendo la interoperabilidad de código abierto y herramientas integradas (Microsoft Inc, 2023). Siendo así está la base, nos permitimos recomendar la arquitectura de implementación de la solución, al ser esta tan versátil, se podrá escalar a las siguientes fases que proponemos, que es entrenar el modelo para las diferentes líneas de negocio y los demás países de Latinoamérica donde la compañía tiene presencia.

**Figura 11.**

*Arquitectura nube propuesta*



**Fuente:** Tomado de Microsoft Learn (Gilley et al., 2023)

Dentro de los roles establecidos, para el caso de la arquitectura de desarrollo se deben definir los developers, en este caso se recomienda que sea el equipo de analítica de la empresa, una persona con un perfil de machine learning developer. En este rol y para el soporte y mejoramiento del modelo, es necesario utilizar plataformas de manejo de versiones, para así tener trazabilidad de cada uno de los cambios que se le hagan al código, por lo que se recomienda incluir al software Git, embebida dentro de un pipeline que relacione cada uno de los

entregables funcionales dentro de un esquema de desarrollo. En cuanto los clientes estos van a ser los encargados de planear la demanda para cada país, el personal de supply chain global, el equipo comercial y de marketing.

Dentro de nuestro servicio de pipeline, se debe establecer una periodicidad para el reentrenamiento del modelo, con el fin de tener mejores resultados debido que al ser la ARIMA un modelo de media móvil, la predicción a un futuro más largo tiende a convertirse en constante.

Por otro lado, como resultado del análisis de riesgos se evidencia que dentro de los eventos inciertos que afectan a la compañía está la fluctuación del precio del dólar, la escasez de materias primas para la fabricación de los productos, la disminución de usuarios o pacientes con alteraciones en el ritmo cardiaco y las pérdidas de ventas por competencia desleal.

Para el caso de la escasez de materias primas y que es la situación que afrontamos actualmente en la compañía el tener un FCT ajustado a la demanda real, es un factor clave para mitigar con el riesgo de no tener producto con el cual responder a nuestros pacientes y a su vez minimizar los costos que representa el perder una venta o fabricar exceso de producto el cual corre el riesgo de expiración. Esto representa en dinero entre \$1.000 USD a 1.500 USD por dispositivo donde si se tiene proyectada una demanda anual de 1,034 piezas, el riesgo de no usar nuestro modelo aumenta probabilidades de perder la utilidad en promedio de \$802.084 USD anuales en Colombia.

Como próximos pasos queda implementar en el modelo y evaluar su comportamiento con las demás líneas de negocio existentes en el campo cardiovascular en Colombia, para luego continuar expendiéndonos por más países en toda la región de Latinoamérica; de igual manera como recomendaciones establecidas por el equipo de planning en la compañía se propuso incluir dentro del power BI los índices de estacionalidad de cada sub- línea de negocio y las métricas

con las cuales se miden a cada uno de los planners con el fin que se pueda evaluar el rendimiento de estos.

## 10. Conclusiones

El desarrollo de un análisis descriptivo para la línea de ritmo cardíaco en Latinoamérica, junto con la aplicación de pruebas de Análisis de Componentes Principales (PCA), resultaron fundamentales para reducir la dimensionalidad de nuestra base de datos. Gracias a este enfoque, se pudo concentrar en la sub-línea de negocio y, el país que presenta un mejor comportamiento en el modelo: específicamente, se determinó que los desfibriladores en Colombia serán la opción óptima.

Después de evaluar los resultados obtenidos para cada uno de los modelos de predicción en serie de tiempo implementados, se llegó a la conclusión que el modelo ARIMA es el más adecuado para predecir la demanda de desfibriladores utilizando los atributos seleccionados. Al ajustar correctamente este modelo, se demostró que tiene una precisión superior al 30% en comparación con los pronósticos generados por el equipo de planificación de la compañía.

Al hacer la evaluación entre el modelo ARIMA y Holt Winters, se decide por la implementación de la ARIMA debido que arrojó una mejor exactitud, sin embargo, el modelo Holt Winters también cumple con los objetivos de precisión de la compañía, por lo que también puede ser utilizado de apoyo para los planeadores de la demanda, al momento que estén estableciendo las unidades demandadas a futuro.

La implementación de este modelo tiene el potencial de tener un impacto significativo en la calidad de vida de los pacientes que padecen enfermedades del ritmo cardíaco, toda vez que permitirá mejorar los procesos de producción y reducir los tiempos de entrega de los dispositivos. Además, que el uso de este modelo ayudará a mitigar la problemática actual relacionada con la falta de disponibilidad de productos, en virtud que su precisión mejorada permite una mejor gestión de los inventarios y una planificación más efectiva de la producción

que le ahorrará a la compañía en promedio \$802.084 USD anuales, para el caso de la línea de alto poder en Colombia.

Al hacer la proyección financiera, se determinó que la compañía al no tener una predicción de la demanda con exactitud del 70%, mejorando 30 puntos porcentuales con respecto a la metodología utilizada actualmente, se está dejando de ganar \$55,302 USD en solo la sub-línea de desfibriladores para Colombia, por lo que, al implementar el algoritmo descrito en la presente investigación, puede revertir esta situación.

### Referencias bibliográficas

- Ayala Castrejón, R. F., & Bucio Pacheco, C. (2020). Modelo ARIMA aplicado al tipo de cambio peso-dólar en el periodo 2016-2017 mediante ventanas temporales deslizantes. *Mexican Journal of Economics & Finance / Revista Mexicana de Economía y Finanzas*, 15(3), 331–354.  
<http://ez.urosario.edu.co/login?url=https://search.ebscohost.com/login.aspx?direct=true&AuthType=ip&db=eoh&AN=EP144434364&lang=es&site=eds-live&scope=site>
- Banerjee, P. (2020). *ARIMA Model for Time Series Forecasting*. Kaggle.  
<https://www.kaggle.com/code/prashant111/arma-model-for-time-series-forecasting>
- Brockwell, P. J., & Davis, R. A. (2016). *Introduction to Time Series and Forecasting*. Springer International Publishing. <https://doi.org/10.1007/978-3-319-29854-2>
- De Livera, A. M., Hyndman, R. J., & Snyder, R. D. (2011). Forecasting Time Series With Complex Seasonal Patterns Using Exponential Smoothing. *Journal of the American Statistical Association*, 106(496), 1513–1527. <https://doi.org/10.1198/jasa.2011.tm09771>
- Dyatkin, B., & Meng, Y. S. (2020). COVID-19 disrupts battery materials and manufacture supply chains, but outlook remains strong. *MRS Bulletin*, 45(9), 700–702.  
<https://doi.org/10.1557/mrs.2020.239>
- Ersöz, N. Ş., Güner, P., Akbaş, A., & BakiR-Gungor, B. (2022). Comparative Performance Analysis of ARIMA, Prophet and Holt-Winters Forecasting Methods on European COVID-19 Data. *International Journal of 3D Printing Technologies and Digital Industry*. <https://doi.org/10.46519/ij3dptdi.1120718>

- Gilley, S., Franks, L., Gayhardt, L., & Salgado, S. (2023). *Azure Machine Learning architecture—Azure Architecture Center*. Azure. <https://learn.microsoft.com/en-us/azure/architecture/solution-ideas/articles/azure-machine-learning-solution-architecture>
- Haffner, O., Kučera, E., & Moravčík, M. (2020). Sales Prediction of Svijany Slovakia, Ltd. Using Microsoft Azure Machine Learning and ARIMA. *2020 Cybernetics & Informatics (K&I)*, 1–9. <https://doi.org/10.1109/KI48306.2020.9039875>
- Hyndman, R., & Athanasopoulos, G. (2018). *Forecasting: Principles and Practice* (2a ed.). <https://otexts.com/fpp2/>
- Makridakis, S., Wheelwright, S., & Hyndman, R. J. (1997). *Forecasting: Methods and Applications*. John Wiley & Sons. <https://research.monash.edu/en/publications/forecasting-methods-and-applications-3rd-ed>
- Medtronic. (2021). *Misión*. Nuestra Misión. <https://latinoamerica.medtronic.com/xl-es/our-company/mission.html>
- Medtronic. (2023). *The Medtronic story: Leading healthcare technology innovation since 1949*. <https://www.medtronic.com/us-en/our-company/history.html>
- Microsoft Inc. (2023). *Azure Machine Learning—ML as a Service | Microsoft Azure*. <https://azure.microsoft.com/en-us/products/machine-learning>
- Modgil, S., Gupta, S., Stekelorum, R., & Laguir, I. (2021). AI technologies and their impact on supply chain resilience during COVID-19. *International Journal of Physical Distribution & Logistics Management*, 52(2), 130–149. <https://doi.org/10.1108/IJPDLM-12-2020-0434>
- Montgomery, D. C., Jennings, C. L., & Kulahci, M. (2008). *Introduction to time series analysis and forecasting*. Wiley-Interscience.

Oracle. (2022, mayo 25). *Cx\_Oracle's documentation*. <https://cx-oracle.readthedocs.io/en/latest/>

Panwar, R., Pinkse, J., & De Marchi, V. (2022). The Future of Global Supply Chains in a Post-COVID-19 World. *California Management Review*, 64(2), 5–23.

<https://doi.org/10.1177/00081256211073355>

Rodriguez, M., Cisneros, H., Arcos-Aviles, D., & Martinez, W. (2022). Forecast of photovoltaic generation in isolated rural areas of Ecuador using Holt-Winters and seasonal variation methods. *IECON 2022 – 48th Annual Conference of the IEEE Industrial Electronics Society, Industrial Electronics Society, IECON 2022 – 48th Annual Conference of the IEEE*, 1–6. <https://doi.org/10.1109/IECON49645.2022.9968817>

Tachu, E. (2022). A quantitative study of the relationship between cloud flexibility and on-premise flexibility. *Issues In Information Systems*, 23.

[https://doi.org/10.48009/1\\_iis\\_2022\\_117](https://doi.org/10.48009/1_iis_2022_117)

Timperley, J., Leeson, P., Mitchell, A. R., & Betts, T. (2019). *Pacemakers and ICDs*. Oxford University Press.

Tsao, C. W., Aday, A. W., Almarzooq, Z. I., Alonso, A., Beaton, A. Z., Bittencourt, M. S., Boehme, A. K., Buxton, A. E., Carson, A. P., Commodore-Mensah, Y., Elkind, M. S. V., Evenson, K. R., Eze-Nliam, C., Ferguson, J. F., Generoso, G., Ho, J. E., Kalani, R., Khan, S. S., Kissela, B. M., ... Martin, S. S. (2022). Heart Disease and Stroke Statistics—2022 Update: A Report From the American Heart Association. *Circulation*, 145(8), e153–e639. <https://doi.org/10.1161/CIR.0000000000001052>

World Health Organization. (2021, junio 11). *Cardiovascular diseases*.

[https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds))