

Proyecto de grado en modalidad de aplicación

[203021] Propuesta metodológica para gestionar el almacenamiento en una empresa del sector alimenticio.

Diego Andrés Pardo Romero ^{a,c}, Daniel Felipe García Gaviria ^{a,c}, Mateo Galvis López ^{a,c}

Juan Carlos García Díaz ^{b,c}

^aEstudiante de Ingeniería Industrial

^bProfesor, Director del Proyecto de Grado, Departamento de Ingeniería Industrial

^cPontificia Universidad Javeriana, Bogotá, Colombia

Abstract

Companies have difficulties in meeting customer demand, which leads to shortages and/or surpluses. In the case of shortages, organizations do not have sufficient inventories to meet demand, while in the case of surpluses, companies incur in inventory cost overruns by having more units than those ordered by the customer. Usually, these scenarios occur in industries which offer products, as is the case of Insaltec, a company that markets powdered raw materials for the technification of processed foods. The performance of the company's demand forecasts can improve, since the instability of the current system generates the non-fulfillment of complete orders implying a decrease in its buyer's loyalty. In order to undertake this type of situations, several ways of dealing with this problem in different industrial sectors have been proposed in the literature, suggesting numerous methodologies for companies to replenish themselves in an optimal way and mitigate order defaults or inventory cost overruns. Therefore, in this paper a methodology is proposed which consists of demand management through the construction of forecasts based on time series models, autoregressive and assemblies of these, accompanied by storage management for the allocation of customer attention through a linear optimization model, and inventory policy management with the DRP method together with the Wagner Whitin algorithm for the Pareto products of the company Insaltec. Firstly, on the demand estimation, an increase was achieved with respect to the accuracy of the predictions made by the organization, finding that, in most cases, the assemblies are the best forecasting methods among the 3 families of models applied. Secondly, with the optimization model it was possible to determine the allocation of the attention of each customer by a warehouse or by cross-docking, including the units shipped and a safety inventory that increased the order fulfillment indicators. Thirdly, the DRP method with the Wagner Whitin inventory policy made it possible to determine how much and when to order for each product reference with the aim of minimizing ordering and holding costs for the planning horizon. Finally, evaluating the performance of the proposed methodology, a 12.02% reduction in the company's logistics costs was achieved.

Keywords: Forecast, exponential time series, autoregressive, ensemble, food industry, inventory policies, storage management, performance measures and logistics costs.

Resumen

Las compañías tienen dificultades para cumplir con la demanda de los clientes, lo que conlleva a que tengan problemas de faltantes y/o sobrantes. Para el caso de faltantes, las organizaciones no cuentan con suficientes inventarios para satisfacer la demanda, mientras que, en el caso de sobrantes, las empresas incurren en sobrecostos de inventarios al tener más unidades de las pedidas por el cliente. Usualmente, estos escenarios se presentan en las industrias que ofrecen productos, como es el caso de la compañía comercializadora de materias primas en polvo para la tecnificación de alimentos procesados Insaltec. El desempeño de los pronósticos de demanda de la compañía puede mejorar, ya que la inestabilidad del sistema actual genera el incumplimiento de pedidos completos, lo que implica una disminución de la fidelidad de sus compradores. Para afrontar este tipo de situaciones, en la literatura se han planteado diferentes maneras de abordar este problema en distintos

sectores industriales, proponiendo diferentes metodologías para que las empresas se reabastezcan de una manera óptima con el fin de mitigar incumplimientos en los pedidos o sobre costos en inventarios. Por lo que se propone una metodología que consiste en la gestión de demanda mediante la construcción de pronósticos basados en modelos de series de tiempo, autorregresivos y ensambles de estos, acompañada además de una gestión del almacenamiento para la asignación de atención de los clientes a través de un modelo de optimización lineal, y una gestión de la política de inventarios con el método DRP junto al algoritmo Wagner Whitin para los productos Pareto de la empresa Insaltec. Primero, sobre la estimación de la demanda se consiguió un aumento con respecto a la precisión de las predicciones realizadas por la organización encontrando que, en la mayoría de los casos los ensambles son los mejores métodos de pronóstico entre las 3 familias de modelos aplicados. Segundo, con el modelo de optimización se logró determinar la asignación de la atención de cada cliente por una bodega o por cross-docking, incluyendo las unidades enviadas y un inventario de seguridad que aumentaron los indicadores de cumplimiento de pedidos. Tercero, el método DRP con la política de inventarios Wagner Whitin permitió determinar cuándo y cuánto pedir para cada referencia que minimice los costos de ordenar y mantener para el horizonte de planeación. Finalmente, evaluando el desempeño de la metodología propuesta, se logró conseguir una reducción del 12.02 % en los costos logísticos de la empresa.

Palabras claves: Pronósticos, series de tiempo exponenciales, autorregresivos, ensambles, industria de alimentos, políticas de inventario, gestión del almacenamiento, medidas de desempeño y costos logísticos

1. Justificación y planteamiento del problema

Las afectaciones que generó la Segunda Guerra Mundial motivaron a 51 países a redactar y firmar la Carta de las Naciones Unidas, la cual buscaba conservar la paz y la seguridad internacional. Pese a que se instauró para evitar conflictos y promover la asistencia humanitaria, la organización de las Naciones Unidas abarca temas fundamentales como el desarrollo sostenible, el medio ambiente, la promoción de los derechos humanos, entre otros. Específicamente, sobre el desarrollo sostenible, en el 2015 los estados miembros de esta organización acordaron 17 objetivos referente a la pobreza, la protección del planeta y mejorar la calidad de vida de las personas para un plazo de 15 años. Dentro de los Objetivos de Desarrollo Sostenible (ODS) de las Naciones Unidas, el noveno se enfoca en industria, innovación e infraestructura, y cómo las tecnologías, el comercio internacional y el uso eficiente de los recursos potencian la competitividad económica para generar empleo e ingresos. Para este noveno objetivo, hay un conjunto de metas y la 9.4 enuncia:

De aquí a 2030, modernizar la infraestructura y reconvertir las industrias para que sean sostenibles, utilizando los recursos con mayor eficacia y promoviendo la adopción de tecnologías y procesos industriales limpios y ambientalmente racionales, y logrando que todos los países tomen medidas de acuerdo con sus capacidades respectivas (Naciones Unidas, n.d.).

Colombia, al ser miembro fundador de las Naciones Unidas en 1945, debe propender por la modernización de la infraestructura de sus industrias mediante nuevas tecnologías y procesos.

La industria alimenticia en Colombia ha crecido en los últimos años, y en este sector se ha presentado un crecimiento promedio por año de 1.4 billones de pesos colombianos los últimos 10 años, lo que implica un incremento medio anual de 4.88 % (Euromonitor, 2020). En consecuencia, las compañías del sector tienen éxito como es el caso de Insaltec, una empresa comercializadora de materias primas en polvo para la tecnificación de alimentos procesados, y que será objeto de este estudio. En el caso de esta compañía, sus ventas han tenido un aumento anual aproximado de 10 % desde el año 2011, posicionándose como una de las 5000 empresas más grandes en Colombia (García, 2020).

Insaltec tiene un portafolio de 213 productos para 20 sectores alimenticios, que se dividen en tres grupos. El primero son las especialidades, que son productos importados con una alta diferenciación por su tecnología avanzada proporcionada por pocos oferentes en el mundo, por lo que existe poca competencia en Colombia. El segundo son los *commodities*, artículos básicos de menor tecnología para el cual existen varios proveedores a nivel internacional, por lo que cuentan con una mayor competencia a nivel nacional. Por último, se encuentran los productos propios, los cuales se diseñan y se implementan de acuerdo con la problemática específica que posee el cliente, y que representan el 5 % de la actividad de la empresa. Los productos que maneja la

organización no son perecederos, pero pierden su funcionalidad y propiedades después de uno o dos años. En cuanto a la gestión de la cadena de suministros, aproximadamente el 90 % de las materias primas que comercializan vienen de proveedores internacionales de 16 países del mundo, principalmente de Alemania y Holanda. Para su operación, la compañía cuenta con 30 bodegas en las principales ciudades del país como Bogotá, Medellín, Cali y Cartagena, las cuales son gestionadas mediante operadores logísticos, y además cuenta con 35 empleados para su actividad en la sede central en Medellín. La estrategia organizacional de Insaltec es ser un aliado fundamental para sus clientes, y su propuesta de valor radica en ofrecer soluciones tecnológicas para sus aliados (García, 2020).

Una de las actividades que realiza Insaltec para su operación son los pronósticos, que son una estimación de eventos futuros en un tiempo determinado con base en registros históricos, los cuales son usados por las empresas para reducir la incertidumbre en la predicción de demanda de sus productos (Medina, 2016). En Insaltec, se utiliza el método de promedios móviles sobre las ventas históricas para establecer una matriz que considera clientes, productos, sector de la industria, ciudades, bodegas, meses y vendedores. Esta matriz permite establecer el presupuesto del año siguiente, aparte de planificar el flujo de inventarios necesario para suplir las necesidades de sus consumidores. Cabe aclarar que, en la industria nacional, los clientes no programan órdenes de compra con anticipación, sin embargo, las ventas de la empresa son un estimado preciso para determinar la demanda real, puesto que la compañía tiene un cumplimiento del 92.99 % para los pedidos programados por los clientes (García, 2020).

Para entender que posibilidades de mejora hay en Insaltec, se desarrolló una matriz DOFA mediante entrevistas con el gerente general de la empresa (Anexo #1. DOFA). Primero, se detectó que la compañía está teniendo problemas de sobrantes o faltantes generando exceso de inventarios o incumplimientos, y se estima que el pronóstico realizado actualmente por la compañía tiene un 65 % de asertividad. Una segunda oportunidad de mejora se presenta en las políticas de inventario, donde actualmente tienen 90 días de inventario para sus principales referencias, es decir para abastecer la demanda de 3 meses. Por esto, se podría valorar la aplicación de nuevas políticas de inventario en las distintas bodegas de acuerdo con la demanda de cada producto que permita tomar decisiones sobre: disminuir o aumentar el número de bodegas arrendadas, la cantidad de producto a almacenar en las bodegas, la frecuencia de pedido, los días de inventario, evaluar donde es menos costoso el almacenamiento, disminuir los kilómetros recorridos para la distribución de sus productos, entre otros. Finalmente, en tercer lugar, mencionó el gerente la posibilidad de una coordinación diferente en el uso de las zonas francas en Colombia, dados los recursos como el flujo de cartera de la empresa, nivel del inventario de seguridad y demanda del cliente (García, 2020).

La principal oportunidad de mejora identificada para Insaltec se encuentra en su flujo logístico, que se divide en tres escenarios. El primer escenario ocurre el 33 % de las veces y se considera flujo normal, esto sucede cuando el cliente compra lo esperado. El segundo escenario se presenta generalmente por factores externos a la organización, causando insuficiencias para atender a cabalidad el requisito del cliente y generando en la empresa faltantes en inventarios, caso que se presenta en el 33 % de las ocasiones. Esta problemática es resuelta por la compañía mediante un servicio aéreo siempre que el proveedor pueda aumentar su capacidad productiva, o con algún distribuidor alternativo que pueda suplir el producto. No obstante, en una minoría de los casos, si ninguna de las dos alternativas es suficiente para abastecer la demanda, la venta se pierde. El factor clave en este proceso es el tiempo disponible con el que cuenta el cliente y el aumento del precio que estaría dispuesto a pagar. La tercera y última situación que experimenta la compañía son los sobrantes, donde Insaltec les informa a sus proveedores que el pedido pactado se detenga debido a que el nivel de adquisición de los consumidores finales presenta una disminución, significando un panorama con exceso de oferta. Esto sucede principalmente por distintas variables exógenas como son: un nuevo competidor, cambios climáticos, nuevos hábitos de compra, entre otros (García, 2020). Dados los tres escenarios logísticos de la empresa, es fundamental tener un pronóstico flexible adecuado a las condiciones de cada producto de acuerdo con los cambios en el mercado utilizando nuevas tecnologías.

De acuerdo con el gerente, una vez establecida la matriz de pronósticos, el flujo logístico de Insaltec se divide dependiendo del país de origen del producto ya sea internacional o nacional, que representan el 90 % y 10 % de los proveedores de la empresa respectivamente. Para el caso del proveedor internacional, el flujo inicia con el transporte marítimo o aéreo de la orden del producto para la recepción y almacenamiento en las zonas francas de Colombia. Después, se hace la nacionalización del producto dependiendo de si este es necesario y de acuerdo con el estado de cartera. Posteriormente, se realiza la contratación de operadores logísticos “Third Party Logistics” (3PL) para que trabajen bajo las directrices y políticas establecidas por la empresa respecto al almacenamiento y transporte que requieren. Continuando, la distribución de las materias primas hacia el cliente puede ser de manera directa bajo la modalidad de Cross-Docking o manteniéndolas en las bodegas del país como inventarios para luego abastecer a los consumidores, exceptuando el 5 % de los productos los cuales son enviados a la planta de Medellín para realizarles un proceso productivo. Para decidir el método de envío de productos al cliente, la empresa usualmente lo hace a través de las bodegas del país, sin embargo, si el consumidor realiza un pedido superior a una cantidad mínima establecida por la compañía, se usa el Cross-Docking o CD directo enviando la referencia y la cantidad solicitada por el cliente, es decir, que no se consolida el pedido con otros artículos (Gómez y Baca, 2014). Para finalizar con el flujo internacional, se efectúa una actualización de los pronósticos con base en la demanda. En el caso de los productos nacionales, el proceso comienza por la contratación de operadores logísticos 3PL y continua de igual manera que en el caso internacional desde este punto (Anexo #2. Diagrama del flujo logístico en Insaltec) (García, 2020).

El principal medio de transporte que usa la empresa para la importación es el marítimo, pero en ocasiones requieren de transportes aéreos cuando hay un escenario de faltantes y el incremento en la demanda no tiene la anticipación necesaria para hacer el respectivo pedido por buque, implicando un aumento en costos logísticos. Con base en los datos de la empresa, normalmente el transporte marítimo cuesta un 8.14 % del valor total de la mercancía, pero el servicio aéreo representa un 51.63 % del valor de la misma, haciendo de este un medio no rentable y de único uso para mantener relaciones estratégicas con el cliente. Se debe aclarar que el comprador y/o el proveedor también responden en cierta medida con el aumento del costo logístico. Sobre este último aspecto, Insaltec está dejando de percibir ventas de los productos más representativos, que configuran un 79.69% de las ventas según el Pareto preliminar, por un valor total de \$788,121,517 COP y \$318,185,139 COP de la demanda que no se atendió por problemas de faltantes para los años 2018 y 2019 respectivamente. El Pareto preliminar para ese periodo de tiempo se puede consultar en (Anexo #3. Faltantes y Pareto). Es por esto que los faltantes son un problema y la disminución del riesgo en estos sería beneficioso para la compañía.

Por lo explicado anteriormente, lo pertinente para Insaltec es mejorar la exactitud de los pronósticos, junto con políticas de inventario y la coordinación del almacenamiento en las diferentes bodegas de la empresa, con el fin de generar una disminución de los costos logísticos y aumentar el cumplimiento de la demanda de los clientes. Como contribución al objetivo 9.4 de los ODS, se planteará para Insaltec el uso de nuevas tecnologías que reduzcan los excesos y escasez en su red logística con el fin de darle uso eficiente a sus recursos. Por ende, se plantea la siguiente pregunta de investigación: ¿Qué cambios al modelo logístico de la empresa Insaltec permitiría disminuir los costos logísticos y aumentar el cumplimiento al cliente en los pedidos de sus principales productos, considerando unos pronósticos que se ajusten mejor al comportamiento de la demanda con una nueva política de inventarios para sus productos, y una gestión de almacenamiento para sus bodegas?

Para el desarrollo del documento, se recomienda revisar la Tabla 1 para distinguir la nomenclatura sobre las abreviaturas de los términos manejados.

ACF - Autocorrelation Function	MAPE - Mean Absolut Percentage Error
ACO - Ant Colony Optimization	ME - Mean Error
AIC - Akaike Information Criterion	MOPSO - Multi-Objective Particle Swarm Optimization
ANN - Artificial Neural Networks	MSE - Mean Squared Error
AR - Auto Regression	MUC - Minimum Unit Cost
ARIMA - Auto Regressive Integrated Moving Average	PACF - Partial Autocorrelation Function
ARIMAX - Auto Regressive Integrated Moving Average with Exogeneous Input	POQ - Periodic Order Quantity
ARMA - Auto Regressive Moving Average	IQR - Interquartile Range
BFP - Balancing Fragmented Period	Q1 - Upper Quartile
CD - Cross-Docking	Q3 - Lower Quartile
DA - Directional Accuracy	R² - Coefficient of Determination
DRP - Distribution Requirement Planning	RB - Gross Requirement (Requerimiento Bruto)
DTR - Decision Tree Regression	RF - Random Forest
ELM - Extreme Learning Machine	RMSE - Root Mean Squared Error
EOQ - Economic Order Quantity	RN - Net Requirement (Requerimiento Neto)
ES - Exponential Smoothing	RNN - Recurrent Neural Networks
FACC - Forecast Accuracy Check	ROP - Planned Order Receipt (Recepción de Orden Planeada)
FOP - Fixed Order Period	RP - Scheduled Receipt (Recepción Programada)
FOQ - Fixed Order Quantity	SARIMA - Seasonal Autoregressive Integrated Moving Average
IBFA - Improved Bacteria Forging Algorithm	SM - Silver Meal
INVH - Project On-Hand (Inventario Hipotético)	SVM - Support Vector Machine
L4L - Lot for Lot	SVR - Support Vector Regression
LOP - Planned Order Release (Liberación de Orden Planeada)	WMA - Weighted Moving Average
MA - Moving Average	WW - Wagner Whitin Algorithm
MAE - Mean Absolut Error	

Tabla 1. Abreviaturas. Fuente: Elaboración propia.

2. Antecedentes

En la cadena de abastecimiento hay diferentes eslabones interactuando y la coordinación óptima de estos permitirá la reducción de costos logísticos. Sobre este tema, un estudio propone un modelo de programación lineal para múltiples eslabones con dos funciones objetivo, una para minimizar costos logísticos y otra para minimizar la tasa de deterioro causado por diferentes alternativas de transporte (Arabzad, Ghorbani y Zolfani, 2015). En otra investigación, se plantea un modelo sobre la variabilidad en tiempos de entrega, haciendo la gestión del exceso o escasez de inventarios mediante el algoritmo ACO, hallando la ruta óptima que reduce costos de mantenimiento adicional de emergencia por recepción temprana o tardía (Yang, Lin, Ho y Kao, 2016; Roozbeh, Hemmati y Akhavan, 2014). Otro caso de estudio usa el IBFA para minimizar costos logísticos para productos perecederos, determinando qué órdenes de compra generar, cuándo producir, cuánto almacenar y qué cantidades enviar entre eslabones, evidenciando que el transporte puede representar más de la mitad de estos costos (Sinha y Anand, 2020). Una investigación aplicada a una cadena minorista evalúa la aplicación de CD en 21 bodegas, valorando el beneficio de despachar los artículos directamente a los clientes evitando el acopio en sus almacenes, disminuyendo los costos logísticos y mejorando la puntualidad de entrega (Vasiljevic, Stepanovic y Manojlovic, 2013). Esta coordinación de eslabones permite reducir costos logísticos, pero requiere de una planeación de la demanda futura para mejorar su precisión.

Una de las primeras medidas para la gestión de la cadena de abastecimiento son los pronósticos, los cuales son manejados por las empresas para disminuir la incertidumbre inherente a la predicción de la demanda. Su finalidad es disminuir pérdidas en ventas, evitar sobrantes o faltantes, disminuir costos logísticos, prestar un mejor servicio al cliente, planear el abastecimiento, entre otros (Kourentzes, Trapero y Barrow, 2020). Esta problemática se ha abordado desde tres enfoques según la revisión literaria de una investigación, donde el primero se basa en modelos de series de tiempo como ARIMA, ARIMAX, ES simple, doble o triple, MA, WMA y modelo de Croston. El segundo se fundamenta en algoritmos de regresión y *Machine Learning* como SVR,

DTR, RF, ANN, RNN, entre otros. El tercero se fundamenta en realizar un ensamble, que es combinar varios algoritmos para crear un modelo de pronósticos el cual logra, en este estudio, un nivel de precisión promedio de 62 %, mejor que los modelos de series de tiempo (59 %) y regresivos (56 %) (Adhikari et al., 2017). No obstante, ninguno de los distintos métodos de pronóstico es predominante sobre los demás, pues la precisión de cada método depende del comportamiento histórico de la demanda (Dellino, Laudadio, Mari, Mastronardi y Meloni, 2015). Otra variante de los pronósticos considera factores externos, como en una investigación sobre la estimación de la demanda de tractores agrícolas que considera cuatro variables exógenas, encontrando que solo una repercute en la variación del consumo (Yadav y Ghosh, 2019). Los demás enfoques hacia factores externos son del sector financiero, distinto al enfoque de esta investigación.

Continuando con los ensambles de pronósticos, una investigación aplicó el objetivo multicriterio MOPSO integrado con un operador dinámico de mutación heterogéneo para la predicción de la macroeconomía e industrias de ese país (Li, Hao, Feng, Sun y Liu, 2021). En otro artículo, realizaron pronósticos sobre la variación en el precio de las acciones en la bolsa de valores de distintas industrias, realizando regresión logística, SVR y RF para categorizar los datos de entrada del ensamble, y aplicando “Deep Learning” combinado con extractores de señales de mercado (Haq, Zeb, Lei, y Zhang, 2021). Otro caso de estudio desarrolla un modelo híbrido para la predicción del consumo de carga eléctrica y el precio de la electricidad, utilizando tres módulos empezando por la transformada de Wavelet, luego la selección de características y por último un algoritmo de aprendizaje profundo de redes (Memarzadeh y Keynia, 2021). De igual manera, otra investigación aplicó modelos ES, ARIMA, SVM, ELM y un ensamble de estos 4 sobre estadísticas de consumo energético del viento en diferentes regiones del mundo, encontrando que el de mejor desempeño para generar predicciones fue el ensamble con un 71.43 %, 85.71 % y 85.71 % respecto al MAPE, RMSE y DA respectivamente (Hao, Feng, Suo, Gao y Sun, 2019). Por ende, la principal ventaja de esta metodología de ensamble de modelos es que generalmente logra obtener mejores resultados que los modelos clásicos y de *Machine Learning*. No obstante, como desventaja, en algunas ocasiones los modelos de ensamble con solo un criterio de optimización tienden a causar un sobreajuste de los datos, es decir, una alta precisión dentro de la muestra, pero un rendimiento deficiente en la generalización del caso (Li et al., 2021). En suma, los modelos clásicos y los ensambles son relevantes para generar predicciones, y ambos se alimentan de registros históricos.

La selección de datos es fundamental en el desempeño de modelos de pronóstico, donde usualmente el 70 % son utilizados para calibrar los parámetros del modelo, y el otro 30 % hace parte de la evaluación y prueba para determinar el error del mismo, mediante el contraste de valores reales de la demanda contra la predicción. El propósito de lo anterior es tener alta precisión, baja variabilidad y bajo sesgo respecto a las pruebas realizadas fuera de la muestra de entrenamiento (Adhikari et al., 2017). Por ende, las medidas más usadas para calibrar los parámetros de un modelo de pronósticos son el MSE y el MAE, métricas usadas para generar menores márgenes de error (Gardner y Acar, 2019). Respecto a la evaluación del modelo, se usan medidas de desempeño para evitar que las empresas incurran en pérdidas significativas por la utilización de los recursos de una manera subóptima dada una predicción de consumo imprecisa. El RMSE y el R^2 son usados para medir el desempeño (Kourentzes et al., 2020; Yadav y Ghosh, 2019). Garantizando unos pronósticos sobresalientes, se podrá diseñar una mejor planeación para atender a los clientes

La gestión de inventarios requiere como dato de entrada pronósticos precisos para generar mejorías en el nivel de servicio al cliente y una reducción en los costos relacionados, haciendo que del almacén se despachen correctamente los productos considerando variables de cantidad, tiempo y costo (Bofill, Sablón y Florido, 2017; Cardona, Orejuela y Rojas, 2018). Sobre este tema, un estudio diseña una metodología buscando solucionar el problema de acopio de materias primas en el sector de concentrados. Primero, se seleccionan los productos más relevantes para hacer los pronósticos correspondientes, segundo, se definen las políticas de inventario a partir del pronóstico calculado y se elige la que genera menores costos y, tercero, se realiza un modelo de programación lineal para decidir la asignación de productos en almacenes (Cardona et al., 2018). En otra investigación, se propone un procedimiento similar por etapas. La primera es buscar información del sistema de inventarios que la empresa aplica actualmente. En la segunda se escogen los productos estrella de la empresa para analizar su demanda y conformar los costos relacionados a los inventarios, luego calcular los parámetros de funcionamiento de diferentes sistemas de inventario y computar los costos de cada modelo. De tercero, se eligen las variables que tuvieron mejor desempeño en el modelo que generó menores costos, las cuales

determinan cuándo y cuánto comprar (Bofill et al., 2017). Las metodologías enunciadas son un acercamiento al gerenciamiento de inventarios, pero existen múltiples enfoques.

Sobre modelos de gestión de inventarios, otra opción es el método DRP, que busca resolver la problemática de los inventarios en el abastecimiento en las empresas (Ngatilah, Rahmawati, Pujiastuti, Porwati y Hutagalung, 2020). Mediante este sistema de control de inventarios, se puede determinar la reposición de productos que se necesita en cada eslabón de la red logística, buscando planear el cumplimiento de la demanda futura (Dayanti, Firdaus, Meiriza, Rosa y Heryanto, 2019; Magdalena y Suli, 2019). Tomando como referencia una compañía de alimentos, una investigación propone gestionar el aprovisionamiento empezando por determinar el consumo en cada nivel de la red logística, luego aplica una política para determinar el tamaño del lote de pedido, posteriormente planea y programa el abastecimiento con el método DRP desde la fábrica a los centros de distribución y las bodegas, logrando una reducción del 20 % en costos de distribución e inventarios (Ngatilah et al., 2020). Un estudio diferente aplica un procedimiento similar, donde adicionalmente consideran el tiempo de reaprovisionamiento (lead time) del producto y un inventario de seguridad reflejados en la matriz del sistema DRP (Dayanti et al., 2019). Dicho inventario de seguridad puede ser calculado de manera genérica sin asumir que la demanda sigue una distribución de probabilidad, o con fórmulas dependiendo de si se ajustan a alguna distribución (Rădășanu, 2016). Otra investigación se centra en los pronósticos como entrada del método DRP, analizando la tendencia y estacionalidad de los datos históricos de la demanda para ajustar las predicciones a modelos de MA o ES, empleando un software para seleccionar el de mejor desempeño en diferentes medidas de error (MAPE, MAE, MSE) (Magdalena y Suli, 2019). Para realizar la gestión planteada, un complemento es la aplicación de políticas de inventario.

Hay múltiples políticas de inventario que usan las empresas en la planeación de sus pedidos a los proveedores, como: L4L, EOQ, POQ, SM, MUC, BFP, entre otras. Una de las políticas existentes es conocida como WW, que tiene como objetivo minimizar los costos de ordenar y de mantener el inventario en un horizonte de planeación, fundamentado en la programación dinámica que evalúa todas las combinaciones posibles con el fin de cubrir la demanda de cada uno de los periodos (Bustos y Chacón, 2012). Es por esto anterior que dicho algoritmo logra el desempeño óptimo, pues evalúa todas las alternativas de órdenes de compra al proveedor y selecciona la que produce menores costos. Como soporte de ello, un estudio aplicó las políticas EOQ, SM, POQ, BFP, L4L, FOP, FOQ y WW para la demanda de un año de seis alimentos de primera necesidad, encontrando que el algoritmo WW produce los menores costos de inventario (Baltagioglu, Temiz y Erol, 2011).

Relacionando los distintos enfoques mencionados, Insaltec gestiona el abastecimiento iniciando por pronósticos de demanda de los productos aplicando MA, considerado el consumo histórico de los últimos dos años por referencia. Por un lado, para la gestión de inventarios de productos importados, se hace un pedido suficiente para cumplir con la demanda pronosticada durante el tiempo de espera entre órdenes, y se vuelve a pedir cuando es recibido. También para estos artículos, la política de inventarios consiste en contar con un nivel de seguridad para 3 meses, y se utilizan operadores logísticos 3PL para el almacenamiento y distribución. Por el otro, en el caso de los productos nacionales, el tiempo de entrega no es un factor determinante.

Por lo tanto, se propone inicialmente un nuevo modelo de pronósticos entre series de tiempo, autorregresivos y un ensamble de estos para la compañía segmentando los datos entre entrenamiento y prueba. Una vez los pronósticos establecidos, es pertinente plantear un modelo de optimización que permita determinar cuáles clientes serán atendidos por CD según los parámetros de la empresa, y cuáles clientes serán atendidos por cada bodega en función de los costos, considerando un inventario de seguridad que garantice disponibilidad de productos. Finalmente, se asignará la política de inventarios WW al método DRP, que minimice los costos de programar las órdenes de compra y los costos de mantener de cada referencia en bodegas y en puertos para el horizonte de planeación, calculando así los costos logísticos añadiendo también los de transporte.

3. Objetivos

Proponer una metodología para gestionar el almacenamiento de los productos Pareto de Insaltec, aplicando métodos de pronósticos que generen mayor precisión, un modelo de optimización para determinar el flujo entre eslabones y una política de inventario que minimicen costos logísticos.

1. Diseñar un modelo de pronósticos de demanda por producto con base en series de tiempo, autorregresivos y un ensamble de modelos, seleccionando el de mejor desempeño para predecir la demanda en el horizonte de planeación.
2. Desarrollar un modelo de optimización lineal, con el fin de determinar el flujo de productos entre eslabones que genere menores costos logísticos, considerando la demanda pronosticada.
3. Aplicar el método DRP para establecer la cantidad y frecuencia de pedido que minimice costos logísticos en el horizonte de planeación, teniendo en cuenta los flujos obtenidos por el modelo de optimización.
4. Medir el desempeño de los diseños propuestos a fin de evaluar la mejoría que generan en comparación con el sistema actual de la empresa, utilizando medidas de error e indicadores.

4. Metodología y Resultados

4.1 Caso de estudio

El caso de estudio se llevó a cabo tomando como base los datos históricos sobre los productos obtenidos del Pareto entre 2018-2019 de la empresa comercializadora de materias primas para la tecnificación de alimentos Insaltec S.A.S. La compañía fundada en el 2011 es una de las 5000 empresas más grandes de Colombia que está presente en 20 sectores alimenticios y en las principales ciudades del país. La logística de la empresa ha presentado problemas en la predicción y almacenamiento de la demanda por la volatilidad, complejidad y desorden del mercado colombiano, generando sobrecostos logísticos e incumplimientos en los pedidos de los clientes.

4.2 Propuesta metodológica

A continuación, se presenta el diagrama de flujo de la metodología planteada para Insaltec, que se subdivide en cinco etapas. La primera consistió en el levantamiento de información respecto a los productos escogidos por el Pareto. En segundo lugar, se hizo la gestión de la demanda de las referencias seleccionadas basada en la elección del mejor modelo de pronóstico de acuerdo con el comportamiento histórico del consumo. El tercero fue la gestión del almacenamiento para determinar las cantidades y la asignación de atención de los clientes ya sea por bodega o puerto, aparte de considerar un inventario de seguridad. En el cuarto, se gestionaron las políticas de inventario de la compañía para establecer la frecuencia y volumen de pedido de los eslabones, con el fin de abastecer la demanda en el horizonte de planeación, disminuir costos logísticos y mejorar el desempeño de acuerdo con indicadores. De quinto y último se realizó la medición del desempeño de la metodología propuesta en comparación con el modelo de Insaltec, respecto a costos logísticos e indicadores. Una explicación más detallada se presenta en la Figura 1.

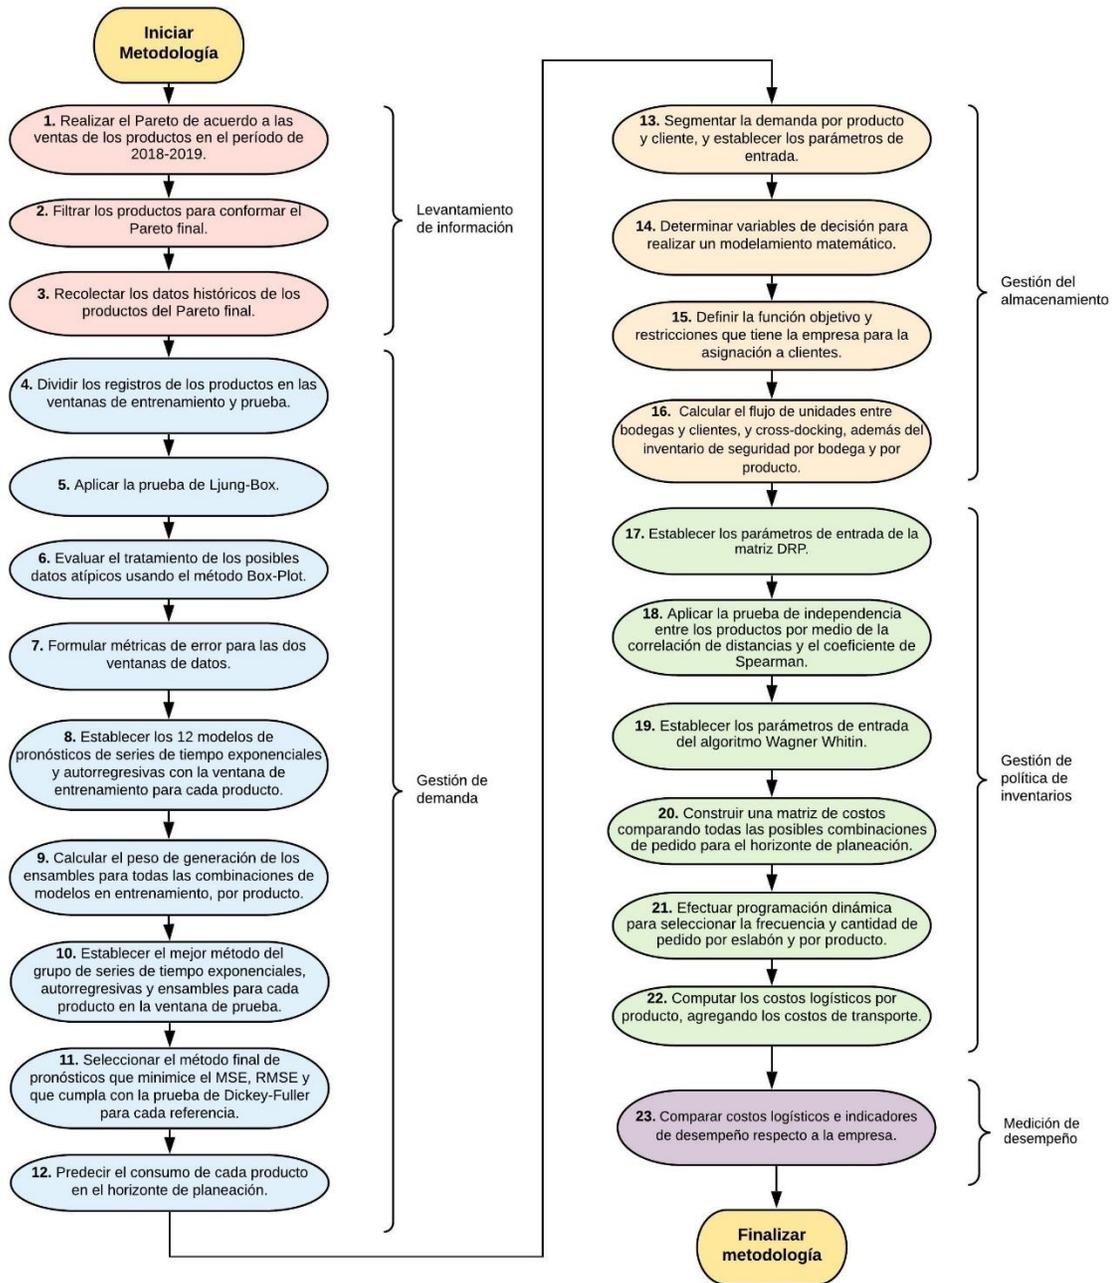


Figura 1. Diagrama de flujo de la metodología propuesta. Fuente: Elaboración propia.

El paso 1 de la metodología consistió en realizar un Pareto de los artículos de la empresa para identificar los productos claves que generan un mayor volumen de ventas, que a su vez son las referencias de mayor rotación puesto que hay una correlación directa entre las ventas y la rotación en esta industria según el gerente (García, 2021). Luego, tomando como base los datos históricos de Insaltec para el periodo del 2018-2019, se aplicó la regla del 80-20 respecto al porcentaje acumulado de ventas, seleccionando inicialmente 22 productos que representaban un 79.69 % del total de las ventas de los dos años. Posteriormente, en el paso 2, se efectuó un filtro de validación considerando que los artículos no tuvieran ningún proceso productivo y que existieran registros de consumo en el 2019. Por ende, para esta propuesta metodológica se trabajó con 14 referencias, de las cuales 3 son *commodities* y 11 son especialidades con un porcentaje de participación del 68.29 % en las ventas entre el 2018-2019, como se evidencia en el Pareto final (Anexo #3. Faltantes y Pareto). Se debe tener

en cuenta que, por temas de confidencialidad, los nombres de los productos fueron cambiados y los registros del año 2020 no se tuvieron en cuenta, debido a que la empresa empezó a importar nuevas referencias y para nuestro estudio es necesario contar con al menos 3 años de datos históricos. Además, para dicho año se evidenció un comportamiento atípico para la industria de alimentos por el Covid-19.

4.3 Gestión de demanda

En este objetivo, se determinaron los modelos de pronóstico por producto adecuados para cada referencia de la compañía Insaltec. En el paso 3 de la propuesta metodológica, se recolectaron los registros históricos de las ventas de los años 2017, 2018 y 2019 de los 14 productos seleccionados para un total de 36 meses, sin tener en cuenta las ventas perdidas por faltantes en estos periodos ya que estuvieron sujetas a factores exógenos. Posteriormente, los registros de ventas fueron convertidos a cantidades utilizando el precio de venta por referencia, para así tener un estimado preciso de la demanda real en kilogramos. Como se mencionó anteriormente, se aplicó la lógica de *Machine Learning* dividiendo los datos en dos grupos para el paso número 4. Por un lado, los datos de entrenamiento abarcan los primeros 30 meses (83 % de la demanda) y se usan para calibrar los parámetros de los pronósticos. Por el otro, los datos de prueba se componen del último semestre del 2019 (17 % de la demanda) y se emplean para medir el desempeño de las predicciones propuestas en la ventana de entrenamiento. En el paso 5, se determinaron qué modelos de pronóstico son los adecuados de acuerdo con el comportamiento de los registros de consumo de cada referencia, por lo que se aplicó la prueba estadística Ljung-Box para verificar el supuesto de autocorrelación de cada producto, ya que los datos históricos presentaban un comportamiento volátil. Su resultado permitió comprobar que al menos existiera un mes dependiente para la demanda en la ventana de entrenamiento, contrastando la siguiente prueba de hipótesis:

$$H_0 = \text{Los datos se distribuyen de forma independiente (Las correlaciones son cero)}$$
$$H_1 = \text{Los datos no se distribuyen de forma independiente (Hay correlación)}$$

Esta prueba se realizó para la demanda inicial en la ventana de entrenamiento sin modificar y diferenciándola de forma mensual y bimestral. Las diferenciaciones se hicieron para convertir la demanda con posibles tendencias a un comportamiento estacionario y detectar de forma fácil las autocorrelaciones entre los distintos meses. Por lo tanto, este supuesto estadístico se aplicó variando el número de meses (*lags*) desde el primero hasta la mitad de los datos para ese conjunto. Debe tenerse en cuenta que las diferenciaciones se realizaron únicamente para la aplicación de la prueba, y este tratamiento no será tenido en cuenta para pasos posteriores.

Por ende, los resultados de la prueba demostraron una autocorrelación entre periodos para la demanda inicial de 5 productos con una confianza del 95 %, sin embargo, en el caso de la diferenciación de un mes, se rechazó la hipótesis nula (H_0) para 11 de los 14 artículos, aumentando considerablemente la cantidad de referencias con una dependencia de las observaciones históricas. Por último, para la diferenciación a dos meses también se cumplió el supuesto estadístico para una conformación diferente de 11 productos. Por consiguiente, se puede afirmar que para todos los artículos seleccionados en el Pareto se cumple la hipótesis alterna (H_1) en al menos un mes, soportado en el (Anexo #4. Resultados gestión de demanda) en la pestaña de pruebas estadísticas. Cabe aclarar que no se diferenció de manera estacional anual, dado que se cumple el supuesto estadístico para todas las referencias de la propuesta metodológica, además, se perderían el 40% de los datos de entrenamiento porque se necesitan 12 observaciones para hacer la diferenciación, generando una serie muy corta. Por lo tanto, con los resultados de la prueba se puede afirmar que los modelos exponenciales y autorregresivos se pueden aplicar sin ningún inconveniente.

Como paso 6, se hizo un análisis de los datos de entrenamiento por medio del método “Box Plot”, una herramienta gráfica que puede ser aplicable a datos asimétricos o que no sigan una distribución normal. Este instrumento se utilizó para detectar cuáles eran los posibles datos atípicos de la demanda de entrenamiento de cada producto por medio de cuartiles. Para iniciar, se calcularon las dimensiones de la caja IQR, restándole el Q1 al Q3, que corresponden al 25 % y el 75 % de los datos respectivamente. Luego, se computaron los límites de los bigotes internos que determinan las zonas donde los datos pueden ser considerados atípicos, los cuales están por encima o por debajo de un rango que tiene una amplitud de $1.5 \cdot \text{IQR}$ por debajo de Q1 y por encima de Q3. Estas cifras anómalas pueden afectar la calibración de los modelos de pronóstico, y para no eliminar por

completo los datos de determinados periodos, en nuestro caso de estudio se cambiaron de tal manera que tomen el valor de la frontera del límite del bigote más cercano y serán referenciados como datos tratados (Seo, 2006; Silva et al., 2019). De igual forma, se analizó el comportamiento de los pronósticos con los datos iniciales y con los datos tratados, buscando verificar si los datos atípicos detectados influían en la calibración de los parámetros de los modelos de pronóstico.

Una vez realizada la prueba de Ljung-Box y definiendo el tratamiento de datos para la ventana de entrenamiento, se definieron las métricas de error que se usarían para comparar los modelos como paso 7. Una de ellas es el error o residual, que establece cuantas unidades estuvo desfazada la predicción de la demanda real. Luego está el ME, que determina en promedio cuanto fue el error en el horizonte de planeación. También se encuentra el MAE con un concepto similar al ME, la diferencia es que se calculan los errores absolutos y se computa el promedio. Posteriormente tenemos el MSE, que es el promedio de los errores elevados al cuadrado. Después está el RMSE calculado como la raíz cuadrada del MSE. Otra métrica es el MAPE, hallado mediante el promedio de los errores porcentuales entre las predicciones y los datos reales. Por último, está la medida porcentual de precisión FACC computado de acuerdo con la ecuación (1).

$$FACC = 1 - \frac{\sum_{i=1}^n (\text{observación}_i - \text{predicción}_i)}{\sum_{i=1}^n (\text{observación}_i)} \quad (1)$$

Donde el 100 % es el caso ideal, si está por encima significa que la predicción se excedió y por debajo fue escasa (Adhikari et al., 2017). Para este estudio, se definieron las métricas MSE y RMSE como criterios de selección del método de pronósticos por producto, ya que el MSE busca castigar los desfases más grandes de las predicciones con respecto a los datos reales puesto que los errores están elevados al cuadrado. Aparte, el RMSE permite interpretar el indicador anterior en las mismas unidades de la demanda, al eliminar la potencia con la raíz. Definiendo lo anterior, se continuó al paso 8 que consistió en la definición de las tres familias de pronósticos que se van a manejar.

Una familia es la de series de tiempo exponenciales, para la cual se aplicaron siete modelos de la familia ES con sus respectivas variaciones. El primer modelo de ES es el simple, que se usa mayormente cuando la demanda no tiene una tendencia clara o un patrón estacional, y consiste en asignarle un mayor peso a los datos históricos más recientes respecto a los antiguos. El segundo y tercer modelo de ES son la doble aditiva y doble multiplicativa, que se diferencian del anterior porque tienen en cuenta dos ecuaciones de suavizado de tendencia. Finalmente, del cuarto al séptimo modelo ES, están las triples con sus respectivas variaciones, que contienen tres ecuaciones adicionales al pronóstico, una para el nivel de suavización, otra para la tendencia y la última para el componente estacional, teniendo la posibilidad de realizar cuatro combinaciones entre tendencia aditiva o multiplicativa y estacionalidad aditiva o multiplicativa (Hyndman y Athanasopoulos, 2018).

Otra familia son los autorregresivos donde se aplicaron 5 modelos distintos. El primero es MA, que consiste en realizar un promedio de los últimos q meses de los datos de entrenamiento para pronosticar los periodos del horizonte de planeación. Es importante mencionar que este no es un modelo autorregresivo, pero se utiliza como base para el ARIMA y sus variantes. De segundo está el AR, que utiliza el coeficiente p para establecer el número de meses que tienen una autocorrelación significativa para realizar las predicciones. El tercero es el ARMA, una combinación entre MA y AR empleado para comportamientos de demanda estacionaria con los parámetros p y q . Como cuarto se encuentra el ARIMA que es similar al anterior, con la diferencia del parámetro d usado para modelar el comportamiento de la serie con tendencia. En quinto lugar, está el SARIMA empleado para datos históricos de demanda que presentan un comportamiento estacional, con los parámetros p , d , q además de P , D , Q para los aspectos estacionales (Hyndman y Athanasopoulos, 2018). Por último, cabe mencionar que para las variaciones del ARIMA no se hizo uso de las gráficas ACF y PACF, sino que se minimizó el AIC para calibrar los parámetros de entrada de los diferentes modelos. También, para promedios móviles se limitó el q hasta 12 periodos con el propósito de que existiera una igualdad de condiciones al momento de considerar la misma cantidad de datos para calcular los errores en el horizonte de entrenamiento.

Los modelos exponenciales se basan en la descripción de la tendencia y la estacionalidad que tienen los datos, mientras que los modelos autorregresivos describen la autocorrelación que existen entre los mismos. Estos dos grandes grupos son los más usados para realizar pronósticos de series de tiempo, además de ser complementarios entre sí (Hyndman y Athanasopoulos, 2018). Como se mencionó en antecedentes, una investigación plantea la combinación entre estas dos grandes familias. No obstante, se planteó un enfoque diferente en el paso 9, al analizar todas las posibles combinaciones entre pares de métodos de pronósticos, con la posibilidad de efectuar la unión de modelos entre las dos familias explicadas anteriormente. Por ende, para generar la unión de modelos se establecieron unos pesos de generación, entendiendo este concepto como el porcentaje promedio de participación que se le asigna a cada método de pronósticos al momento de combinarlos, el cual debe sumar 100 % entre ambos modelos. Esta asignación de pesos se determina por medio de las métricas de error obtenidas en la ventana de entrenamiento por cada modelo, dándole una mayor importancia al método que tuvo mejor desempeño como se evidencia a continuación:

$$\mathbf{error}_{ij} = \mathbf{abs}(\mathbf{demanda\ Real}_i - \mathbf{predicción}_{ij}) \quad (2)$$

$$\mathbf{W}_{ij} = \frac{\mathbf{error}_{ik}}{\sum_{j=1}^2(\mathbf{error}_{ij})} \quad (3)$$

$$\mathbf{TW}_j = \frac{\sum_{i=1}^T \mathbf{W}_{ij}}{T} \quad (4)$$

Donde i indica el periodo, j y k el método de pronóstico individual donde j y k son diferentes modelos y T la cantidad de datos en la ventana de entrenamiento. La ecuación 2 se utilizó para obtener el error absoluto de cada predicción dentro de los datos de entrenamiento de acuerdo con cada método. En la ecuación 3 se explica el cálculo del peso porcentual por par de modelos a ensamblar para cada periodo, considerando que el peso de generación es inversamente proporcional al error generado por el método de pronóstico, es decir que, a menor error, el peso porcentual será mayor y viceversa. Para ilustrar esto anterior, se desglosó la ecuación 3 para cada modelo como se muestra a continuación:

$$\mathbf{W}_{i1} = \frac{\mathbf{error}_{i2}}{\sum_{j=1}^2(\mathbf{error}_{ij})} = \mathbf{1} - \mathbf{W}_{i2} \quad (3.1)$$

$$\mathbf{W}_{i2} = \frac{\mathbf{error}_{i1}}{\sum_{j=1}^2(\mathbf{error}_{ij})} = \mathbf{1} - \mathbf{W}_{i1} \quad (3.2)$$

Donde se puede observar en las ecuaciones 3.1 y 3.2 que el peso de cada método de predicción se calcula en función del error del otro. En otras palabras, si el error del modelo 2 (\mathbf{error}_{i2}) es mayor, generará para el modelo 1 (\mathbf{W}_{i1}) un mayor peso en el ensamble al ser más preciso (el método 1 sería el de menor error), y de igual manera en sentido contrario. Utilizando la ecuación 3 para cada periodo en el horizonte de entrenamiento, se procedió a calcular el peso de generación definitivo por modelo en la ecuación 4, mediante un promedio de los pesos generados en la ventana de entrenamiento. Para cada par de métodos de pronóstico se calcularon los pesos, y el ensamble consistió en multiplicarlos por la predicción respectiva de los modelos, sumando los resultados para obtener una nueva estimación de la demanda en cada periodo del horizonte de planeación. Es importante mencionar que existe una excepción cuando la predicción del modelo j es igual a la demanda real para un periodo en específico, puesto que la ecuación 3 tendría un numerador de cero, donde se le asignaría un valor de 1 al peso de generación para la predicción i del modelo j , dado que el pronóstico es exacto.

Teniendo los resultados de los pronósticos de las tres familias, para el paso 10 se empleó la prueba estadística Dickey-Fuller con el propósito de evidenciar un comportamiento de ruido blanco sin raíces unitarias, es decir, que no existiera ninguna tendencia o patrón en los errores generados en la ventana de prueba por los métodos de pronóstico, mediante la siguiente prueba de hipótesis:

$$\begin{aligned} H_0 &= \text{Raíz unitaria (No es estacionaria)} \\ H_1 &= \text{No hay raíz unitaria (Es estacionaria)} \end{aligned}$$

Esta prueba analiza que los modelos de las tres familias de pronóstico se van a desempeñar de una manera correcta para proyecciones futuras de consumo, proporcionando una validez estadística. Continuando con el

paso 11, se determinó el criterio de selección de los mejores modelos en prueba que cumplieran el supuesto estadístico de la no presencia de raíces unitarias (errores estacionarios), minimizando a su vez el MSE y RMSE. Para cerrar la etapa de gestión de demanda con el paso 12, se determinó el modelo final de pronósticos que cumpliera los criterios de selección para calcular las predicciones por producto. Es importante mencionar que para la ventana de prueba no se vuelven a calibrar los parámetros de los modelos clásicos ni los pesos de generación de los ensambles, sino que se utilizan los obtenidos en la fase de entrenamiento.

Para evidenciar los resultados de los pasos de la gestión de demanda (del 4 al 12 de la metodología propuesta) mencionados se puede consultar el (Anexo #4. Resultados gestión de demanda), que se obtuvieron mediante el software del (Anexo #5. Código Python). Para ilustrar el procedimiento del capítulo, se tomó como ejemplo el producto “A” dividiendo la demanda histórica en entrenamiento y prueba, de acuerdo con el paso 4. Sobre el paso siguiente (5), se aplicó la prueba Ljung-Box para la ventana de entrenamiento. En los datos sin modificar del producto se obtuvo que no existía ninguna autocorrelación, evidenciando que la serie de tiempo no presentó un comportamiento estacionario, sino con posibles tendencias y estacionalidades. En contraste, para las diferenciaciones de uno y dos meses, se comprobó estadísticamente que existe una dependencia de los datos históricos desde el primer mes hasta el decimotercer mes. Pasando al paso 6, se aplicó el gráfico “Box-Plot” para la posible detección de datos atípicos como se muestran a continuación.

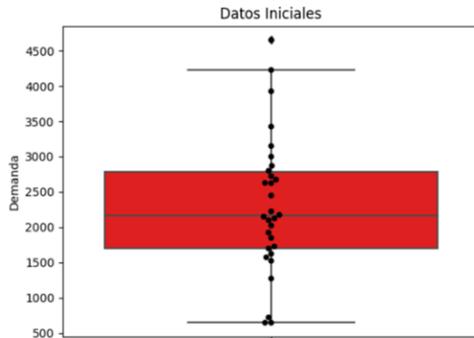


Figura 2. “Box Plot” del producto “A” para datos iniciales. Fuente: Elaboración propia.

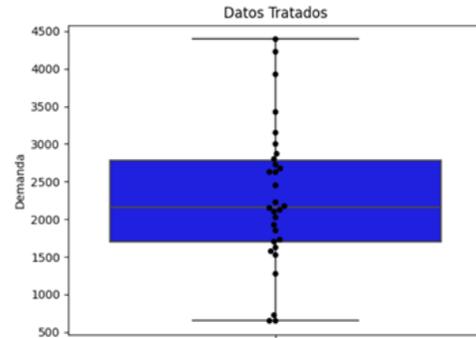


Figura 3. “Box Plot” del producto “A” para datos tratados. Fuente: Elaboración propia.

Como se puede evidenciar en la Figura 2, sólo se consideró un posible dato atípico puesto que se situó por encima del bigote superior, y la naturaleza de este registro anómalo fue porque un cliente elevó el consumo debido a que otro proveedor no fue capaz de cumplir su requisito de demanda. Posteriormente, en la Figura 3 se cambia el dato asignándole el mismo valor del bigote más cercano. Como paso 7, las métricas de error fueron modeladas y formuladas para ambas ventanas de tiempo, y como paso 8 se calibraron los modelos exponenciales, autorregresivos y ensambles optimizando sus parámetros de acuerdo con el criterio de decisión, como se evidencia seguidamente:

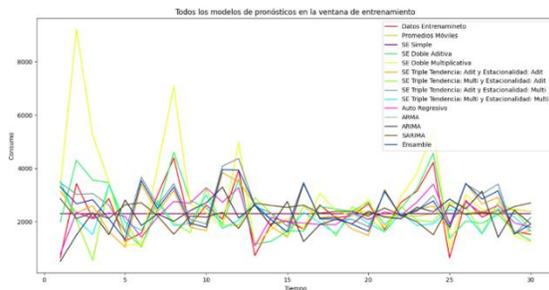


Figura 4. Modelos de pronóstico del producto “A” en la ventana de entrenamiento para datos iniciales. Fuente: Elaboración propia.

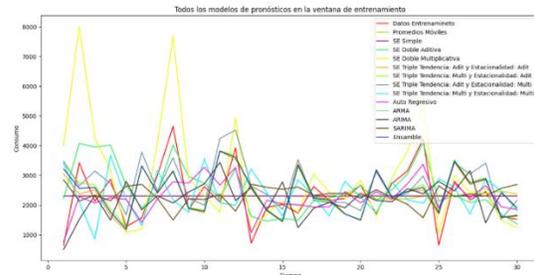


Figura 5. Modelos de pronóstico del producto “A” en la ventana de entrenamiento para datos tratados. Fuente: Elaboración propia.

En las Figuras 4 y 5, se pueden distinguir los doce modelos de pronósticos aplicados para el producto “A” en el horizonte de tiempo de entrenamiento con la demanda sin modificar y con los datos tratados. A pesar de que sólo se modificó un posible dato atípico, se observa que para algunos modelos afecta la calibración de sus parámetros, como es el caso de la ES doble aditiva (verde lima). Además, se puede observar que varios modelos no se acoplan al comportamiento de los datos de entrenamiento, presentando un alto margen de error. Por ende, se realizó un filtro para quedarse con el mejor modelo de predicción de cada una de las tres familias.

Profundizando en los ensambles, en el paso 9 se realizaron todas las posibles combinaciones de las duplas de los modelos individuales con un total de 78 opciones, para posteriormente seleccionar el mejor ensamble que cumpla la hipótesis alterna (H_1) de la prueba Dickey-Fuller y minimice el MSE y RMSE de acuerdo con los pasos 10 y 11. Los métodos de pronósticos finalmente ensamblados se encuentran en la Tabla 2 y 3 con las respectivas métricas de error en la ventana de entrenamiento.

Demanda Inicial								
Entrenamiento del ensamble								
Modelos	Nombre	Error	EM (ME)	DAM (MAE)	ECM (MSE)	RECM (RMSE)	EPAM (MAPE)	FACC
Modelo 1	SE Triple Tendencia: Adit y Estacionalidad: Adit	-2724,39	-90,81	850,43	1150452,55	1072,59	54,6%	96,06%
Modelo 2	SE Triple Tendencia: Multi y Estacionalidad: Adit	-4388,78	-146,29	837,46	1134729,16	1065,24	55,6%	93,66%
Ensamble	Ensamble	-3565,71	-118,86	842,54	1138373,52	1066,95	55,1%	94,85%

Tabla 2. Entrenamiento del ensamble para el producto “A” mediante la demanda inicial. Fuente: Elaboración propia.

Demanda Tratada								
Entrenamiento del ensamble								
Modelos	Nombre	Error	EM (ME)	DAM (MAE)	ECM (MSE)	RECM (RMSE)	EPAM (MAPE)	FACC
Modelo 1	SE Triple Tendencia: Adit y Estacionalidad: Adit	-2899,13	-96,64	872,20	1172342,50	1082,75	56,4%	95,79%
Modelo 2	SE Triple Tendencia: Adit y Estacionalidad: Multi	-11486,05	-382,87	857,13	1181250,13	1086,85	59,4%	83,33%
Ensamble	Ensamble	-7112,72	-237,09	835,49	1136925,98	1066,27	56,5%	89,68%

Tabla 3. Entrenamiento del ensamble para el producto “A” mediante la demanda tratada. Fuente: Elaboración propia.

La ES triple con tendencia y estacionalidad aditiva y la ES triple con tendencia multiplicativa y estacionalidad aditiva, fueron los dos modelos seleccionados para el ensamble de esta referencia, teniendo pesos de generación promedio de 49.45 % y 50.55 % en los datos iniciales respectivamente. Respecto a los datos tratados, se ensambló la ES triple con tendencia y estacionalidad aditiva y la ES triple con tendencia aditiva y estacionalidad multiplicativa con pesos de 50.93 % y 49.07 % cada uno. Cabe destacar que los métodos de pronósticos seleccionados en el ensamble para la demanda inicial pueden ser distintos en comparación con la demanda modificada, como sucedió en algunos productos, debido a que los posibles datos atípicos detectados y tratados en entrenamiento pueden modificar el proceso de aprendizaje de los modelos.

Analizando los errores para la demanda inicial, se obtuvo que el modelo 2 (ES triple con tendencia multiplicativa y estacionalidad aditiva) tuvo mejor desempeño de acuerdo con el criterio establecido, mientras que en la demanda tratada se determinó que el ensamble fue superior. Estos errores sirven de forma preliminar para analizar cómo se está comportando el método, pero las métricas de error calculadas en la ventana de prueba determinan si el modelo de pronósticos quedó calibrado correctamente. Luego, como paso 10 se determinaron los mejores modelos de cada una de las tres familias para ambas demandas, como se muestra en las Figuras 6 y 7.

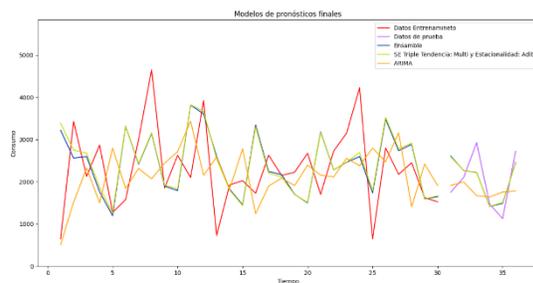


Figura 6. Mejores modelos de pronóstico para el producto “A” con la demanda inicial. Fuente: Elaboración propia.

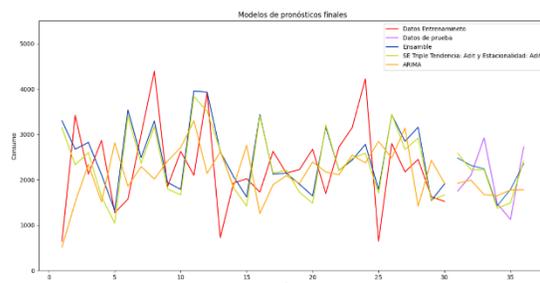


Figura 7. Mejores modelos de pronóstico para el producto “A” con la demanda tratada. Fuente: Elaboración propia.

Para la demanda inicial, los tres mejores modelos fueron ES triple con tendencia multiplicativa y estacionalidad aditiva, ARIMA y el ensamble, mientras que para la demanda tratada fueron la ES triple con tendencia y estacionalidad aditiva, ARIMA y el ensamble. Visualmente, se logra apreciar una diferencia de los ensambles (azul) obtenidos para cada una de las gráficas, evidenciando la distinta calibración de sus parámetros para generar las predicciones en entrenamiento y prueba.

Demanda Inicial								
Prueba								
Modelos	Nombre	Error	EM (ME)	DAM (MAE)	ECM (MSE)	RECM (RMSE)	EPAM (MAPE)	FACC
Series de tiempo	SE Triple Tendencia: Multi y Estacionalidad: Adit	-334,22	-55,70	408,78	245687,03	495,67	21,5%	97,24%
Series de tiempo autorregresivas	ARIMA	1353,88	225,65	543,82	489538,68	699,67	26,5%	111,19%
Ensamble	Ensamble	-352,70	-58,78	403,64	245720,43	495,70	21,2%	97,09%

Tabla 4. Métricas de error en prueba de los mejores modelos para el producto “A” con la demanda inicial. Fuente: Elaboración propia.

Demanda Tratada								
Prueba								
Modelos	Nombre	Error	EM (ME)	DAM (MAE)	ECM (MSE)	RECM (RMSE)	EPAM (MAPE)	FACC
Series de tiempo	SE Triple Tendencia: Adit y Estacionalidad: Adit	-204,03	-34,00	407,23	241748,31	491,68	21,4%	98,31%
Series de tiempo autorregresivas	ARIMA	1305,18	217,53	549,56	491442,10	701,03	27,0%	110,79%
Ensamble	Ensamble	-504,16	-84,03	452,32	271058,90	520,63	25,2%	95,83%

Tabla 5. Métricas de error en prueba de los mejores modelos para el producto “A” con la demanda tratada. Fuente: Elaboración propia.

Como se evidencia en las Tabla 4 y 5 del paso 11, se estableció que el modelo final que generó mejores resultados fue la ES triple aditiva-aditiva con la demanda tratada, con un RMSE de 4 kg menos en comparación con el mejor modelo de la demanda inicial. Para el modelo final del producto “A” se obtuvo una incertidumbre o MAPE del 21.40 % y un FACC del 98.31 %, que generó un 1.69 % de faltantes en promedio. Para finalizar, en el paso 12 se realizaron las predicciones en el horizonte de prueba utilizando el modelo seleccionado.

Al igual que el ejemplo anterior, este procedimiento se efectuó para las 14 referencias establecidas. Como resultados generales, se determinó que 6 de los 14 productos no contienen registros fuera de los bigotes internos del método “Box Plot”, por lo que para los restantes existen posibles datos atípicos, donde la cantidad de datos cambiados fluctuó entre uno y cuatro meses. Las principales razones por las cuales se presentaron estos datos atípicos se resumen en factores externos de los clientes de Insaltec que varían su consumo, como por ejemplo que el consumidor tuvo una oportunidad de negocio para la cual requirió más producto, o que un competidor se desabasteció y recurrieron a la empresa. También, se analizó que para el 37.50 % de los productos, la demanda tratada tuvo un impacto significativo en la calibración de los parámetros de los modelos, puesto que en la selección del método final tuvo un mejor desempeño en comparación con los datos originales, generando un mejor proceso de aprendizaje en entrenamiento. Respecto a los ensambles obtenidos, se pueden observar los resultados en la Tabla 6 con su respectivo peso de generación para cada producto, teniendo presente el escenario de la demanda inicial y la tratada.

Producto	Entrenamiento 30 datos				Demanda Tratada: Ensamble			
	Modelo Individual 1	Modelo Individual 2	Peso Modelo 1	Peso Modelo 2	Modelo Individual 1	Modelo Individual 2	Peso Modelo 1	Peso Modelo 2
A	SE Triple Tendencia: Adit y Estacionalidad: Adit	SE Triple Tendencia: Multi y Estacionalidad: Adit	0,49	0,51	SE Triple Tendencia: Adit y Estacionalidad: Adit	SE Triple Tendencia: Adit y Estacionalidad: Multi	0,51	0,49
B	SE Triple Tendencia: Adit y Estacionalidad: Adit	ARIMA	0,49	0,51	SE Triple Tendencia: Adit y Estacionalidad: Adit	ARIMA	0,49	0,51
C	Promedios Móviles	Auto Regresivo	0,57	0,43	SE Triple Tendencia: Adit y Estacionalidad: Multi	Auto Regresivo	0,50	0,50
D	SE Simple	SE Triple Tendencia: Adit y Estacionalidad: Adit	0,70	0,30	SE Doble Aditiva	SE Triple Tendencia: Adit y Estacionalidad: Adit	0,58	0,42
E	SE Triple Tendencia: Adit y Estacionalidad: Adit	SE Triple Tendencia: Multi y Estacionalidad: Adit	0,57	0,43	ARIMA	ARIMA	0,55	0,45
F	SE Triple Tendencia: Adit y Estacionalidad: Adit	Auto Regresivo	0,63	0,37	SE Doble Aditiva	ARIMA	0,41	0,59
G	SE Doble Aditiva	SE Triple Tendencia: Adit y Estacionalidad: Multi	0,47	0,53	SE Doble Aditiva	SE Triple Tendencia: Adit y Estacionalidad: Multi	0,47	0,53
H	SE Simple	SE Triple Tendencia: Adit y Estacionalidad: Multi	0,60	0,40	SE Triple Tendencia: Adit y Estacionalidad: Multi	Auto Regresivo	0,25	0,75
I	ARIMA	SARIMA	0,50	0,50	ARIMA	SARIMA	0,50	0,50
J	Promedios Móviles	Auto Regresivo	0,46	0,54	Promedios Móviles	Auto Regresivo	0,46	0,54
K	SE Doble Aditiva	SE Doble Multiplicativa	0,53	0,47	SE Doble Aditiva	SE Doble Multiplicativa	0,53	0,47
L	SE Triple Tendencia: Adit y Estacionalidad: Adit	Auto Regresivo	0,57	0,43	SE Triple Tendencia: Adit y Estacionalidad: Multi	Auto Regresivo	0,54	0,46
M	SE Doble Aditiva	SE Triple Tendencia: Multi y Estacionalidad: Adit	0,48	0,52	SE Doble Multiplicativa	SE Triple Tendencia: Multi y Estacionalidad: Adit	0,46	0,54
N	SE Triple Tendencia: Adit y Estacionalidad: Adit	Promedios Móviles	0,52	0,48	SE Triple Tendencia: Adit y Estacionalidad: Adit	Promedios Móviles	0,52	0,48

Tabla 6. Peso de generación para los ensambles finales por producto en demanda inicial y tratada. Fuente: Elaboración propia.

De acuerdo con la tabla anterior, el 35.71 % de las veces se mezclaron métodos exponenciales y autorregresivos, mientras que el 64.29 % de las ocasiones se combinaron modelos de la misma familia. Este último porcentaje esta subdividido acoplando 3 pares de modelos autorregresivos y compaginando 6 pares de modelos de series de tiempo exponenciales para las 9 combinaciones de duplas de métodos entre la misma familia. En general, los modelos de series de tiempo exponenciales fueron más usados en los ensambles que la familia de los autorregresivos para las 14 referencias. Para finalizar, los resultados del modelo final para cada producto son los siguientes:

Prueba Semestral					
Unidad	Modelo Seleccionado	Medidas de desempeño			
Productos	Modelo final	ECM	RMSE	MAPE	FACC
A	SE Triple Tendencia: Adit y Estacionalidad: Adit	241748,31	491,68	21,41%	98,31%
B	Ensamble	274002,05	523,45	33,98%	98,66%
C	Ensamble	70345,02	265,23	No aplica	93,07%
D	Ensamble	2567473824,43	50670,25	26,66%	102,92%
E	SE Triple Tendencia: Adit y Estacionalidad: Adit	15856508,96	3982,02	No aplica	116,64%
F	Ensamble	752219,97	0,11	No aplica	99,48%
G	SE Doble Aditiva	698927,70	836,02	No aplica	-91,89%
H	Ensamble	1112831,24	1054,91	No aplica	73,37%
I	Ensamble	54200826,42	7362,12	46,66%	120,13%
J	Ensamble	212719,87	461,22	75,22%	104,11%
K	SE Doble Multiplicativa	284023,15	532,94	27,11%	116,39%
L	Ensamble	217589,35	466,46	21,50%	98,26%
M	Ensamble	707585,51	841,18	14,64%	101,64%
N	Promedios Móviles	596197,92	772,14	No aplica	103,17%

Tabla 7. Modelos finales por producto. Fuente: Elaboración propia.

De acuerdo con la Tabla 7, el mejor método para predecir en la ventana de prueba fue el ensamble seleccionado en el 64.29 % de los modelos de pronóstico, seguido de las series exponenciales con 28.57 % y por último las autorregresivas con 7.14 %. Respecto a las métricas de error, se obtuvo un promedio del RMSE de 4875.69 kg para todos los productos, al igual que un FACC del 88.16 % haciendo referencia que generalmente se están produciendo más faltantes que sobrantes. Para gestionar la escasez generada en promedio, es recomendable establecer un inventario de seguridad, lo cual se abordará con mayor precisión en el próximo capítulo. Para finalizar, se analizó el MAPE en las distintas referencias encontrando que para 6 de los 14 artículos había valores de la demanda cercanos a cero, haciendo que la métrica de error se dispare. Para el resto de las referencias, se evidenció un MAPE promedio de 33.40 %, con un valor mínimo de 14.64 % y un máximo de 75.22 %, lo que indica que en general hay una alta incertidumbre. Cabe recalcar que los modelos finales cumplieron el criterio del supuesto estadístico de Dickey-Fuller con un 95 % de confianza, concluyendo que no existe tendencia o patrones en los errores en la ventana de prueba para los métodos de pronóstico finales. Para revisar los resultados de los seis pasos de la gestión de demanda para todos los productos consulte el (Anexo #4. Resultados gestión de demanda).

4.4 Gestión del almacenamiento

Tomando las predicciones calculadas en el paso anterior y continuando con la propuesta metodológica, el paso 13 consistió en dividir los pronósticos por producto de acuerdo con el consumo histórico por cliente y establecer los parámetros de entrada. Posteriormente plantear un modelamiento matemático con el objetivo de determinar la asignación de la atención de la demanda pronosticada de cada cliente, ya sea por una bodega o por CD, además de precisar los flujos e inventarios necesarios entre eslabones para suplir los consumos. Para este modelo los siguientes conjuntos fueron planteados:

- K = Bodegas
- L = Clientes
- P = Productos
- T = Tiempo
- C = Ciudades

Respecto a las 30 bodegas de la empresa, estas se pueden agrupar en 5 ciudades dado que cada almacén tiene el mismo costo de almacenamiento por ubicación, es decir, que por facilidad se manejaron 5 bodegas (K) que corresponden a la ciudad en la cual se localizan. Para los 14 productos (P) seleccionados, hay una base de 122 clientes (L) que se ubican en un total de 7 ciudades diferentes. En cuanto al conjunto (C), este se formó mediante la intersección de ciudades en las cuales se localizaban tanto las bodegas como los clientes, resultando 7 en total. El conjunto restante es el del tiempo (T), considerando que se hizo una planeación para los últimos 6 meses del 2019. Se debe aclarar que cada referencia entra por un único puerto en función del país de origen del proveedor, por lo que no es necesario un conjunto de puertos. Los parámetros para el funcionamiento del modelo que se plantearon se encuentran a continuación:

M	= La gran M, un valor muy grande	
$TONaKG$	= Conversión de toneladas a Kg	[Ton/Kg]
CAP	= Capacidad mínima en Kg para transportar el producto al cliente bajo la modalidad de cross-docking, según el criterio de la empresa	[Kg]
HB_k	= Costo de mantener una tonelada de producto en la bodega k	[\$/Ton]
CT_{cs}	= Costo promedio por Kg de transportar desde la ciudad c a la ciudad s ($s \in C$)	[\$/Kg]
CT_{cs}	= Tarifa promedio por Kg de transportar desde la ciudad c a la ciudad s ($s \in C$)	[\$/Kg]
DP_{lpt}	= Demanda pronosticada en Kg del cliente l del producto p en el tiempo t	[Kg]
IIB_{kp}	= Inventario inicial en la bodega k del producto p	[Kg]
γ_{kc}	= [1: Si la bodega k está en la ciudad c, 0: De lo contrario]	
ω_{lc}	= [1: Si el cliente l está en la ciudad c, 0: De lo contrario]	
ISP_p	= Inventario de seguridad en Kg que debe haber cada periodo del producto p	[Kg]

Los parámetros M y $TONaKG$ se agregaron para facilitar el desarrollo del modelo. Referente a CAP , HB_k , CT_{cs} , IIB_{kp} , γ_{kc} y ω_{lc} fueron determinados a partir de los datos proporcionados por la empresa. De igual manera, para la demanda pronosticada (DP_{lpt}) se usaron los registros de ventas del 2017, 2018 y primera mitad del 2019 de Insaltec, para hallar la participación promedio de compra de los clientes para cada uno de los productos, y así dividir porcentualmente las predicciones realizadas en el paso anterior por artículo. Finalmente, el parámetro ISP_p del inventario de seguridad fue hallado empleando las ecuaciones 4, 5 y 6 como se muestra a continuación.

$$\text{Safety stock} = \text{Average period consumption} * \text{replenishment lead time} \quad (4)$$

$$IC_{95\%} = \bar{X} \pm Z_{1-\frac{\alpha}{2}} * \frac{S}{\sqrt{n}} \quad (5)$$

$$\text{Safety stock} = \left(\bar{X} + Z_{1-\frac{\alpha}{2}} * \frac{S}{\sqrt{n}} \right) * \text{replenishment lead time} \quad (6)$$

La ecuación 4 fue usada dado el comportamiento dispar entre las referencias manejadas, utilizando metodologías para el cálculo del inventario de seguridad que no asumen una distribución de probabilidad específica por producto, y así establecer una forma genérica de cómputo del inventario de seguridad para todas las referencias (Rădăşanu, 2016). No obstante, los pronósticos de demanda presentaron una alta incertidumbre que no considera la media en la ecuación 4, por lo que fue utilizada la ecuación 5 donde $IC_{95\%}$ es el intervalo de confianza del 95 %, \bar{X} hace referencia al consumo medio por periodo, Z denota el valor de la distribución normal de dos colas para una significancia de $1 - \frac{\alpha}{2}$, S es la desviación estándar y n el número de observaciones de la media que en este caso era de 30 meses. Es importante mencionar que se asumió una condición de normalidad en el factor de confianza de acuerdo con el teorema del límite central o regla empírica, que establece que una muestra de observaciones superior o igual a 30 datos se puede modelar con una distribución normal (Canal, 2006; Dietrichson, 2019). Con la finalidad de que el inventario de seguridad considerara la incertidumbre generada por la volatilidad de la demanda y por defecto por los pronósticos, se propuso la ecuación 6 donde el inventario de seguridad es el límite superior de la media de consumo con una confianza del 95 % multiplicado por el tiempo de reaprovisionamiento, sin asumir ninguna distribución de probabilidad sobre la demanda y usando una condición de normalidad únicamente para el cálculo del estimador (límite superior del $IC_{95\%}$ del consumo medio por periodo). Los parámetros y conjuntos mencionados fueron alimentados al modelo mediante archivos “.csv” que se encuentran en (Anexo #6. Código Gusek). En el paso 14, fueron determinadas las siguientes variables de decisión:

X_{kpt}	= Cantidad en Kg que se envía del puerto de entrada del producto p a la bodega k en el tiempo t para atender la demanda de los clientes	[Kg]
IX_{kpt}	= Inventario en Kg del producto p que debe existir en la bodega k en el tiempo t	[Kg]
α_{lpt}	= [1 Si el producto p es enviado del puerto al cliente l por cross-docking en el periodo t, 0: De lo	

contrario]

β_{klpt} = [1 Si el producto p es enviado de la bodega k al cliente l en el periodo t, 0: De lo contrario]

Y_{lpt} = Variable auxiliar que determina la cantidad en kg del producto p que se envía por cross-docking desde el puerto al cliente l en el tiempo t [Kg]

POR_{kp} = Variable auxiliar que determina el porcentaje promedio del producto p que debe haber en la bodega k en el horizonte de planeación [%]

IS_{kp} = Variable auxiliar que determina el inventario de seguridad en Kg que debe haber en la bodega k del producto p en el horizonte de planeación [Kg]

Donde las variables X_{kpt} e IX_{kpt} muestran el flujo de producto en el eslabón de las bodegas y las unidades a almacenar respectivamente y las variables α_{lpt} y β_{klpt} determinan si el cliente es atendido por una bodega o por CD cada una. Las demás variables son auxiliares para saber las cantidades enviadas a los clientes por CD (Y_{lpt}), la división porcentual del inventario de seguridad por producto y por bodega (POR_{kp}), y el inventario de seguridad en kg en cada bodega de cada producto (IS_{kp}). Definiendo todo lo anterior se puede realizar un modelamiento matemático donde, como paso 15 se estableció la función objetivo y las restricciones de la empresa, mostradas en las siguientes ecuaciones:

$$Min Z = \sum_{\substack{\forall p \\ \forall t}} \sum_{\forall k} IX_{kpt} * HB_k * TONaKg + \sum_{\substack{\forall k \\ \forall l \\ \forall p \\ \forall t \\ \forall c \\ \forall s \in C}} \beta_{klpt} * DP_{lpt} * CT_{cs} * \gamma_{kc} * \omega_{ls} \quad (7)$$

$$\alpha_{lpt} * CAP \leq DP_{lpt} \quad \forall l \forall p \forall t \quad (8)$$

$$DP_{lpt} \leq CAP + \alpha_{lpt} * M \quad \forall l \forall p \forall t \quad (9)$$

$$\alpha_{lpt} + \sum_{\forall k} \beta_{klpt} = 1 \quad \forall l \forall p \forall t \quad (10)$$

$$IIB_{kp} + X_{kpt} - (\sum_{\forall l} \beta_{klpt} * DP_{lpt}) = IX_{kpt} \quad \forall k \forall p \forall t |_{t=1} \quad (11)$$

$$IX_{kp(t-1)} + X_{kpt} - (\sum_{\forall l} \beta_{klpt} * DP_{lpt}) = IX_{kpt} \quad \forall k \forall p \forall t |_{t>1} \quad (12)$$

$$\sum_{\forall l} DP_{lpt} * \beta_{klpt} \leq X_{kpt} \quad \forall k \forall p \forall t \quad (13)$$

$$Y_{lpt} = DP_{lpt} * \alpha_{lpt} \quad \forall l \forall p \forall t \quad (14)$$

$$POR_{kp} = \frac{\sum_{\forall t} X_{kpt}}{\sum_{\forall u \in T} DP_{lpu}} \quad \forall k \forall p \quad (15)$$

$$IS_{kp} = POR_{kp} * ISP_p \quad \forall k \forall p \quad (16)$$

$$IX_{kpt} \geq IS_{kp} \quad \forall k \forall p \forall t \quad (17)$$

$$X_{kpt} \geq 0 \quad \forall k \forall p \forall t \quad (18)$$

$$IX_{kpt} \geq 0 \quad \forall k \forall p \forall t \quad (19)$$

$$Y_{lpt} \geq 0 \quad \forall l \forall p \forall t \quad (20)$$

$$POR_{kp} \geq 0 \quad \forall k \forall p \quad (21)$$

$$IS_{kp} \geq 0 \quad \forall k \forall p \quad (22)$$

La ecuación 7 es la función objetivo que tiene en cuenta, por un lado, los costos de almacenamiento del inventario de seguridad en las bodegas, considerando que el costo de mantener es por posición, es decir por tonelada, por lo que se hizo la respectiva conversión de unidades. Por otro, la función objetivo también incluye los costos de transportar la demanda de cada cliente desde la bodega a la que fue asignado, relacionando las ciudades de origen y destino mediante los parámetros binarios para conocer la tarifa de transporte entre las ciudades respectiva. En las ecuaciones 8 y 9, se modela la política de envío de la empresa donde, si un cliente pide más de la cantidad CAP de un producto en un determinado periodo, será atendido directamente por CD desde el puerto de acopio de dicho artículo y mediante el tipo de transporte de mayor capacidad. En el mismo

orden de ideas, si el pedido de un producto de un cliente en un periodo no es atendido por CD, por complemento, debe ser atendido por una única bodega y en todo caso se debe garantizar que el cliente sea atendido como se ve en la ecuación 10.

Posteriormente, el control del inventario de seguridad entre periodos para cada bodega de los diferentes productos es acotado en las ecuaciones 11 y 12, donde primero se inicializa la restricción de inventarios y luego se realiza el control de estos para los demás periodos. Otro elemento importante es el cumplimiento de la demanda pronosticada de cada cliente, para la cual hay dos modalidades. La primera se ilustra en la ecuación 13, donde a cada bodega debe llegar del puerto, en cada periodo y para cada producto, la cantidad suficiente para atender a los clientes que fueron asignados. La segunda, es que la orden de producto del cliente sea atendida por CD en determinado periodo (Ecuación 14).

La ecuación 15 permite dividir porcentualmente la participación por bodega según lo que se envía desde el puerto con respecto a la demanda total de cada producto, y de esta manera hallar la proporción en kg de inventario de seguridad de cada producto en las diferentes bodegas como se muestra en la ecuación 16. Para lo anterior, es necesario garantizar que el inventario de seguridad esté disponible en cada bodega, para todos los productos y a lo largo del horizonte de planeación como lo hace la ecuación 17. Finalmente, se deben considerar las restricciones de no negatividad de las variables de decisión de manera que no puedan tomar valores por debajo de cero, como se observa en las ecuaciones 18, 19, 20, 21 y 22.

El modelo matemático se encuentra en el (Anexo #6. Código Gusek) como archivo “.mod”. Este generó como resultados principales la asignación de atención de los clientes por medio de dos formas. Una es el binario por producto y por periodo de qué clientes son atendidos por CD (α_{lpt}) y qué cantidad se le envía (Y_{lpt}). La otra es el complemento de los clientes que son atendidos por una bodega mediante un binario que establece la asignación (β_{klpt}), determinando lo que se pide al puerto para cumplir la demanda de los clientes (X_{kpt}) teniendo en cuenta un inventario mínimo (IX_{kpt}). Estos resultados conforman el paso 16, y pueden ser consultados en el (Anexo #7. Resultados gestión del almacenamiento).

Analizando los resultados obtenidos, se estudiaron varios aspectos relevantes. Uno de ellos es que solo tres clientes fueron atendidos por CD demandando el mismo producto (“D”) en algunos periodos, por lo que se puede determinar que es el producto con mayor demanda. Seguidamente y para corroborar lo anterior, en el análisis de las bodegas se observó que el producto “D” representaba el 57.32 % del flujo. Los siguientes productos más significativos son el “I” y el “F” con una participación del 10.20 % y 9.42 % para cada uno. En contraparte, los productos “C”, “G” y “N” son los de menor participación con una implicación del 0.48 %, 0.91 % y 0.96 % respectivamente. A continuación, se examinó que la bodega más utilizada es el mismo centro de operaciones de la empresa, es decir Medellín, con un 47.57 % de utilización, seguida de Bogotá (26.61 %), Cali (15.43 %) y Cartagena (10.39 %). En cuanto a la bodega de Barranquilla, ningún cliente fue asignado y por consiguiente no hay flujos de producto en esta. Esto se debe a que es más rentable almacenar y despachar producto desde la bodega de Cartagena, principalmente porque su costo de almacenar es un 53.13 % menor. Para los productos Pareto seleccionados, la bodega de Barranquilla no es significativa, sin embargo, lo es para algunos de los 199 productos que no se tienen en cuenta en esta investigación (García, 2021).

4.5 Gestión de política de inventario

En cuanto al paso 17 de la propuesta metodológica, se establecieron los parámetros de entrada de la matriz DRP, a partir de los resultados del capítulo anterior. El primer parámetro de entrada es el RB que representó el flujo de unidades que salieron del puerto hacia las bodegas, entre los meses de julio a diciembre del 2019, es decir, que la variable de decisión X_{kpt} del modelo de optimización se transformó en el RB. El segundo es la RP que son las órdenes de pedido previstas anteriormente por la empresa antes de realizar el algoritmo, que para esta investigación no se tuvo en consideración. En tercer lugar, está el Inventario de Seguridad, manejado con el nombre ss en las matrices, que sirve para amortiguar la incertidumbre de la demanda y que se relaciona con la variable de decisión de inventarios IX_{kpt} . Como cuarto parámetro se encuentra el INVH que mide la cantidad de producto almacenado al final de cada periodo. El quinto y último es el RN que se obtiene a partir de los parámetros mencionados previamente y se calcula así: $RN_t = RB_t + ss_t - INVH_{t-1} - RP_t$, donde t indica

cada periodo del horizonte de planeación (Magdalena y Suli, 2019; Ngatilah et al., 2020). Utilizando este último parámetro, debe aplicarse una política de inventarios para cada producto que determine la frecuencia y cantidades a pedir al proveedor necesaria para abastecer la demanda de los clientes.

La política WW es un modelo determinístico de inventarios para demanda independiente que optimiza los costos de mantener y ordenar, y que fue usado en esta investigación. No obstante, como paso 18, antes de poder aplicar el algoritmo se debió realizar una prueba de independencia entre las demandas de cada par de productos para comprobar dicho supuesto. Para esto, se realizaron dos pruebas de independencia nombradas correlación de distancias y el coeficiente de Spearman, con el propósito de corroborar que la demanda de cada producto seleccionado anteriormente en el Pareto no tuviera una correlación estadística respecto a las demás como se muestra en la siguiente hipótesis.

$H_0 =$ La demanda del producto i es independiente del producto j

$H_1 =$ La demanda del producto i es dependiente del producto j

Donde i y j son un par de productos de los 14 seleccionados evaluando todas las combinaciones. Por un lado, para analizar los resultados de la prueba de correlación de distancias se debe tener en cuenta que el valor de cero indica una independencia perfecta entre las variables, y uno lo contrario (Pazos, 2018). Por el otro, el coeficiente de Spearman se calculó con un nivel de significancia del 5 % dándole un soporte estadístico al criterio anterior. Cabe aclarar que ambas pruebas pueden comparar variables que no sigan distribuciones normales y detectan relaciones lineales o no lineales (Lin, Cai, Liu, Puppala y Haifeng, 2017). Como resultados de ambas pruebas, obtuvimos que la independencia entre las demandas de los productos del Pareto prevalece en la mayoría de las 91 combinaciones posibles. Para la prueba de correlación de distancias, se consiguió que el 78.02 % de los emparejamientos entre pares de referencias fueran independientes entre sí, mientras que para el coeficiente de Spearman se obtuvo el 90.11 % con un nivel de confianza del 95 %.

Una vez comprobados los supuestos estadísticos, se procedió al paso 19 que define los datos necesarios para aplicar la política WW, la cual necesita de los costos logísticos de pedir, mantener y unitario, además del RN de cada eslabón por periodo determinados por el método DRP. Para este caso de estudio, los costos unitarios varían de acuerdo con cada producto, el costo de ordenar es de \$93.600 COP para el proveedor y de \$50.000 COP para el puerto, siendo estos constantes para el horizonte de planeación debido a que tienen el mismo proceso de generación de compra con los mismos cargos involucrados. Por último, el costo de mantener cambia dependiendo si el producto se almacena en el puerto o en alguna bodega, pero es constante a través del tiempo.

Como paso 20 se realizó el algoritmo WW, comenzando con la lectura de los parámetros de entrada anteriormente mencionados que se encuentran consignados en el (Anexo #5. Código Python), luego se construyó una matriz de costos a partir de todas las combinaciones de pedidos que se pueden presentar para el horizonte de planeación, teniendo como resultados un total de 21 posibles alternativas. Finalmente, para el paso 21 se implementó programación dinámica con el propósito de determinar la frecuencia de pedido óptima entre periodos de las combinaciones anteriormente encontradas. Como resultado de este algoritmo, también se determinaron dos elementos más de la matriz DRP. El primero es la ROP, que es la cantidad de producto que se espera recibir en el periodo t . El otro es la LOP, que es la programación del pedido teniendo en cuenta el tiempo de demora (lead time) de llegada de las órdenes desde el proveedor hasta el periodo de la ROP, es decir en el periodo $t-\tau$, donde τ son los periodos que toma el reaprovisionamiento.

Para comprender los pasos mencionados (del 17 al 21 de la propuesta metodológica), se mostrarán a continuación los resultados obtenidos mediante algoritmo WW para el producto “D” en el horizonte de planeación, y a su vez las matrices DRP correspondientes a los eslabones de las bodegas y el puerto. Para más información del resultado obtenido para cada producto, puede consultar en el (Anexo #8. Resultados gestión de políticas de inventario). Esta referencia fue elegida debido a que se realizaron despachos por CD y también por bodegas para cumplir las órdenes de compra de los clientes, permitiendo evidenciar amabas rutas de atención. Las matrices DRP de las bodegas resultantes para este artículo son las siguientes:

BODEGA BOGOTÁ							BODEGA CARTAGENA					
	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre
RB Clientes	12541,54	12635,65	13117,94	13212,05	13694,33	13788,45	16820,77	16947,00	0,00	0,00	0,00	0,00
RP	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
ss	5957,70	5957,70	5957,70	5957,70	5957,70	5957,70	2546,88	2546,88	2546,88	2546,88	2546,88	2546,88
INVH	5957,70	5957,70	5957,70	5957,70	5957,70	5957,70	2546,88	2546,88	2546,88	2546,88	2546,88	2546,88
RN	18499,24	12635,65	13117,94	13212,05	13694,33	13788,45	19367,65	16947,00	0,00	0,00	0,00	0,00
ROP	18499,24	12635,65	13117,94	13212,05	13694,33	13788,45	19367,65	16947,00	0,00	0,00	0,00	0,00
LOP	18499,24	12635,65	13117,94	13212,05	13694,33	13788,45	19367,65	16947,00	0,00	0,00	0,00	0,00

BODEGA CALI							BODEGA MEDELLÍN					
	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre
RB Clientes	1058,70	1066,65	1107,36	1115,30	1156,02	1163,95	24427,88	24611,21	25550,55	25733,88	26673,19	26856,51
RP	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
ss	502,92	502,92	502,92	502,92	502,92	502,92	11604,15	11604,15	11604,15	11604,15	11604,15	11604,15
INVH	502,92	502,92	502,92	502,92	502,92	502,92	11604,15	11604,15	11604,15	11604,15	11604,15	11604,15
RN	1561,62	1066,65	1107,36	1115,30	1156,02	1163,95	36032,03	24611,21	25550,55	25733,88	26673,19	26856,51
ROP	2628,27	0,00	2222,66	0,00	2319,97	0,00	36032,03	24611,21	25550,55	25733,88	26673,19	26856,51
LOP	2628,27	0,00	2222,66	0,00	2319,97	0,00	36032,03	24611,21	25550,55	25733,88	26673,19	26856,51

Tabla 8. Matriz DRP de las bodegas para el producto “D”. Fuente: Elaboración propia.

De acuerdo con la Tabla 8, el producto “D” se encuentra en las principales bodegas del país sin tener en cuenta la de Barranquilla, debido a que esta no almacena ninguno de los 14 productos que se tomaron en cuenta para esta investigación, como lo determinó el modelo de optimización en el capítulo anterior. Analizando las bodegas de Bogotá, Cartagena y Medellín, se realizan pedidos al puerto de manera mensual, mientras que la bodega de Cali generó pedidos de forma bimestral. Así mismo, el LOP es igual al ROP dado que el transporte de unidades de manera nacional no toma más de 3 días, y como se manejó el tiempo de reaprovisionamiento (lead time) en meses, se asumió que el ROP llega el mismo mes en el que se coloca la orden (LOP). La matriz DRP del puerto para la referencia “D” se observa a continuación:

PUERTO												
2019												
	Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre
RB Total Bodegas							76527,20	54193,86	40891,15	38945,93	42687,49	40644,96
RB Cross Docking							98414,86	99153,40	120531,67	121396,44	125827,70	126692,47
RP							0,00	0,00	0,00	0,00	0,00	0,00
ss Cross Docking							0,00	0,00	0,00	0,00	0,00	0,00
INVH							0,00	0,00	0,00	0,00	0,00	0,00
RN							174942,06	153347,26	161422,82	160342,37	168515,19	167337,43
ROP							174942,06	153347,26	161422,82	160342,37	168515,19	167337,43
LOP							174942,06	153347,26	161422,82	160342,37	168515,19	167337,43

Tabla 9. Matriz DRP del puerto para el producto “D”. Fuente: Elaboración propia.

En la Tabla 9 se evidencia que los puertos tienen dos tipos de RB a diferencia de la tabla anterior, los pedidos de las bodegas y la demanda que se despacha directamente al cliente por CD. El “RB Total Bodegas” se determina sumando los LOP necesarios para atender a las bodegas en el respectivo mes que solicitan el producto “D” al puerto. Mientras que el “RB Cross Docking” fue determinado por el modelo de optimización según el criterio de la empresa para abastecer al consumidor por CD, descrito por la variable auxiliar Y_{lpt} . Finalmente, las órdenes de pedido de la referencia que se producen por parte del puerto al proveedor se generan de manera mensual, teniendo en cuenta que el LOP se programa con un mes de anterioridad, ya que este es el tiempo de reaprovisionamiento (lead time) para esta referencia de acuerdo con el proveedor.

Al correr el algoritmo de manera general para determinar la frecuencia y cantidad de pedido para todos los productos en el horizonte de planeación, se observó que las bodegas de Bogotá, Cali, Cartagena y Medellín para cada referencia realizaron diferentes cantidades de pedidos, con LOP de compra en diferentes periodicidades. También, para las bodegas que pidieron de manera semestral, es decir, que sólo realizaron un pedido para todo el horizonte de planeación, se presentó porque las cantidades en kg que demandaban dichos almacenes eran bajas salvo el producto “G” que realizó una orden de 8.33 toneladas. Por otro lado, Medellín fue la bodega que almacenó la mayor variedad de productos para los seis meses proyectados, con un total de diez referencias de las catorce seleccionadas. En cambio, para el eslabón de puertos, la mayor frecuencia de pedido que se presentó para cada producto fue de manera bimestral. Es importante mencionar que el único producto que se despacha por CD es el “D” determinado en el capítulo anterior.

Una vez establecida la política de inventarios, se procedió con el paso 22 de la metodología, para determinar los costos de transporte terrestre que se dividen entre paquetero o por vehículo consolidado, desde puerto a cliente, puerto a bodega y bodega a cliente. Por un lado, el paquetero consiste en enviar cantidades pequeñas cuando la demanda de un cliente o bodega no es significativamente grande, es decir, se pueden agrupar varios productos en un mismo camión, donde el operador logístico se encarga de ese aspecto y cobra una tarifa por kg de acuerdo con el origen y destino. Se estableció empíricamente que el criterio para elegir esta modalidad es cuando la demanda no supera las 3 toneladas, que representa el 67 % del camión de menor capacidad. Por el otro, los envíos consolidados se hacen mediante cuatro vehículos que son mula, patineta, sencillo y turbo, cada uno con capacidades de 33, 17, 8.5 y 4.5 toneladas respectivamente, donde se paga el costo de alquilar el vehículo completo en función del origen y el destino. Por ende, se realizó un algoritmo que minimice los costos de transporte, y que se encuentra en el (Anexo #8. Resultados gestión de políticas de inventario). Los principales resultados se muestran a continuación:

Costo total de transporte	Costos por producto		Uso de vehículos			Valor de mercancía por medio de transporte	
	Producto	Costo				Vehículo	Capacidad (kg)
	A	\$ 8.185.785	MULA	33000	47	Consolidado	\$ 251.640.000
	B	\$ 1.525.759	PATINETA	17000	6	Paquetero	\$ 7.756.751
	C	\$ 514.436	SENCILLO	8500	40		
	D	\$ 173.691.837	TURBO	4500	20		
	E	\$ 11.491.791					
	F	\$ 13.555.381					
	G	\$ 2.146.667					
	H	\$ 2.141.696					
	I	\$ 27.856.517					
	J	\$ 2.133.750					
	K	\$ 1.350.155					
L	\$ 1.494.288						
M	\$ 11.986.809						
N	\$ 1.321.881						

Tabla 10. Costo de transporte de la propuesta. Fuente: Elaboración propia.

Analizando las dos modalidades de transporte mencionadas, como se logra apreciar en la Tabla 10, respecto al paquetero se tuvo un costo total de \$7.756.751 COP para el horizonte de planeación, donde el 81.48 % es generando por el envío de bodegas a cliente, el 18.52 % es el transporte de puerto a bodegas y de puerto a cliente no hay despachos dado que solo se utiliza la modalidad de CD mediante mulas. Para los costos consolidados se obtuvo un valor de \$ 251.640.000 COP, donde el 6.81% proviene de bodegas a cliente utilizando 35 vehículos sencillos durante los 6 meses, el 47.93 % se deriva de bodegas a clientes percibiendo que los medios de transporte más utilizados son las mulas (19 vehículos) y turbos (17 vehículos) para el horizonte de planeación. Finalmente, el 45.26 % es de puerto a cliente, donde por reglas de negocio se utiliza solo la mula para un total de 28 camiones de este tipo, en este caso para un único producto que es el "D". Para entrar más en detalle de los resultados se puede consultar el (Anexo #9. Costos Transporte).

4.6 Medición de desempeño

Una vez determinados todos los costos logísticos se procedió al paso 23 que consiste en comparar la propuesta metodológica con el procedimiento actual de Insaltec. Se debe considerar que para esta investigación no se consideraron los costos por faltantes dado que estos surgen a partir de factores exógenos, por lo que los costos de no cumplir la demanda y de transporte aéreo no fueron tenidos en cuenta. Por lo tanto, para el computo de los costos logísticos totales se consideraron los costos de pedir, de mantener en inventario y el costo de transporte para cada referencia, como se muestra a continuación:

Producto	Costo total logístico de la propuesta	Costo total logístico de Insaltec	Comparativa		
			Reducción	Aumento	
A	\$ 10.486.581	\$ 7.932.026	\$ -	\$ 2.554.554	↑
B	\$ 3.022.917	\$ 2.463.523	\$ -	\$ 559.393	↑
C	\$ 1.134.094	\$ 1.501.679	\$ 367.586	\$ -	↓
D	\$ 178.566.029	\$ 220.004.487	\$ 41.438.458	\$ -	↓
E	\$ 15.646.273	\$ 11.143.405	\$ -	\$ 4.502.868	↑
F	\$ 18.728.628	\$ 19.783.530	\$ 1.054.902	\$ -	↓
G	\$ 3.492.438	\$ 4.421.700	\$ 929.262	\$ -	↓
H	\$ 3.580.461	\$ 3.682.681	\$ 102.220	\$ -	↓
I	\$ 34.326.382	\$ 33.309.066	\$ -	\$ 1.017.316	↑
J	\$ 3.742.393	\$ 5.273.831	\$ 1.531.438	\$ -	↓
K	\$ 2.428.359	\$ 2.475.203	\$ 46.843	\$ -	↓
L	\$ 2.639.175	\$ 2.249.899	\$ -	\$ 389.276	↑
M	\$ 17.541.465	\$ 13.864.888	\$ -	\$ 3.676.577	↑
N	\$ 2.465.766	\$ 2.839.245	\$ 373.479	\$ -	↓
Total	\$ 297.800.961	\$ 330.945.164	\$ 45.844.188	\$ 12.699.984	

Tabla 11. Comparación de costos logísticos entre la propuesta y la empresa. Fuente: Elaboración propia.

Observando la Tabla 11 se muestran los costos logísticos tanto de la propuesta metodológica, como los de la empresa para cada producto. En la parte de comparativa, se puede ver en la columna de reducción el costo que se disminuyó para las referencias donde la propuesta fue mejor, y en la columna de aumento el desfase de la propuesta respecto a los costos de la empresa que fueron mejores. En general, en 8 de las 14 referencias se logró reducir el costo y el balance resulta en un ahorro de \$33.144.203 COP al cruzar las reducciones y aumentos generados. En definitiva, la propuesta permitió reducir los costos logísticos de la empresa en un 10.02 %.

Una vez finalizado el proceso y análisis de cada capítulo de la metodología, se utilizó la estrategia de referencia a nivel mundial de operaciones de la cadena de suministro SCOR, que vincula procesos de negocio, indicadores de desempeño (*Key Performance Indicator - KPI*), prácticas y talento humano en la versión número 12 de la norma. Ésta explica las actividades de negocio que permiten satisfacer la demanda de los clientes con 5 indicadores de desempeño que son: confiabilidad, capacidad de respuesta, agilidad, costos e inversiones (SCOR, 2017). Para entrar en más detalle del significado de los indicadores seleccionados, puede dirigirse a la sección de normas y estándares del componente de diseño.

Para el cálculo de cada indicador, es importante mencionar que la información suministrada por parte de la empresa limitó de forma directa la medición de estos, considerando solamente los eslabones de bodegas y clientes. También, el producto “G” se discontinuó para principios del año 2020, por lo que su consumo se vio afectado de forma considerable disminuyendo las cantidades vendidas para los últimos periodos del año 2019. Sin embargo, este producto se tuvo en cuenta dentro de la investigación debido a que era la referencia más vendida de ese entonces y representaba el 15.63 % de las ventas totales de la empresa, lo que generó afectaciones en algunos indicadores de desempeño para la metodología.

El primer indicador es el de precisión de pronósticos (*RL.3.37 Forecast Accuracy*), que evalúa el desempeño de los modelos de pronóstico propuestos en la ventana de prueba y los aplicados actualmente por la empresa. Para la medición de este indicador en la metodología, se seleccionó uno de los errores calculados en el capítulo de gestión de demanda llamado MAPE, el cual mide el nivel de incertidumbre entre las predicciones y los datos de prueba. Sin embargo, el problema del MAPE es que su valor se dispara cuando la demanda de los productos es cercana a cero como se evidenció en el capítulo de gestión de demanda. Por lo tanto, para cuantificar el nivel promedio de precisión de los pronósticos propuestos, se sustrajeron los productos que tenían este comportamiento, teniendo como resultado un nivel de exactitud del 74.12 % para la metodología propuesta y entre el 65 % y 69.47 % para la empresa. También se comprobó otra alternativa para el cálculo del MAPE, en donde se consideraron las demandas de todos los productos salvo aquellas que se encontraron por debajo de un mínimo de 230 kg establecido arbitrariamente, obteniendo así un nivel de precisión medio del 71.12 % para los modelos finales obtenidos.

Otro indicador es el porcentaje de pedidos entregados en su totalidad (RL.2.1 % of *Orders Delivered In Full*), el cual se calcula mediante la división del número de órdenes de compra entregadas en su totalidad al cliente sobre el total de ordenes existentes. Para el horizonte de planeación, la propuesta obtuvo un valor de 95.13 % en comparación con Insaltec con un 92.99 %, generando un aumento del 2.14 % en el indicador. Esto tiene un impacto de forma directa en el desempeño del servicio al cliente, ya que al aumentar esta métrica se puede satisfacer las órdenes de compra en su totalidad de los consumidores, exceptuando un 4.87 % de los casos. Obviando el producto “G” por su comportamiento inusual, el indicador podría aumentar en un 4.33 % respecto a la compañía, llegando a ser de 97.32 %.

El porcentaje de producto transferido a tiempo según el requisito de demanda (RL.3.25 % *Product Transferred On-Time to Demand Requirement*), se computa con base en el número de periodos en los que no hubo faltantes dividido el total de pedidos en ese tiempo, también conocido como el nivel de servicio tipo 1 (α). Este KPI, tiene una interpretación para tomar decisiones estratégicas que benefician los procesos internos de la empresa respecto a los sistemas logísticos, ya que determina la disponibilidad de los productos por periodo en cada eslabón de la cadena de suministro. La propuesta efectuada logró un 93.46 % con una mejoría del 0.47 % respecto a Insaltec. Así mismo, de no considerar el anómalo producto “G”, el indicador obtendría un valor de 96.04 %, un 3.05 % mejor respecto a la organización.

El siguiente indicador es para identificar y medir los activos que tiene la empresa, expresado como la cantidad de inventario en días de ventas (AM.2.2 *Inventory Days of Supply*). Esto quiere decir que, si la compañía vendió 20 kg de un producto en un día y le quedaron 100 kg en inventario, los días que Insaltec dispone para seguir teniendo ventas de esa referencia son 5. Respecto a los resultados, en promedio el indicador fue de 110.78 días para la propuesta sin tener en cuenta el producto “G”, mientras que para la empresa dio de 80.03 días para los productos sobre los cuales había datos, siendo 30.75 días mayor con la metodología. Con esta diferencia de 1 mes más, la liquidez de la empresa se afecta al incurrir en mayores gastos de almacenamiento, pero a cambio tendrá más inventarios para responder a picos de consumo mejorando los indicadores de cumplimiento de la demanda.

Por último, uno de los indicadores más utilizados por las empresas para medir el cumplimiento de las órdenes de pedido es el nivel de servicio (RL.3.36 *Fill Rate*). El indicador usado fue el de tipo 2 (β), el cual mide la proporción de órdenes de compra atendidas de manera inmediata con las existencias en inventario de la empresa para cada periodo del horizonte de planeación. Para ello, se identificó el número de clientes que cada bodega atiende por mes, comprobando si el ROP de todos los almacenes para cada producto cubre la demanda total del periodo inmediato o no. De acuerdo con la demanda real de cada referencia para el último semestre del 2019, la empresa obtuvo el 92.99 % de pedidos entregados de forma completa mientras que, a partir de la política de inventarios previamente definida, se obtuvo el 94.15 % de despachos efectuados, teniendo una mejoría del 1.16 % frente al procedimiento actual. No obstante, si no se considera el producto “G”, el indicador podría llegar a ser de 96.78 %, superando el de Insaltec en un 3.79 %. Los resultados de los indicadores SCOR y la comparativa con la empresa se encuentran en (Anexo #10. Resultados indicadores SCOR).

5. Componente de Diseño en ingeniería

5.1 Declaración de diseño

Diseño de un sistema de pronósticos entre series de tiempo, autorregresivos y ensamble de estos modelos que genere mayor precisión frente al sistema actual, luego establecer la asignación de bodegas y puertos para cada cliente por periodo, para finalmente establecer la política de inventarios óptima que abastezca las predicciones de consumo.

5.2 Proceso de Diseño

Para la propuesta metodológica se utilizaron tres recursos tecnológicos. El primero es Excel, debido a que en este momento Insaltec maneja todos los datos relevantes mediante este aplicativo para el cálculo actual de sus ventas, manejo de inventarios, control financiero y requerimientos de producción. El segundo es Python,

un lenguaje de programación libre apto para todo público de forma gratuita, altamente utilizado, puesto que cuenta con un lenguaje flexible orientando a un objetivo multipropósito de código abierto, y es compatible con distintos sistemas operativos como son Linux, Windows y Mac. Además, cuenta con librerías y paquetes para la realización de modelos de pronósticos, gráficas, heurísticas, interfaces gráficas, entre otros. El tercero es Gusek, este es un aplicativo de código cerrado utilizado para resolver problemas de programación lineal mediante conjuntos, parámetros, restricciones, variables de decisión y una función objetivo que busca la solución óptima del problema. Por un lado, para la gestión de demanda y la gestión de políticas de inventarios se empleó Excel y Python, por el otro, para la gestión de almacenamiento se usó Excel y Gusek como se evidenciaron en los anexos enunciados durante el desarrollo de la metodología.

5.3 Requerimientos de desempeño

- El modelo de pronósticos tendrá mayor precisión respecto a los que tiene actualmente la compañía.
- El modelo de pronósticos permitirá estimar la demanda para el horizonte de planeación bajo condiciones normales.
- El modelo de optimización le asignará a cada bodega la cantidad de clientes que debe atender por periodo.
- El modelo de optimización decidirá qué productos almacenar y qué artículos enviar directamente al cliente por periodo.
- El modelo de optimización disminuirá el número de faltantes y sobrantes por medio del inventario de seguridad.
- La política de inventarios WW decidirá la cantidad y frecuencia de pedido por bodega y por puerto, para cada producto
- La política de inventarios WW optimizará los costos de pedir y de mantener.
- La matriz DRP evidenciará los resultados de la gestión de inventarios para el horizonte de planeación.
- La metodología reducirá los costos logísticos actuales de la empresa.

5.4 Pruebas de rendimiento

Para la gestión de demanda se tomó en cuenta el análisis de los resultados de los pronósticos con los datos suministrados por la empresa, efectuando un tratamiento de posibles valores atípicos en los registros históricos para cada producto. En cuanto al aumento en los indicadores de atención al cliente, el modelo de optimización consideró un inventario de seguridad para cada producto, que se ajustó al consumo histórico de sus clientes y permitió realizar la asignación óptima de los clientes. Por último, se analizó el comportamiento de la política de inventarios para optimizar los costos de pedir y de mantener en el horizonte de planeación, se calcularon los costos de transporte y finalmente se contrastaron los costos logísticos totales de la propuesta respecto al modelo actual de la empresa.

5.5 Restricciones de diseño

Las restricciones que limitan el alcance del proyecto son las siguientes:

- La difícil accesibilidad a la información de las sedes de la empresa en otros países hace que el enfoque sea solo en la sucursal en Colombia.
- No se tendrán en cuenta los procesos productivos de la empresa, pues la orientación principal de la compañía es la importación y comercialización de sus productos.
- Esta investigación se coarta de situaciones atípicas y factores externos. Es decir, que no se tuvo en cuenta el año 2020 por la pandemia generada por el COVID-19 y solo se consideraron datos históricos bajo condiciones normales. Así mismo, no se tendrá en cuenta los escenarios de faltantes, específicamente lo referido a sobrecostos generados por servicios aéreos, ya que suceden por situaciones exógenas.
- La escasa exactitud de la información por parte de Insaltec limita la precisión de los modelos propuestos, afectando los posibles resultados obtenidos, especialmente el registro de la demanda y los costos de transporte.

5.6 Normas y estándares

La normativa SCOR se subdivide en las siguientes 6 etapas:

1) Planear (sP): La implementación de medidas correctivas y estrategias que determinen los recursos necesarios para lograr los objetivos de la cadena de suministros.

2) Abastecer (sS): Son las actividades relacionadas con el pedido, entrega, recepción y transferencia de materias primas, productos y/o servicios.

3) Producir (sM): Consiste en la transformación de productos y/o servicios por medio de la creación o fabricación, generando un valor agregado.

4) Entregar (sD): Las actividades relacionadas con la entrega, gestión y cumplimiento de órdenes, de acuerdo con los pedidos de los consumidores.

5) Devoluciones (sR): Procesos para abordar los defectos de productos y/o servicios para efectuar un mantenimiento o reparación, y que van del consumidor final en sentido contrario a la cadena de suministros.

6) Habilitar (sE): Monitorear y administrar el desempeño general de la cadena de suministros respecto como flujo de información, relaciones, recursos, activos, mantenimiento, reglas comerciales, cumplimiento, entre otros.

Esta norma tiene diferentes enfoques para medir procesos efectuados por las distintas organizaciones, pero para este proyecto se destacaron los siguientes enfoques:

- Planear entregas (sP4 *Plan Deliver*), haciendo énfasis en la actividad de identificar, priorizar y agregar requisitos de entrega (sP4.1 *Identify, Prioritize and Aggregate Delivery Requirements*) con la métrica de precisión de pronósticos (RL.3.37 *Forecast Accuracy*) (SCOR, 2017).
- Abastecerse para almacenar producto (sS1 *Source Stocked Product*), específicamente en la transferencia de referencias (sS1.4 *Transfer Product*) con las métricas de: porcentaje de producto transferido a tiempo según el requisito de demanda (RL.3.25 *% Product Transferred On-Time to Demand Requirement*) y días de suministro de inventario (AM.2.2 *Inventory Days of Supply*) (SCOR, 2017).
- Entrega de producto almacenado (SD1 *Deliver Stocked Product*). Se hará énfasis exclusivamente en el inciso de reserva de inventario y determinación de la fecha de entrega (SD1.3 *Reserve Inventory and Determine Delivery Date*), que cuenta con las siguientes métricas: porcentaje de pedidos entregados en su totalidad (RL.2.1 *% of Orders Delivered In Full*) y niveles de servicio (RL.3.36 *Fill Rate*) (SCOR, 2017).

6. Conclusiones y recomendaciones

6.1 Conclusiones:

- Respondiendo la pregunta de investigación, los principales cambios detectados al modelo logístico de la compañía fueron los pronósticos de demanda, ya que el nivel de precisión de los procedimientos actuales es de 69.47 % y el propuesto de 74.12 %, siendo el de la metodología planteada un 4.65 % mejor. También, en la gestión del almacenamiento se demostró que la propuesta planteada para abordar el inventario de seguridad fue una medida efectiva para controlar la escasez e incertidumbre generada en los pronósticos según la medida FACC y MAPE respectivamente, logrando indicadores de cumplimiento al cliente en promedio entre el 93.46 % y 95.13 %, mejores que la referencia de 92.99 % de la empresa. Así mismo, las políticas de inventario permitieron establecer una frecuencia de pedido óptima de acuerdo con el comportamiento histórico de la demanda de cada referencia y las proyecciones de la misma, permitiendo la disminución de los costos logísticos en un 10.02%.

- El aporte de esta investigación al objetivo 9.4 de los ODS es el uso de nuevas tecnologías como Python y Gusek complementado con Excel, que permitieron establecer una mejor administración de los recursos de Insaltec en el horizonte de planeación, disminuyendo sus costos logísticos y aumentando sus indicadores de cumplimiento al cliente.
- Se puede afirmar que el ensamble fue el mejor modelo de pronóstico respecto a las dos familias de métodos individuales, pues fue seleccionada para 8 de los 14 productos. Dentro de los ensambles, los modelos más usados fueron los de series de tiempo exponenciales por encima de los autorregresivos, y en un 64.29 % de las ocasiones se usaron modelos de la misma familia, respaldando la propuesta realizada.
- La gestión del almacenamiento determinó que, para los 14 productos del Pareto final, la bodega de Barranquilla no se utilizó debido al costo elevado de mantener en comparación con el almacén de Cartagena. Sin embargo, es oportuno resaltar que Insaltec importa y comercializa otros productos que sí podrían transitar por este almacén.
- El tratamiento de datos históricos tiene una influencia significativa en los resultados de los pronósticos, puesto que la transformación de posibles datos atípicos generó un cambio en la parametrización y desempeño de los diferentes modelos. En el caso de las de series de tiempo exponenciales, un 62.5 % de los modelos de pronóstico finales fueron distintos al realizar la transformación de los datos, mientras que para los autorregresivos se presentaron cambios de métodos en el 50 % de las ocasiones, y en los ensambles se obtuvo un 100% de diferencias en los modelos usados. Por lo tanto, la familia de ensambles es más sensible a la corrección de datos atípicos en la demanda porque depende de la inicialización de dos métodos de pronósticos en la ventana de entrenamiento. En cuanto a las familias clásicas de modelos, la familia de series de tiempo exponenciales presenta mayor sensibilidad que las autorregresivas.

6.2 Recomendaciones:

- Para trabajos e investigaciones futuras recomendamos ensamblar más de dos modelos de pronóstico o indagar acerca de otras metodologías, con el fin de evaluar si se genera una mayor precisión en las predicciones o no. Lo anterior para tener mayor robustez en el cálculo de los pesos de generación en las combinaciones, que se puede lograr utilizando heurísticas, metaheurísticas y modelos de optimización mencionados en el aparatado de antecedentes.
- Sugerimos abordar la gestión del almacenamiento con programación no lineal, con el propósito de dar una mayor flexibilidad y adaptabilidad al modelo de incluir restricciones más complejas que consideren externalidades que sucedan en la industria.
- Recomendamos realizar pruebas estadísticas para determinar las distribuciones de probabilidad que sigue la demanda de cada producto analizado, con el objetivo de proponer el cálculo del inventario de seguridad por producto de acuerdo con una función de probabilidad que modele el comportamiento de cada artículo.
- Se sugiere implementar la metodología desarrollada manejando datos históricos atípicos como fueron los años 2020 y 2021, con el propósito de medir el desempeño y la flexibilidad de los modelos desarrollados en esta investigación. Además, considerando dichos periodos se podría evaluar maneras alternas para tratar datos atípicos, que consideren factores estacionales y de tendencia, dado que, en nuestro caso el número de registros en la ventana de entrenamiento era de un tamaño reducido.

- Proponemos la implementación de un algoritmo, modelamiento o heurísticas para optimizar el transporte de las unidades entre los eslabones considerados en el método DRP, buscando minimizar aún más los costos logísticos.
- Se recomienda utilizar una mayor cantidad de datos en la ventana de entrenamiento para que modelos estacionales como el SARIMA consigan detectar patrones en temporalidades que les permitan tener un mejor desempeño. Además, para los modelos empleados, se tendría un mejor proceso de aprendizaje y se pueden calibrar con mayor precisión los parámetros de funcionamiento.
- En la literatura existen diferentes pruebas estadísticas para comprobar cada uno de los supuestos abordados en esta investigación. Es por esto, que se recomienda aplicar diferentes alternativas para evaluar las hipótesis planteadas y contrastar la diferencia de los resultados obtenidos en este estudio.

7. Referencias

- Adhikari, N. C., Garg, R., Datt, S., Das, L., Deshpande, S., y Misra, A. (2017). Ensemble methodology for demand forecasting. *International Conference on Intelligent Sustainable Systems (ICISS)*, 846–851. Recuperado el 5 de septiembre del 2020 de: <https://doi.org/10.1109/ISS1.2017.8389297>
- Arabzad, S. M., Ghorbani, M., y Zolfani, S. H. (2015). A Multi-Objective Robust Optimization Model for a Facility Location-Allocation Problem in a Supply Chain under Uncertainty. *Engineering Economics*, 26(3), 227–238. Recuperado el 20 de septiembre del 2020 de: <https://doi.org/http://dx.doi.org/10.5755/j01.ee.26.3.4287>
- Baltacioglu, G., Temiz, I., y Erol, S. (2011). Fuzzy Wagner Whitin Algorithm and an Application of Class I Supplies. *Gazi University Journal of Science*, 24(1), 125–134. Recuperado el 10 de junio del 2021 de: https://www.researchgate.net/publication/257341916_Fuzzy_Wagner_Whitin_Algorithm_and_an_Application_of_Class_I_Supplies
- Bofill, A., Sablón, N., y Florido, R. (2017). Procedimiento para la gestión de inventario en el almacén central de una cadena comercial cubana. *Revista Universidad y Sociedad*, 9 (1), 41-51. Recuperado el 15 de agosto del 2020 de: http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S2218-36202017000100006
- Bustos, C., y Chacón, G. (2012). Modelos determinísticos de inventarios para demanda independiente: Un estudio en Venezuela. *Contaduría y administración*, 57(3), 239–258. Recuperado el 2 de junio del 2021 de: http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S0186-10422012000300011
- Canal, N. (2006). Distribuciones de probabilidad. El teorema del límite central. Recuperado el 28 de julio del 2021 de: <https://www.revistaseden.org/files/8-CAP%208.pdf>
- Cardona, J., Orejuela, J., y Rojas, C. (2018). Gestión de inventario y almacenamiento de materias primas en el sector de alimentos concentrados. *Universidad EIA*, 195-208. Recuperado el 15 de agosto del 2020 de: <http://www.scielo.org.co/pdf/eia/v15n30/2463-0950-eia-15-30-195.pdf>
- Dayanti, A., Firdaus, M. A., Meiriza, A., Rosa, D., y Heryanto, A. (2019). Implementation of Distribution Requirement Planning in the Subsidized Fertilizer Management System. *Sriwijaya International Conference on Information Technology*, 172, 532–538. Recuperado el 29 de enero del 2021 de: <https://doi.org/10.1080/00207543.2019.1639841>
- Dellino, G., Laudadio, T., Mari, R., Mastronardi, N., y Meloni, C. (2015). Sales Forecasting Models in the Fresh Food Supply Chain. *International Conference on Operations Research and Enterprise Systems*, 419–426. Recuperado el 22 de junio del 2020 de: <https://doi.org/10.5220/0005293204190426>

- Dietrichson, N. (2019). Métodos Cuantitativos. Recuperado el 28 de julio del 2021 de: <https://bookdown.org/dietrichson/metodos-cuantitativos/>
- Euromonitor. (2020). Packaged Food in Colombia. Recuperado el 14 de agosto del 2020 de: <https://go.euromonitor.com/passport.html>
- García, O. (2020, junio 15). Entrevista a profundidad acerca del sistema logístico de Insaltec. [Entrevista telefónica].
- García, O. (2021, abril 4). Entrevista a profundidad acerca de las restricciones en el sistema logístico de Insaltec. [Entrevista telefónica].
- García, O. (2021, julio 23). Entrevista a profundidad para aclarar temas respecto al Pareto, la política de faltantes de la empresa, la precisión sobre la naturaleza de los posibles datos atípicos, la relación con los operadores logísticos y el funcionamiento del cross-docking. [Entrevista telefónica].
- Gardner, E. S., y Acar, Y. (2019). Fitting the damped trend method of exponential smoothing. *Journal of the Operational Research Society*, 70(6), 926–930. Recuperado el 9 de septiembre del 2020 de: <https://doi.org/10.1080/01605682.2018.1469457>
- Gómez, J. y Baca, A. (2014). *Análisis de Operaciones Cross Docking Directas e Indirectas en Colombia* (Tesis de posgrado). Universidad Militar Nueva Granada, Bogotá, Colombia.
- Hao, J., Feng, Q., Suo, W., Gao, G., y Sun, X. (2019). Ensemble forecasting for electricity consumption based on nonlinear optimization. *Procedia Computer Science*, 162, 19–24. Recuperado el 4 de marzo del 2021 de: <https://doi.org/10.1016/j.procs.2019.11.252>
- Haq, A. U., Zeb, A., Lei, Z., y Zhang, D. (2021). Forecasting daily stock trend using multi-filter feature selection and deep learning. *Expert Systems With Applications*, 168. Recuperado el 13 de enero del 2021 de: <https://doi.org/10.1016/j.eswa.2020.114444>
- Hyndman, R., y Athanasopoulos, G. (2018). *Forecasting: principles and practice*. Melbourne, Australia. Recuperado el 8 de febrero del 2021.
- Kourentzes, N., Trapero, J. R., y Barrow, D. K. (2020). Optimising forecasting models for inventory planning. *International Journal of Production Economics*, 225, 1–9. Recuperado el 21 de agosto del 2020 de: <https://doi.org/10.1016/j.ijpe.2019.107597>
- Li, J., Hao, J., Feng, Q., Sun, X., y Liu, M. (2021). Optimal selection of heterogeneous ensemble strategies of time series forecasting with multi-objective programming. *Expert Systems With Applications*, 166. Recuperado el 13 de enero del 2021 de: <https://doi.org/10.1016/j.eswa.2020.114091>
- Lin, J., Cai, G., Liu, S., Zou, H., y Puppala, A. J. (2017). Correlations Between Electrical Resistivity and Geotechnical Parameters for Jiangsu Marine Clay Using Spearman's Coefficient Test. *International Journal of Civil Engineering*, 15(3), 419–429. Recuperado el 26 de mayo del 2021 de: <https://doi.org.ezproxy.javeriana.edu.co/10.1007/s40999-016-0055-9>
- Magdalena, R., y Suli, T. (2019). Forecasting Methods and Implementation of DRP (Distribution Requirement Planning) Methods in Determining the Master Production Schedule. *IOP Conference Series: Materials Science and Engineering*, 528(1). Recuperado el 9 de enero del 2021 de: <https://iopscience.iop.org/article/10.1088/1757-899X/528/1/012049>

- Memarzadeh, G., y Keynia, F. (2021). Short-term electricity load and price forecasting by a new optimal LSTM-NN based prediction algorithm. *Electric Power Systems Research*, 192. Recuperado el 13 de enero del 2021 de: <https://doi.org/10.1016/j.epsr.2020.106995>
- Medina, M. (Productor). (2016). Pronóstico de Ventas: una herramienta comercial. [MP4]. Recuperado el 24 de junio del 2020 de: <https://www.youtube.com/watch?v=DLJ7hJUWm3E&feature=youtu.be>
- Montoya, C. (Productor). (2020). Inventarios con Demanda Estocástica. [MP4]. Recuperado el 2 de octubre del 2020 de: https://drive.google.com/file/d/16IBS00FeLh2IZ-ebiW4zie5yPd7_nn4t/view
- Naciones Unidas. (n.d.). Naciones Unidas | Paz, dignidad e igualdad en un planeta sano. Recuperado el 2 de febrero del 2021 de: <https://www.un.org/es/>
- Ngatilah, Y., Rahmawati, N., Pujiastuti, C., Porwati, I., y Hutagalung, A. Y. (2020). Inventory Control System Using Distribution Requirement Planning (DRP) (Case Study: Food Company). *Journal of Physics: Conference Series*, 1569(3). Recuperado el 9 de enero del 2021 de: <https://doi.org/10.1088/1742-6596/1569/3/032005>
- Pazos, A. (2018). Análisis de correlación moderno ¿Qué alternativas existen para la correlación de Pearson? (Maestría). *Universidad de Cataluña*. Recuperado el 22 de junio del 2021 de: <http://openaccess.uoc.edu/webapps/o2/bitstream/10609/81845/7/apazosrTFM0618memoria.pdfRoozbeh>
- A., Hemmati, M., y Akhavan, S. (2014). A fuzzy vendor managed inventory of multi-item economic order quantity model under shortage: An ant colony optimization algorithm. *International Journal of Production Economics*, 155, 259–271. Recuperado el 23 de septiembre del 2020 de: <https://doi.org/10.1016/j.ijpe.2013.07.017>
- Rădășanu, A. C. (2016). Inventory Management, Service Level and Safety Stock. *Journal of Public Administration, Finance and Law*, 9, 145–153. Recuperado el 16 de junio del 2021 de: https://www.jopafl.com/uploads/issue9/INVENTORY_MANAGEMENT_SERVICE_LEVEL_AND_SAFETY_STOCK.pdf
- SCOR. (2017). Supply Chain Operations Reference Model. Recuperado el 2 de octubre del 2020 de: <http://www.apics.org/apics-for-business/frameworks/scor>
- Seo, S. (2006). A review and comparison of methods for detecting outliers in universe data sets (Maestría). *University of Pittsburgh*. Recuperado el 3 de marzo del 2021 de: <http://d-scholarship.pitt.edu/7948/1/Seo.pdf>
- Silva, L., Hermsdorf, J., Guedes, V., Teixeira, F., Fernandes, J., Bispo, B., y Teixeira, J. P. (2019). Outliers Treatment to Improve the Recognition of Voice Pathologies. *Procedia Computer Science*, 164, 678–685. Recuperado el 3 de marzo del 2021 de: <https://doi-org.ezproxy.javeriana.edu.co/10.1016/j.procs.2019.12.235>
- Sinha, A. K., y Anand, A. (2020). Optimizing supply chain network for perishable products using improved bacteria foraging algorithm. *Applied Soft Computing Journal*, 86. Recuperado el 26 de agosto del 2020 de: <https://doi.org/10.1016/j.asoc.2019.105921>
- Vasiljevic, D., Stepanovic, M., y Manojlovic, O. (2013). Cross Docking Implementation in Distribution of Food Products. *Economics of Agriculture*, 60(1), 91–101. Recuperado el 22 de julio del 2020 de: <https://www-proquest-com.ezproxy.javeriana.edu.co/docview/1346956557?accountid=13250>

Yadav, A., y Ghosh, S. (2019). Forecasting monthly farm tractor demand for India using MSARIMA and ARMAX models. *Indian Journal of Agricultural Research*, 53(3), 315–320. Recuperado el 15 de agosto del 2020 de: [10.18805/IJARE.A-5185](https://doi.org/10.18805/IJARE.A-5185)

Yang, M., Lin, Y., Ho, L. H., y Kao, W. F. (2016). An Integrated Multiechelon Logistics Model with Uncertain Delivery Lead Time and Quality Unreliability. *Mathematical Problems in Engineering*, 2016. Recuperado el 20 de septiembre del 2020 de: <https://doi.org/http://dx.doi.org/10.1155/2016/8494268>