

Escuela Superior Politécnica del Litoral

Facultad de Ingeniería en Mecánica y Ciencias de la Producción

“Desarrollo de una herramienta estadística para el pronóstico de la demanda en una
empresa de balanceado acuícola”

Proyecto Integrador

Previo la obtención del Título de:

Ingeniero Industrial

Presentado por:

Ricardo Joel Espinoza Espinales

Eliana Cristina Asanza Paladines

Guayaquil - Ecuador

Año: 2025

Dedicatoria

El presente proyecto lo dedico con todo mi cariño y gratitud a mis padres, Ricardo y Sully, quienes han sido mi guía constante en cada etapa de mi vida. Gracias por enseñarme con su ejemplo el valor del esfuerzo, la disciplina y la perseverancia. Sus consejos y apoyo incondicional han sido la base para alcanzar este logro, y espero que este trabajo sea motivo de orgullo para ustedes.

A mis hermanos, Emily y Luis por ser una fuente de alegría e inspiración.

También dedico este proyecto a mi gata Luna, quién en su momento con su compañía silenciosa y afectuosa me brindó tranquilidad en las largas jornadas de estudio.

Ricardo Espinoza

Dedicatoria

Este proyecto lo dedico con mi más profundo cariño y gratitud a mis padres, Miriam y Manuel, quienes siempre estuvieron junto a mí, impulsándome a dar a lo mejor de mí y enseñándome a no rendirme nunca. Valoro todo el esfuerzo y sacrificio que hicieron para que yo pueda formarme profesionalmente.

A mis hermanas Luisa y Dennise, quienes jamás dejaron de confiar en mí, y siempre me recordaron que los sueños se disfrutan más cuando se comparten.

Y desde luego, a mis abuelitas, Regina y Licha, quienes siempre oraron por mí, y me acompañaron con su amor incondicional.

Eliana Asanza.

Agradecimientos

Mi más sincero agradecimiento a mis padres, por estar siempre presentes en cada etapa de este proceso, brindándome su apoyo y comprensión constante en los momentos más retadores de la carrera.

A la Escuela Superior Politécnica del Litoral (ESPOL) y a la Facultad de Ingeniería en Mecánica y Ciencias de la Producción, por ser el espacio de formación que me permitió adquirir los conocimientos y experiencias necesarias para mi desarrollo profesional.

A mi tutora, María Belén Segovia, por sus valiosos aportes, dedicación y guía durante el desarrollo de este proyecto.

Finalmente, agradezco a mis amigos, compañeros y a todas esas personas que formaron parte de este proceso aportando con su ayuda, consejos y motivación para alcanzar este logro académico.

Ricardo Espinoza

Agradecimientos

En primer lugar, le quiero agradecer a Dios por permitirme vivir esta experiencia, agradezco a mi madre Miriam, quien ha sido mi pilar, mi inspiración y mi ejemplo a seguir, que con su apoyo incondicional y amor infinito siempre me ha impulsado a seguir adelante, a mi padre Manuel que desde el cielo siempre ha sido mi motivación para dar lo mejor de mí y hacerlo sentir orgulloso. A mis hermanas Luisa y Dennise, quienes son mi inspiración, mi fuerza y mi refugio incondicional.

Agradezco a María Belén Segovia, quien nos brindó de su tiempo, apoyo y dedicación en cada etapa de este trabajo.

Por último, le agradezco a mis amigos, quienes me acompañaron a lo largo de la carrera, a mi familia, y a todas aquellas personas que, de una u otra forma, hicieron posible que hoy pueda alcanzar esta meta.

Eliana Asanza

Declaración Expresa

Yo/Nosotros Eliana Cristina Asanza Paladines y Ricardo Joel Espinoza Espinales acuerdo/acordamos y reconozco/reconocemos que:

La titularidad de los derechos patrimoniales de autor (derechos de autor) del proyecto de graduación corresponderá al autor o autores, sin perjuicio de lo cual la ESPOL recibe en este acto una licencia gratuita de plazo indefinido para el uso no comercial y comercial de la obra con facultad de sublicenciar, incluyendo la autorización para su divulgación, así como para la creación y uso de obras derivadas. En el caso de usos comerciales se respetará el porcentaje de participación en beneficios que corresponda a favor del autor o autores.

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

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

Guayaquil, 29 de mayo del 2025.



Eliana Cristina
Asanza Paladines



Ricardo Joel
Espinoza Espinales

Evaluadores

María Fernanda López S., MSc.

Profesor de Materia

María Belén Segovia N., MSc.

Tutor de proyecto

Resumen

El presente proyecto tiene como finalidad el desarrollo de una herramienta estadística para el pronóstico de la demanda en una empresa de balanceado acuícola, con el objetivo de aumentar la precisión de las previsiones en al menos un 65%, a fin de optimizar la planificación de la producción y el uso de materias primas. La hipótesis sostiene que la incorporación de modelos estadísticos robustos y la clasificación técnica de los patrones de demanda permiten reducir los errores de estimación y mejorar la eficiencia operativa. Para su ejecución se recopilieron y verificaron datos históricos de ventas extraídos del sistema ERP de la empresa, los cuales fueron depurados y posteriormente analizados mediante técnicas de series temporales y la evaluación de diferentes modelos de pronóstico. Los resultados demostraron una mejora significativa, alcanzando un nivel de precisión del 71% al comparar los valores proyectados con la demanda real de julio de 2025, superando así el objetivo planteado. Asimismo, se identificaron beneficios económicos, sociales y ambientales derivados de una planificación más confiable y eficiente. Se concluye que la herramienta desarrollada incrementa la exactitud de los pronósticos, fortalece la toma de decisiones estratégicas y contribuye a la sostenibilidad de las operaciones de la empresa.

Palabras Clave: Pronóstico de la demanda, precisión, planificación, series temporales.

Abstract

This project focuses on the development of a statistical tool for demand forecasting in an aquaculture feed company, with the objective of increasing forecast accuracy by at least 65% in order to optimize production planning and the use of raw materials. The hypothesis states that the incorporation of robust statistical models and the technical classification of demand patterns can reduce estimation errors and improve operational efficiency. For its implementation, historical sales data were collected and verified from the company's ERP system, which were then cleaned and analyzed through time series techniques and the evaluation of different forecasting models. The results demonstrated a significant improvement, achieving an accuracy level of 71% when comparing the projected values with the actual demand of July 2025, thus surpassing the initial objective. In addition, economic, social, and environmental benefits were identified as a result of more reliable and efficient planning. It is concluded that the proposed tool increases forecast reliability, strengthens strategic decision-making, and contributes to the sustainability of the company's operations.

Keywords: demand forecasting, accuracy, planning, time series.

Índice general

Resumen	I
<i>Abstract</i>	II
Índice general	III
Abreviaturas	V
Índice de Figuras	VI
Capítulo 1	1
1.1 Introducción	2
1.2 Descripción del Problema	3
1.3 Justificación del Problema	4
1.4 Objetivos	5
1.4.1 Objetivo general	5
1.4.2 Objetivos específicos	5
1.5 Marco Teórico	5
Capítulo 2	9
2. Metodología	10
2.1 Definición	10
2.1.1 Antecedentes del cliente	10
2.1.2 Diagramación del proceso (SIPOC)	10
2.1.3 Necesidades del cliente	11
2.1.4 Mapa de empatía	12
2.1.5 Voz del cliente (VOC)	14
2.1.6 Casa de la Calidad (QFD)	16
2.1.7 Declaración del problema	18
2.2 Recolección de datos	19
2.2.1 Plan de recolección de datos	19
1.1.1 Verificación de los datos	20

2.3	Análisis.....	22
1.1.2	Evaluación de diseño	22
1.1.3	Análisis financiero	31
Capítulo 3.....		34
3.	Resultados y análisis	35
1.1.4	Evaluación y validación de la herramienta de pronóstico	35
1.1.5	Análisis de sensibilidad	43
1.1.6	Análisis del Impacto Social, Económico y Ambiental.....	44
Capítulo 4.....		47
4.1	Conclusiones y recomendaciones	48
4.1.1	Conclusiones	48
4.1.2	Recomendaciones	49
Referencias bibliográficas		51

Abreviaturas

ADI	Average Demand Interval
CTQ	Critical to Quality
CV	Coefficient of Variation
ETS	Exponential Triple Smoothing
LightGBM	Light Gradient Boosting Machine
MASE	Mean Absolute Scale Error
NBATS	Neural Basis Expansion Analysis for Time Series Forecasting
RMSE	Root Mean Squared Error
SIPOC	Suppliers, Inputs, Process, Outputs, Customers
SKU	Stock Keeping Unit
TBATS	Trigonometric, Box-Cox, ARMA errors, Trend and Seasonal components
TIR	Tasa Interna de Retorno
TSB	Teunter-Syntetos-Babai Model
VAN	Valor Actual Neto
VOC	Voice of the Customer

Índice de Figuras

<i>Figura 1: Proceso actual del pronóstico de la demanda</i>	11
<i>Figura 2: Journey map del pronóstico de la demanda</i>	12
<i>Figura 3: Mapa de empatía a la planificadora de demanda</i>	13
<i>Figura 4: Mapa de empatía a la líder del departamento IBP</i>	13
<i>Figura 5: Mapa de empatía a un especialista del departamento de compras</i>	14
<i>Figura 6: VOC aplicado al departamento de IBP.</i>	15
<i>Figura 7: VOC aplicado a los departamentos de producción, compras, formulación.</i>	15
<i>Figura 8: Diagrama de Afinidad</i>	16
<i>Figura 9: CTQ TREE</i>	17
<i>Figura 10: Quality Function Deployment (QFD)</i>	18
<i>Figura 11: Declaración del problema</i>	19
<i>Figura 12: Plan de recolección de datos</i>	20
<i>Figura 13: Diagrama Pareto del Volumen de Ventas por SKU</i>	23
<i>Figura 14: Descomposición de la serie de tiempo del volumen de ventas agregado</i>	24
<i>Figura 15: Análisis estacional del volumen de ventas agregado.</i>	25
<i>Figura 16: Descomposición de la serie de tiempo del volumen de venta del SKU 14385805</i>	26
<i>Figura 17: Resumen de los resultados de la clasificación de los SKUs según su patrón de demanda.</i>	27
<i>Figura 18: Evaluación de los paquetes de modelos con respecto a los requerimientos del cliente.</i>	29
<i>Figura 19: Evaluación de los paquetes de modelos con respecto a los requerimientos técnicos.</i>	29
<i>Figura 20: Evaluación de los paquetes de modelos con respecto a las restricciones de diseño.</i>	30
<i>Figura 21: Resumen del análisis financiero del paquete 1</i>	32
<i>Figura 22: Resumen del análisis financiero del paquete 2.</i>	32
<i>Figura 23: Resumen del análisis financiero del paquete 3.</i>	32
<i>Figura 24: Resultados del pronóstico de temperatura de los próximos 15 meses.</i>	36
<i>Figura 25: Resultados del pronóstico de la demanda de cada SKU con un horizonte de 15 meses</i>	38
<i>Figura 26: Serie de tiempo del SKU 17133275 con patrón de declive progresivo.</i>	41
<i>Figura 27: Serie de tiempo de SKU 13611675 con picos aislados</i>	42

<i>Figura 28: Resultados del pronóstico con un incremento del 20% de la demanda en cada SKU.</i>	
.....	43

Capítulo 1

1.1 Introducción

La acuicultura es uno de los pilares claves para el crecimiento económico y la sostenibilidad de Ecuador, gracias a su destacada actividad camaronera. En el año 2024, el camarón destacó como el principal producto de exportación no petrolera, representando un total 28% del total, generando ingresos de 6.992 millones de dólares. Por ello, la industria de alimentos balanceados para camarón desempeña un papel fundamental para el desarrollo de este mercado. (MPCEIP, 2025)

En esta industria, la variabilidad que se presenta en la demanda es uno de los mayores desafíos a resolver. Estas variaciones suelen estar determinadas por factores como cambios económicos, estacionalidades, condiciones ambientales, entre otros. Dado este contexto, el pronóstico de la demanda se posiciona como una herramienta esencial para mitigar estos desafíos y mejorar la toma de decisiones operativas.

La precisión en el pronóstico no solo permite alinear la producción con las necesidades reales del mercado, sino también optimizar los recursos y reducir costos, especialmente aquellos derivados de situaciones de sobreproducción o desabastecimiento, influenciando a su vez en la mejora de la gestión de recursos materiales.

El presente proyecto se encuentra estructurado por cuatro capítulos. En el capítulo 1 se aborda el problema, el contexto de la empresa e industria camaronera y se plantearon los objetivos de este trabajo. En el capítulo 2 se desarrolla el marco teórico y metodológico incluyendo las distintas herramientas para levantar la información y técnicas de pronóstico utilizadas. En el capítulo 3 se exponen los resultados obtenidos de la herramienta, junto a una breve comparación con el desempeño actual de los pronósticos de demanda. Finalmente, en el capítulo 4 se presentan las conclusiones y recomendaciones.

1.2 Descripción del Problema

En la empresa dedicada a la producción de alimentos balanceados para camarón, el departamento de planificación de demanda y materia prima juega un rol fundamental para garantizar una operación eficiente. Actualmente, este departamento utiliza un sistema certificado para realizar los pronósticos de demanda de los diversos SKU's del portafolio. Sin embargo, dicho sistema presenta varias limitaciones, como su ineficiencia en la adaptación a las variaciones de la demanda y una interfaz poco intuitiva para los usuarios. Esto ha llevado a que el equipo complemente su trabajo con el uso de un archivo de Microsoft Excel para elaborar los pronósticos.

Esto genera dos escenarios problemáticos para la planificación:

- **Pronóstico inferior a la demanda real:** Este escenario obliga a utilizar materia prima adicional para cubrir el déficit y producir el SKU en cuestión. A menudo, esta situación compromete la capacidad de producción de otras fórmulas debido a la falta de insumos, lo que puede generar incumplimientos en los pedidos.
- **Pronóstico superior a la demanda real:** En este caso, el exceso de inventario de materias primas satura la capacidad de almacenamiento en las bodegas. Esto incrementa el riesgo de que los materiales caduquen antes de ser utilizados, generando costos adicionales por obsolescencia e incrementando los costos de almacenamiento.

Como resultado de estos problemas, el indicador **precisión de pronóstico** de la empresa actualmente se encuentra en un nivel bajo, que refleja la necesidad urgente de una solución que permita mejorar la precisión en los pronósticos y mitigar los efectos negativos tanto financieros como operativos. Por ello, se declaró el siguiente problema:

Desde enero de 2025, el departamento de Procesos Integrados de Negocio ha registrado un promedio de 56% de precisión en los pronósticos de demanda por mes, cuando en realidad apunta a tener al menos un 65% de precisión de demanda por mes.

1.3 Justificación del Problema

Un pronóstico preciso de la demanda es fundamental para una planificación de producción efectiva, ya que permite satisfacer las órdenes de los clientes en tiempo y forma, optimizar el uso de las materias primas y garantizar la sostenibilidad de la empresa a largo plazo. Cuando este elemento crítico falla, la empresa enfrenta escenarios de sobreproducción o desabastecimiento, los cuales incrementan los costos y reducen la eficiencia operativa, afectando directamente la rentabilidad del negocio.

En términos de escenarios de sobreproducción, se presentan casos de reformulación, lo que implica volver a “armar” la fórmula de un producto utilizando materias primas sustitutas. Esta práctica genera un incremento de costos estimado en 35 mil dólares mensuales, debido a la falta de disponibilidad de insumos exclusivos necesarios para producir artículos que no formaban parte del forecast o cuyo volumen real superó lo planificado.

La principal complejidad radica en la alta variabilidad de la demanda en este mercado. Factores como la estacionalidad, variables externas, picos inesperados de demanda y otras fluctuaciones requieren un análisis estadístico profundo para comprender sus patrones y tendencias. Este contexto manifiesta la necesidad de herramientas avanzadas que permitan abordar estas variaciones de manera efectiva.

Con este enfoque, se espera no solo mejorar la precisión del pronóstico y los indicadores asociados, sino también fortalecer la competitividad de la empresa en el mercado. Un pronóstico confiable y eficiente no solo facilita la planificación operativa, sino que también refuerza la confianza de los clientes.

1.4 Objetivos

1.4.1 Objetivo general

Diseñar una herramienta de previsión de la demanda basada en modelos estadísticos robustos, que aumente la precisión de las previsiones en al menos un 65%, con el fin de optimizar la planificación de la producción y las materias primas en una empresa de piensos para acuicultura, en un plazo de 4 meses.

1.4.2 Objetivos específicos

- Analizar el comportamiento histórico de la demanda de los SKUs con mayor rotación para identificar patrones, tendencias y estacionalidad que puedan utilizarse para desarrollar modelos de pronóstico más precisos.
- Diseñar modelos estadísticos robustos en R Studio para reducir el margen de error en la estimación de la demanda.
- Validar los pronósticos de demanda con el modelo seleccionado para garantizar su confiabilidad y precisión.

1.5 Marco Teórico

La capacidad de predecir la demanda con precisión ejerce un impacto directo sobre la eficiencia de las operaciones y los resultados económicos de las empresas (Mentzer & Moon, 2004). En los últimos años, la creciente disponibilidad de datos y la necesidad de actualizar las proyecciones de forma dinámica han hecho imprescindible contar con herramientas estadísticas que ofrezcan mayor solidez que los métodos tradicionales. Por ello, diseñar un sistema de pronóstico eficaz implica integrar diversos modelos y técnicas que permitan ajustar las predicciones a distintos tipos de patrones en las series de tiempo.

La construcción de un modelo de pronóstico inicia con la exploración detallada de las

propiedades estadísticas de la serie. Box, Jenkins, Reinsel y Ljung (2016) subrayan la importancia de este diagnóstico inicial, que se basa en:

- Verificar la estacionalidad, es decir, que la media y la varianza se mantengan estables a lo largo del tiempo.
- Identificar posibles patrones estacionales que se repiten de manera periódica.

En términos generales, los métodos de pronóstico pueden clasificarse en dos grandes grupos: los enfoques cualitativos, sustentados en opiniones expertas, y los cuantitativos, basados en técnicas estadísticas y modelos matemáticos (Hyndman & Athanasopoulos, 2021).

Entre los modelos cuantitativos destacan los ARIMA, adecuados para datos que requieren diferenciarse hasta lograr estacionariedad. Estos modelos han demostrado buenos resultados cuando las series presentan tendencias lineales y fluctuaciones regulares de baja estacionalidad (Hyndman & Athanasopoulos, 2021). En casos donde la estacionalidad es relevante, se emplean los modelos SARIMA, que incorporan componentes adicionales específicos de la estacionalidad (Wei, 2006).

Una extensión relevante de estos enfoques es el SARIMAX, que permite incluir variables externas que puedan incidir en la variable objetivo, enriqueciendo la capacidad explicativa del modelo (Hyndman & Athanasopoulos, 2021).

Por su parte, el método de Media Móvil consiste en calcular el promedio de un número determinado de observaciones recientes, suavizando así la variabilidad a corto plazo y destacando tendencias subyacentes. Aunque se trata de una técnica sencilla, continúa siendo utilizada como referencia y complemento de otros modelos más complejos (Makridakis, Wheelwright & Hyndman, 1998).

Los modelos ETS y el enfoque de Holt-Winters se centran en descomponer la serie temporal en componentes de nivel, tendencia y estacionalidad, resultandos apropiados cuando los patrones tienden a ser relativamente constantes a lo largo del tiempo (Gardner, 2006).

En los últimos años, el aprendizaje automático ha proporcionado nuevos marcos de modelado, destacando algoritmos como XGBoost. Este método de boosting de árboles de decisión es capaz de capturar relaciones complejas y no lineales, incorporando variables adicionales y optimizando de forma eficiente el proceso de entrenamiento (Chen & Guestrin, 2016). No obstante, su implementación requiere bases de datos amplias y una validación cuidadosa para evitar sobreajustes (Makridakis et al., 2018).

Para el pronóstico de series con demanda intermitente, el modelo TSB (Teunter Syntetos-Babai) constituye una alternativa reconocida, ya que considera tanto la probabilidad de que ocurra demanda como el volumen esperado. Este enfoque ha demostrado mejorar la precisión frente a modelos clásicos como el de Croston (Teunter, Syntetos & Babai, 2011).

Antes de definir el modelo de pronóstico más adecuado como los que se han mencionado, es fundamental realizar una clasificación técnica de las series de demanda. Para ello, se adopta el enfoque propuesto por Syntetos y Boylan (2005), el cual se ha convertido en un referente dentro de los estudios sobre demanda intermitente. Esta metodología utiliza dos indicadores cuantitativos: el intervalo promedio entre demandas (ADI), que estima la frecuencia con la que se presentan los pedidos, y el coeficiente de variación (CV), que mide la dispersión en la cantidad solicitada. Al combinar estos dos valores, es posible agrupar las series en cuatro categorías —Smooth, Intermittent, Erratic y Lumpy— lo que facilita la elección de modelos que se ajusten al comportamiento específico de cada patrón. Integrar esta clasificación en el desarrollo de la herramienta de pronóstico permite automatizar la selección del enfoque más eficaz para cada caso, mejorando la precisión y adaptabilidad de los resultados. La adopción de cualquiera de estos métodos debe acompañarse de un proceso metodológico claro que asegure la confiabilidad de los resultados. En este sentido, la validación de los modelos no debe limitarse a un único periodo de prueba, sino que se recomienda implementar esquemas de backtesting o validación cruzada específica para series temporales, en los que los datos se dividen respetando la secuencia

cronológica para evaluar el desempeño del modelo en múltiples orígenes de pronóstico. Este procedimiento, también denominado *time series cross-validation*, permite estimar de forma más robusta la capacidad predictiva de los modelos en escenarios reales, reduciendo el riesgo de sobreajuste y mejorando la confiabilidad de las conclusiones (Hyndman & Athanasopoulos, 2021). Por otra parte, en la elección de métricas de desempeño, se opta por el uso del MASE (*Mean Absolute Scaled Error*) ya que proporciona una medida independiente de la escala y comparable entre distintas series, ya que evalúa los errores en relación con un modelo ingenuo de referencia.

Capítulo 2

2. Metodología.

La metodología utilizada en el proyecto fue **Design Thinking**, dado que resalta por centrarse en el usuario. Este método permitió desarrollar la herramienta de pronóstico de manera progresiva, validando cada avance con los usuarios y adaptando la solución a las necesidades específicas de la empresa. Mediante esta estrategia, fue posible incluir la retroalimentación de los usuarios en cada etapa del trabajo, esto permitió adaptar a la herramienta a los objetivos y necesidades de la compañía.

2.1 Definición

En esta fase inicial se llevó a cabo un análisis detallado del contexto actual de la empresa, con el propósito de identificar el problema central, establecer el alcance del proyecto, definir los objetivos a cumplir y determinar las variables que permitirán evaluar su desempeño.


2.1.1 Antecedentes del cliente

El proyecto se desarrolló en el área de Supply Chain, específicamente en el proceso de planificación de la demanda dentro del departamento de Integrated Business Planning (IBP). Esta unidad es la encargada de consolidar, analizar y generar los pronósticos de venta que sirven como base para la planificación de la producción y el abastecimiento de materias primas. Su rol resulta crítico, ya que conecta la información comercial con la capacidad operativa de la planta, asegurando que la empresa pueda responder de manera eficiente a las necesidades del sector camaronero.

2.1.2 Diagramación del proceso (SIPOC)

Se empleó la herramienta SIPOC con el objetivo de entender el proceso del levantamiento del pronóstico de demanda, desde sus entradas, áreas relacionadas, salidas y resultados.

Figura 1: Proceso actual del pronóstico de la demanda



Fuente: Elaboración propia

2.1.3 Necesidades del cliente

Para identificar todos los momentos positivos y negativos que ocurren durante las distintas etapas del proceso de elaboración del pronóstico de la demanda, se elaboró un journey map. Esta herramienta permitió obtener un enfoque más claro sobre los problemas específicos y los principales puntos de dolor. El journey map se aplicó a la planificadora de la demanda del departamento, quien es la responsable directa de este proceso. Gracias a ello, fue posible reconocer aspectos críticos, como la falta de contexto en los datos de ventas actuales, la obtención de resultados incoherentes y la frustración generada por no conseguir proyecciones adecuadas.

Figura 2: Journey map del pronóstico de la demanda


	Data Collection	Previous Analysis	Model Selection	Forecast Generation	Validation and Adjustment	Forecast Communication	Monitoring
Actions	Download historical data on demand, sales, production	Review seasonality, spikes, trends	Select statistical methods (Weighted average, exponential smoothing)	Run the model, obtain results	Review with sales and production, and adjust the forecast	Present results and explain the changes made	Compare forecast vs actual demand, measure forecast accuracy
Thoughts	"Were the data recorded correctly?" "Are the data complete?"	"Are there outliers? Should those outliers be included?"	"Is this the most suitable model for this category?"	"I hope the forecast is more accurate than the previous period."	"Will the promotion implemented by sales be effective? How much will it impact the forecast?"	"I have to explain why we lowered the forecast for this SKU or increased it for another."	"How bad were we this month?" "Why did the error increase or decrease this period?"
Touchpoints	Database, ERP, Excel	ERP, Power BI, sales report, historical data	Excel, forecast history, DMP	DMP, dashboard, Excel	Shared file, emails, meetings	Dashboards, reports, meetings	KPI's, Excel, Power BI
Pain Points	Incomplete data, errors, delayed entries	Difficult to distinguish real anomalies from mistakes	The DMP system doesn't consider exogenous variables	Unreliable results when there are abrupt changes in demand	Different perspectives between departments, lack of alignment	Difficult to justify changes	No periodic feedback
User Experience	Frustration and wasted time cleaning and validating data 	Confusion when interpreting data without context 	Insecurity when making decisions, constant trials 	Tension due to uncertainty in results 	Debate or disagreement with other departments 	Pressure to justify errors or adjustments 	Little long-term learning if no review is conducted 
Needs	Access to clean, centralized, and reliable data	Greater visibility of commercial and production context	Tool that recommends models based on behavior and exogenous variables	Improve model accuracy and adjust for external events	Fluent communication and shared context	Clear log of changes and reasons	Measure monthly accuracy and learn from mistakes

Fuente: Elaboración propia

2.1.4 Mapa de empatía


El mapa de empatía referente al proceso de pronóstico (Figura 3) evidenció que las personas involucradas, tanto internas como externas, experimentan emociones de estrés, frustración e incertidumbre respecto a los datos generados por los pronósticos.

Figura 3: Mapa de empatía a la planificadora de demanda



Fuente: Elaboración propia

Figura 4: Mapa de empatía a la líder del departamento IBP




Fuente: Elaboración propia

Asimismo, se observó que esta situación provoca afectaciones transversales en distintas

operaciones de otras áreas involucradas, disminuyendo la eficiencia y generando retrabajo en ciertos casos.

Figura 5: Mapa de empatía a un especialista del departamento de compras

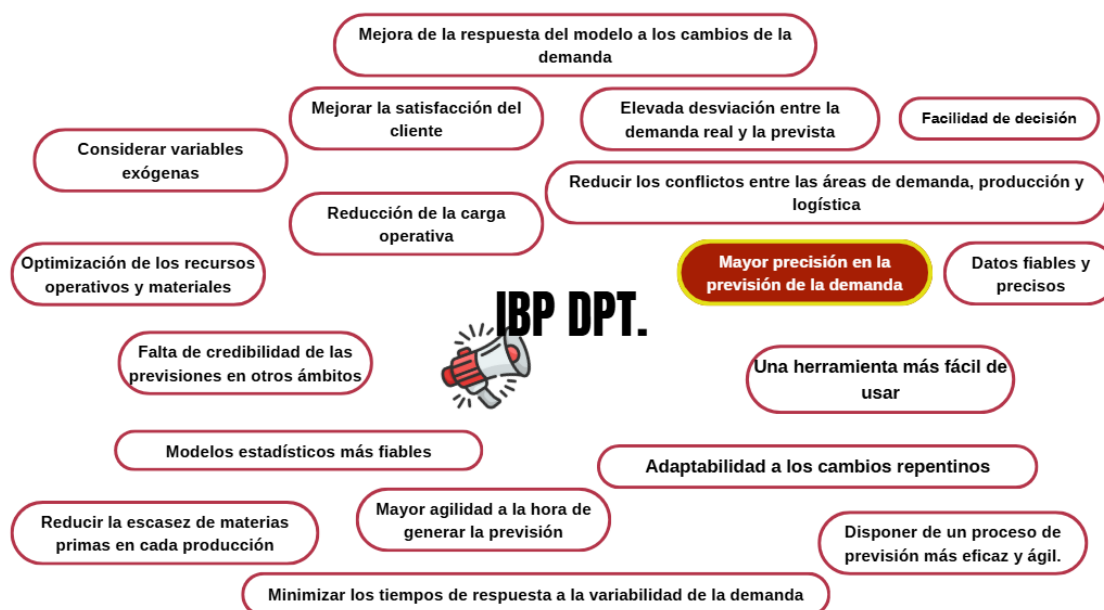


Fuente: Elaboración propia

2.1.5 Voz del cliente (VOC)

Con el objetivo de captar las necesidades del cliente de manera más detallada, se empleó la herramienta VOC, que permitió identificar necesidades clave, tales como incrementar la precisión de los pronósticos, incluir variables exógenas y reducir la carga operativa.

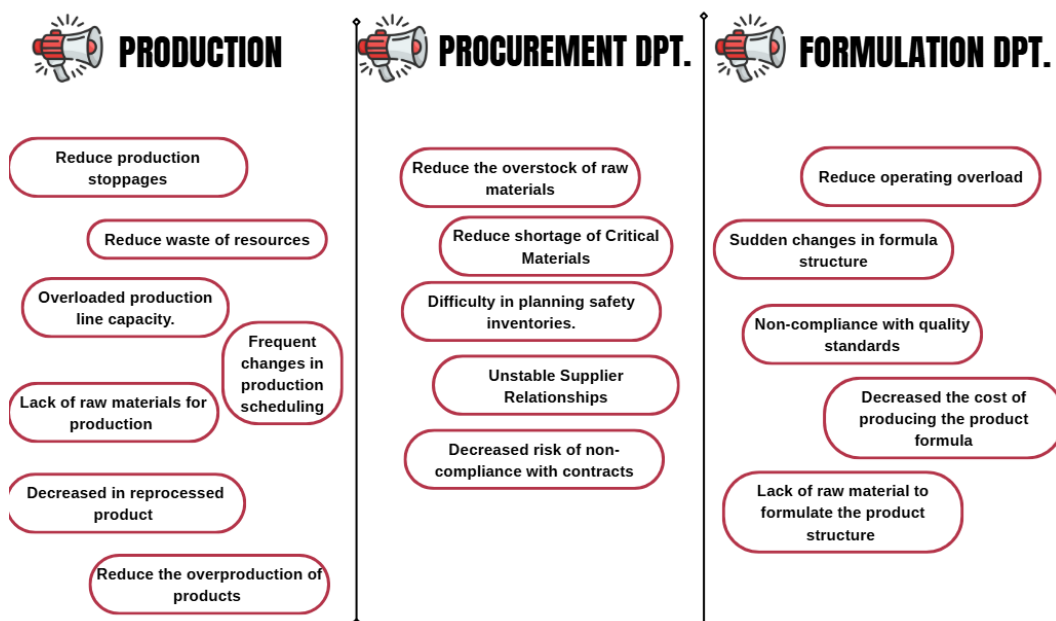
Figura 6: *VOC aplicado al departamento de IBP.*



Fuente: Elaboración propia

De igual manera, se aplicó la herramienta VOC a las áreas que se ven impactadas por un pronóstico deficiente, lo que permitió determinar con claridad el alcance del problema.

Figura 7: *VOC aplicado a los departamentos de producción, compras, formulación.*



Fuente: Elaboración propia

2.1.6 Casa de la Calidad (QFD)

Con todas las necesidades del cliente identificadas, se utilizó la herramienta diagrama de afinidad para clasificar la información recopilada y definir los principales drivers, que fueron: eficiencia operacional, flexibilidad del modelo y precisión del pronóstico.


Figura 8: Diagrama de Afinidad



Fuente: Elaboración propia

A partir de esta clasificación, se elaboraron los CTQ (Critical to Quality) con el objetivo de traducir dichas necesidades en requisitos medibles y específicos.

Figura 9: CTQ TREE




Fuente: Elaboración propia

Una vez definidos los CTQs, se procedió a transformar las necesidades del cliente en especificaciones de diseño. Para cuantificar la importancia relativa de cada requerimiento, se empleó la metodología QFD (Quality Function Deployment), asignando ponderaciones según el grado de relación entre la necesidad y el requerimiento: 9 para una relación fuerte, 3 para media, 1 para débil y 0 si no existía relación.

Como requerimientos críticos de diseño, se priorizaron aquellos que obtuvieron el mayor valor porcentual dentro de la matriz. En este caso se obtuvo: Porcentaje del forecast accuracy $\geq 65\%$.

Figura 10: Quality Function Deployment (QFD)



Fuente: Elaboración propia

Adicionalmente, se establecieron métricas específicas en el marco del enfoque Triple Bottom Line. Las métricas económicas se orientaron a mejorar la precisión de las previsiones, ya que esto reduce los costos asociados a la sobreproducción por reformulación de productos y a la ruptura de inventarios. La métrica social se centró en eliminar la frustración derivada de herramientas ineficaces y en optimizar la experiencia de toma de decisiones. Por último, la métrica ambiental correspondió a la reducción de la huella de carbono generada por las frecuentes reprogramaciones.


El proyecto estuvo alineado con el Objetivo de Desarrollo Sostenible número 8: Trabajo Decente y Crecimiento Económico.

2.1.7 Declaración del problema

De acuerdo con la aplicación de la herramienta 3W+2H, se determinó la siguiente declaración:

Desde enero de 2025, el departamento de IBP ha registrado una media del 56% de precisión en las previsiones de demanda mensuales, mientras que el objetivo establecido es alcanzar al menos un 65% de precisión.

Figura 11: Declaración del problema



Fuente: Elaboración propia

2.2 Recolección de datos

2.2.1 Plan de recolección de datos

Se llevaron a cabo entrevistas con los actores principales, con el fin de identificar qué datos estaban disponibles por parte del personal responsable y conocer cuáles eran las métricas consideradas deseables para el proceso. Dado esto se definió el siguiente plan de recolección de datos (Figura 12).

Figura 12: Plan de recolección de datos

WHO?	WHAT?			WHEN?	WHERE?	WHY?	HOW?		VERIFICATION METHOD
Responsible	Operational Definition	Unit of measure	Data Type	Date	Location- Origin	Future Use	Observation Method	Data Collection method	
Ricardo Espinoza & Eliana Asanza	Total number of SKUs that make up the company's portfolio	Units	Quantity - Discrete	From May 25, 2025	Planning System (ERP), Power BI, Excel	Collect all SKUs codes that make up the company's portfolio for future analysis.	Interview, Document Review	Download Power BI report data or reports.	Verify with the sales department the list of the total SKUs currently being sold
Ricardo Espinoza & Eliana Asanza	Total sales per SKU and per month (historical data)	TM/MONTH	Quantity - Discrete	From May 25, 2025	Planning System (ERP), Power BI	Analyze historical data, in order to find patterns, aberrant data to understand sales behavior and have the most appropriate model.	Interview, Document Review	Download historical sales data from the company's reporting system (ERP-PowerBI).	Verify with the demand planner if this is the historical data currently in use
Ricardo Espinoza & Eliana Asanza	Total sales volume of the SKUs that make up the company's portfolio	TM/MONTH	Quantity - Discrete	From May 25, 2025	Planning System (ERP), Power BI	Analyze the sales volume of the SKUs to obtain more trend information with the use of the statistical tool.	Interview, Document Review	Download historical sales data from the company's reporting system and apply specific filters (ERP-PowerBI).	Verify with the sales department if the information obtained is correct.
Ricardo Espinoza & Eliana Asanza	Total time it takes to complete the demand forecasting process with the forecasting system	Hours	Quantity - Continuous	From May 25, 2025	Work area	Ensure that the implementation of the future statistical tool requires less time for demand forecasting	Interview, Gemba	Measure the time in which the planner completes demand forecasting	Verify demand forecasting time with Demand Planner
Ricardo Espinoza & Eliana Asanza	Forecast Accuracy Percentage	%	Quantity - Continuous	From May 25, 2025	Planning System (ERP)	Use the forecast accuracy indicator to measure the effectiveness of the proposed models.	Interview, Document Review	Observe the % of the Forecast Accuracy indicator at the end of the current month.	Compare forecast demand for SKUs with actual demand for SKUs.

Fuente: Elaboración propia

1.1.1 Verificación de los datos

La validación de los datos representó una etapa fundamental para asegurar la precisión y confiabilidad de los resultados obtenidos durante el análisis. A continuación, se describe el procedimiento seguido para la verificación de la información conforme al plan de recolección establecido.

La fuente principal de información fue el sistema ERP de la empresa, del cual se extrajo la base de datos correspondiente al historial de ventas desde el año 2023 hasta el año 2025. Esta base contenía los registros de transacciones generados automáticamente por el sistema tras el ingreso de pedidos por parte de los clientes, sin intervención manual adicional. Esta característica garantizó la trazabilidad y autenticidad de los datos.

Durante el proceso de depuración, se identificó registros con valores negativos en las ventas, los cuales fueron analizados con mayor profundidad. A través de una revisión detallada y en coordinación con el equipo de Customer Service (CS), se determinó que dichos valores correspondían a devoluciones de productos generadas por diversas causas operativas, tales como sacos rotos o errores en la facturación. Dado que estas devoluciones no reflejan ventas efectivas,

sino ajustes de inventario, se consideró metodológicamente adecuado excluirlas del conjunto de datos a analizar.

Adicionalmente, se realizó una verificación cruzada entre una muestra del histórico extraído del ERP y un reporte comercial elaborado en Power BI. Esta comparación, aplicada a un mes de referencia del año 2024, evidenció una total concordancia entre ambas fuentes, confirmando la consistencia de los valores registrados.

Con el objetivo de sistematizar este proceso, en la Tabla X se presenta un resumen de los instrumentos empleados, las técnicas de validación aplicadas y los hallazgos principales obtenidos:

Tabla 1: Técnicas de validación empleadas

Fuente de datos	Técnica de Validación	Criterios de evaluación	Hallazgos
Histórico de ventas (ERP)	Content validity (validez de contenido)	- Especies del área AQUA. - Inclusión de divisiones de demanda. - Registros diarios, semanales y mensuales.	Base de datos trazable y auténtica, sin intervención manual. Incluye devoluciones e inventarios que debieron depurarse.
Histórico de ventas (ERP) vs. Reporte Comercial (Power BI)	Parallel shape method (comparación paralela de formas)	- Concordancia de valores agregados de ventas en un mes de muestra (2024). - Verificar que no existan diferencias en montos totales.	Se evidenció concordancia total en las sumas de ventas entre ambas fuentes. Los datos son consistentes y confiables.
Datos con valores	Content validity + revisión cruzada con Customer Service	- Identificación de devoluciones, errores	Los registros negativos corresponden a

negativos (ERP y Power BI)		de facturación y ajustes de inventario.	devoluciones o ajustes. Se excluyeron para mantener solo ventas efectivas.
Cálculo de Forecast Accuracy (Power BI)	Construct validity (validez de constructo)	- Contrastar la fórmula usada en la empresa con la literatura especializada. - Verificar que la métrica se mantenga entre 0 y 100%.	Aunque la fórmula empleada no coincide exactamente con ninguna definición teórica aceptada. Se valida su pertinencia para evaluar el desempeño del pronóstico.
Portafolio de SKUs (ERP y Excel)	Content validity + concordancia simple y cruzada	- Confirmar que los SKUs proyectados estén activos en el portafolio. - Verificar coincidencia entre SKUs proyectados y vendidos.	Todos los SKUs se encuentra activos para los movimientos de producción y venta dentro del sistema de la empresa

Fuente: Elaboración propia


2.3 Análisis

Se llevó a cabo un análisis exhaustivo de los datos históricos del volumen de ventas para comprender el comportamiento de la demanda, identificar patrones relevantes, con la finalidad de diseñar una herramienta que permita pronosticar la demanda de forma más precisa.

1.1.2 Evaluación de diseño

Una vez que se realizó la validación de los datos históricos, se aplicó un análisis de Pareto en función del volumen de ventas por SKU. A continuación, se presenta el gráfico obtenido:

Figura 13: Diagrama Pareto del Volumen de Ventas por SKU




Fuente: Elaboración propia

A través de este análisis, fue posible determinar que, solo 19 de 304 SKUs representaban el 80% del volumen total de ventas en los últimos 12 meses, razón por la que se decidió enfocar el estudio en aquellos productos que poseen un mayor impacto en el portafolio de ventas de la empresa.

Con el fin de analizar el comportamiento de los datos, se utilizó Minitab para generar una serie de tiempo de las ventas totales de todos los SKUs, y de la misma manera se realizó su descomposición en sus componentes de tendencia y estacionalidad, tal como se muestra a continuación:

Figura 14: Descomposición de la serie de tiempo del volumen de ventas agregado




Fuente: Elaboración propia

Donde la líneas azul, roja y verde muestran la serie real, los ajustes del modelo y la tendencia estimada respectivamente.

El análisis de la serie temporal reveló una velocidad de crecimiento alta y sostenida, lo que se traduce en una tendencia creciente en el tiempo.

La estacionalidad en la serie de tiempo muestra patrones estacionales máximos recurrentes entre marzo-mayo y diciembre, y mínimos entre agosto-octubre, para hacer un análisis más profundo se generó en Minitab la gráfica correspondiente al análisis estacional del volumen de ventas agregado que se muestra a continuación:

Figura 15: Análisis estacional del volumen de ventas agregado.




Fuente: Elaboración propia

El análisis de los índices estacionales mostró un patrón recurrente en el ciclo anual, con picos y valles claramente definidos, identificando a marzo y abril como los picos más notorios, mientras que, septiembre representó el valle más profundo, seguido por julio y agosto con valores también reducidos. Este comportamiento es consistente con el sector camaronero, en el cual la producción se contrae en la época de frío que comprende entre junio y noviembre debido a que, las bajas temperaturas provocan una disminución de la inmunidad y la capacidad de resistencia a enfermedades de los organismos cultivados, afectando su desarrollo y el crecimiento (Ren, Wang, Shao, Xu, Liu & Li, 2021). Razón por la que se destacaron altas ventas en el primer semestre (Q1-Q2), con una caída marcada en el tercer trimestre y un leve repunte en diciembre.

Luego se replicó este análisis en el SKU 14385805, que representaba el 34% del volumen de ventas, convirtiéndose en uno de los productos clave del portafolio, donde primero se generó la descomposición de la serie de tiempo:

Figura 16: Descomposición de la serie de tiempo del volumen de venta del SKU 14385805



Fuente: Elaboración propia

Donde el SKU 14385805 mostró un comportamiento claramente creciente a lo largo del periodo analizado. Por otro lado, el componente estacional mostró repeticiones consistentes año tras año, destacando la importancia de los ciclos anuales en este SKU. mostrando picos claros en los meses de marzo, abril y mayo. En contraste, entre junio y octubre donde se observaron reducciones importantes, lo que indicó una fase valle en el ciclo anual. Este comportamiento evidenció una fuerte estacionalidad concentrada en el segundo trimestre del año.

Posteriormente, para el tratamiento de todos los productos que encabezan el portafolio de ventas, se clasificó a cada SKU en las categorías Smooth, Erratic, Lumpy e Intermittent, basándose en criterios como el coeficiente de variación, la frecuencia de ceros y la dispersión de los datos. A continuación, se presentan los resultados de la clasificación de los SKUs según su patrón de demanda:

Figura 17: Resumen de los resultados de la clasificación de los SKUs según su patrón de demanda.

Clasificación	SKU	ADI	CV
Smooth	13612675	1,05	0,41
	14385805	1,00	0,41
	17311455	1,00	0,44
Erratic	13606975	1,00	0,61
	13607005	1,27	1,15
	13611495	1,00	0,56
	13611505	1,00	0,51
	13611645	1,00	0,73
	13611675	1,07	2,10
	13611875	1,07	0,50
	14405215	1,00	0,59
	17021605	1,00	0,71
	17116745	1,29	1,43
	17133275	1,27	0,68
	17305645	1,15	1,38
	17311465	1,00	0,54
	17524005	1,20	0,85
Lumpy	13611705	1,45	1,41
	17234825	1,42	0,72

Fuente: Elaboración propia

En la tabla anterior, se encontró que, 3 SKUs pertenecen a la categoría “Smooth”, dado que, estos productos revelaron un comportamiento estable o ligeramente cíclico; por otro lado, 14 SKUs se clasificaron como “Erratic” ya que su demanda es altamente variable y sin un patrón claro con cambios impredecibles; mientras que, 2 SKUs corresponden a la categoría “Lumpy”, puesto que, se caracterizan por una demanda altamente irregular, con largos periodos de baja actividad y picos aislados intensos.

Una vez que se llevó a cabo el respectivo análisis de los SKUs más vendidos y fueron clasificados según su patrón de demanda, se diseñaron tres paquetes de modelos de pronóstico, donde se incluyeron combinaciones de los algoritmos más representativos destinados a cubrir las características que presenta el comportamiento de la demanda de los productos.

El paquete 1 estaba conformado por los siguientes modelos:

- Holt-Winters Exponential Smoothing
- ARIMA

- Prophet con regresores externos
- Random Forest

El paquete 2 se compone de los siguientes modelos:

- Moving Average
- SARIMAX
- XGBoost
- TSB (Teunter-Syntetos-Babai)

Por último, el paquete 3 incluye los siguientes modelos:

- Theta Model
- TBATS (Trigonometric, Box-Cox, ARMA errors, Trend and Seasonal components)
- NBATS (Neural Basis Expansion Analysis for Time Series Forecasting)
- LightGBM (Light Gradient Boosting Machine)

Cabe recalcar que cada paquete de modelos fue construido con la finalidad de que sea adaptable a distintos niveles de dificultad y capacidad operativa, permitiendo una aplicación flexible, sin embargo, no se descarta la incorporación de modelos adicionales en función de las necesidades que surjan al emplear la herramienta.

Para determinar el paquete de modelos más adecuado para los productos de la compañía, se evaluaron las distintas alternativas considerando tres aspectos clave: los requerimientos del cliente, los requisitos técnicos de la herramienta y las restricciones de diseño del proyecto.

Con este propósito, se aplicó un análisis multicriterio de decisión que midió el grado de cumplimiento de cada paquete respecto a dichos criterios. Este análisis se cuantificó mediante una escala de Likert, asignando los valores 1, 2 y 3 para indicar si el paquete no cumple, cumple parcialmente o cumple completamente, respectivamente. Posteriormente, se calculó el puntaje final ponderado para cada alternativa, lo que permitió comparar su desempeño relativo.

Los resultados de esta evaluación se presentan en las siguientes tablas, donde se evidenció el nivel de cumplimiento de cada paquete frente a los criterios establecidos.

Figura 18: Evaluación de los paquetes de modelos con respecto a los requerimientos del cliente.

Requerimientos del cliente	Calificación de importancia para el cliente	Paquete 1	Paquete 2	Paquete 3
Alta precisión en el pronóstico	10	3	3	3
Bajo costo de reformulación del producto	7	2	3	1
Consideración de eventos externos	5	3	3	2
Adaptabilidad a cambios repentinos	8	3	2	3
Gestión adecuada de recursos	9	2	3	1
Datos precisos y confiables	6	3	3	2
Weighted score		119	127	92
Weighted Score Percentage		35%	38%	27%

Fuente: Elaboración propia

Figura 19: Evaluación de los paquetes de modelos con respecto a los requerimientos técnicos.

Requerimientos técnicos	Porcentaje de importancia	Paquete 1	Paquete 2	Paquete 3
1. Tiempo promedio para generar el pronóstico ≤ 1 semana	10%	1	2	1
2. Precisión del pronóstico $\geq 65\%$	26%	2	2	1
3. Precisión en la detección de datos atípicos $> 90\%$	12%	1	2	1
4. Costo promedio de cambios en la estructura del producto $< \$478,528/\text{mes}$	20%	1	2	0
5. Número promedio de cambios en la planificación de producción $< 132/\text{mes}$	20%	1	2	1
6. Número de variables exógenas en los modelos ≥ 1	12%	2	2	1
Puntuación Ponderada		1,38	2	0,8

Fuente: Elaboración propia

Figura 20: Evaluación de los paquetes de modelos con respecto a las restricciones de diseño.

Restricción de diseño	Paquete 1	Paquete 2	Paquete 3
1. Dependencia de datos externos	2	2	1
2. Calidad de los datos históricos	1	2	1
3. Volatilidad de mercado	1	2	1
4. Experiencia limitada del usuario con herramientas	1	2	0
Puntaje	1,25	2	0,75

Fuente: Elaboración propia

Con base en la evaluación de los criterios mencionados respecto a las características de los modelos incluidos en cada paquete, se determinó que el Paquete 2 fue el más adecuado en todos los escenarios evaluados. Este paquete, conformado por Moving Average, SARIMAX, XGBoost y TSB, destacó por su equilibrio entre precisión, velocidad de procesamiento y facilidad de implementación, cumpliendo completamente con los requerimientos técnicos definidos por el cliente, como la generación de pronósticos en menos de una semana, la incorporación de variables exógenas y la detección de datos atípicos con alta precisión. Además, superó a los otros paquetes en la evaluación de restricciones de diseño, demostrando mayor adaptabilidad ante cambios en el mercado y limitaciones en la experiencia técnica de los usuarios. A diferencia del Paquete 1 que, aunque ofrecía precisión con ARIMA y Prophet, implicaba mayor complejidad operativa y sensibilidad a datos recientes, y del Paquete 3, que incorporaba modelos potentes como TBATS y NBATS pero requería altos recursos técnicos y limpieza de datos, siendo así que el Paquete 2 se posicionó como la opción más robusta, práctica y eficiente para la realidad del entorno analizado, lo que indicó que la herramienta debe estar conformada por al menos los algoritmos que componen dicho paquete, sin descartar la posibilidad de incluir modelos adicionales en etapas posteriores.

1.1.3 Análisis financiero

Para el análisis financiero de los tres paquetes de modelos propuestos para predecir la demanda, se tomó a consideración los costos asociados a su implementación, así como los beneficios percibidos como resultado de una reducción de gastos por la reformulación de los productos.

En primer lugar, se identificaron los gastos en los que incurre cada paquete de modelos, tales como la implementación inicial del modelo (que abarca el desarrollo, pruebas y puesta en marcha), el mantenimiento o actualización anual, los costos de reentrenamiento ante eventos inesperados, y la capacitación del personal involucrado, donde se estimó el número de horas requeridas para cada actividad según el nivel de complejidad de cada paquete y se estableció que el valor unitario sería de \$6.00 por hora, considerando el salario promedio de un analista de datos en Ecuador.

Posteriormente, se estimó el beneficio anual esperado por cada paquete de modelos con base en la reducción de costos generados por las reformulaciones de producto que se producen cuando las previsiones de la demanda no son adecuadas y se utilizan como alternativa materias primas más costosas o se deben realizar ajustes logísticos imprevistos que incrementan el gasto. Para ello, se calculó el promedio anual de sobrecostos y se consideró un porcentaje de mejora de precisión de pronóstico para cada paquete basado en el porcentaje de puntuación ponderada que obtuvieron en el análisis multicriterio de los requerimientos técnicos, de manera que a los paquetes 1, 2 y 3 se les asignó una mejora del 33%, 48% y 19% respectivamente.

Por último, se calculó el Valor Actual Neto (VAN) y la Tasa Interna de Retorno (TIR), empleando un horizonte de evaluación de 3 años y una tasa de descuento del 10%. A partir de este análisis se obtuvieron los resultados que se detallan a continuación:

Figura 21: Resumen del análisis financiero del paquete 1.

Paquete 1			
Concepto	Horas Estimadas	Costo Unitario (\$/h)	Costo Total (USD)
Implementación inicial	120	\$9,00	\$1.080,00
Mantenimiento/actualización anual	40	\$9,00	\$360,00
Reentrenamiento por cambios bruscos	25	\$9,00	\$225,00
Capacitación	65	\$9,00	\$585,00
TOTAL COSTO INICIAL			\$2.250,00
Beneficio anual estimado	\$1.359,20		
Valor Presente Neto (VAN)	\$324,00		
Tasa Interna de Retorno (TIR)	2,00%		

Fuente: Elaboración propia

Figura 22: Resumen del análisis financiero del paquete 2.

Paquete 2			
Concepto	Horas Estimadas	Costo Unitario (\$/h)	Costo Total (USD)
Implementación inicial	100	\$9,00	\$900,00
Mantenimiento/actualización anual	40	\$9,00	\$360,00
Reentrenamiento por cambios bruscos	30	\$9,00	\$270,00
Capacitación	70	\$9,00	\$630,00
TOTAL COSTO INICIAL			\$2.160,00
Beneficio anual estimado	\$1.969,86		
Valor Presente Neto (NPV)	\$1.133,00		
Tasa Interna de Retorno (IRR)	41%		

Fuente: Elaboración propia

Figura 23: Resumen del análisis financiero del paquete 3.

Paquete 3			
Concepto	Horas Estimadas	Costo Unitario (\$/h)	Costo Total (USD)
Implementación inicial	125	\$9,00	\$1.125,00
Mantenimiento/actualización anual	45	\$9,00	\$405,00
Reentrenamiento por cambios bruscos	40	\$9,00	\$360,00
Capacitación	80	\$9,00	\$720,00
TOTAL COSTO INICIAL			\$2.610,00
Beneficio anual estimado	\$787,94		
Valor Presente Neto (NPV)	-\$2.320,87		
Tasa Interna de Retorno (IRR)	-78%		

Fuente: Elaboración propia

Una vez realizado el análisis financiero, se encontró que el Paquete 2 demostró ser la mejor alternativa, dado que, tanto el Valor Actual Neto (VAN) y la Tasa Interna de Retorno (TIR) resultó

ser significativamente mayor en comparación con el resto de paquetes, ya que, como se observó, le paquete 3 obtuvo un VAN y TIR negativo, lo que indica que su implementación no es viable financieramente; mientras que el paquete 1 es viable económicamente sin embargo ofrece un retorno menor con respecto al paquete 2.

Finalmente, como resultado de los análisis realizados previamente se determinó que la herramienta que pronosticará la demanda deberá tener al menos los modelos del paquete 2, dado que, presentó el mejor escenario financiero con una tasa de retorno de 41% en un horizonte de 3 años. Además, el conjunto de modelos que lo conforman está balanceado técnicamente, de manera que pueden cubrir distintos comportamientos de la demanda, ya que poseen una alta adaptabilidad a las fluctuaciones del mercado, su implementación es amigable con el usuario y permiten incorporar variables exógenas. Sin embargo, cabe mencionar que no se descarta la posibilidad de ajustar la herramienta incluyendo más modelos.

Capítulo 3

3. Resultados y análisis

1.1.4 Evaluación y validación de la herramienta de pronóstico

El desarrollo de la herramienta en RStudio permitió realizar una evaluación sistemática de la demanda histórica de cada SKU, aplicando modelos estadísticos diferenciados según el patrón de comportamiento, las características estadísticas de la serie y las validaciones previas establecidas. Para ello, se emplearon paquetes especializados en series temporales como *forecast*, *tsintermittent* y *Metrics*, entre otros, que facilitaron tanto la modelación como la medición de la precisión de los resultados.

Con el fin de comprender la lógica de funcionamiento de la herramienta, la Figura X presenta el flujo de procesos que describe la relación entre los datos de entrada y los resultados obtenidos. Los inputs considerados incluyeron:

- i) la demanda histórica de los SKUs que conforman el 80% del volumen de ventas de la empresa (19 SKUs en total) en el periodo 2023–2025
- ii) El identificador de cada SKU y sus fechas de venta estandarizadas en formato mensual
- iii) Variables exógenas opcionales, como la temperatura promedio mensual.

Para poder entender de manera más detallada el diseño y uso del programa se detalla las diferentes etapas con su objetivo durante el uso del programa.

La base de datos iniciales se dividió en dos subconjuntos: un conjunto de entrenamiento (70%) y un conjunto de prueba (30%), lo cual permitió evaluar la trazabilidad y consistencia del desempeño de la herramienta.

Como parte del desarrollo de la herramienta, se consideró la incorporación de variables exógenas que puedan influir en la demanda. Entre estas, se incluyó la temperatura mensual, dada su relación con la actividad acuícola. Por ello se empleó un API climático que extrajo la

temperatura de los últimos 7 años, donde se evaluaron los modelos ARIMA y ETS, seleccionando el que tuvo un menor error para generar un pronóstico de 15 meses de temperatura. A continuación, se presentan los datos obtenidos:

Figura 24: Resultados del pronóstico de temperatura de los próximos 15 meses.

	Ciudad	Fecha	Pronostico	Colchon_3SD	IC95_Sup
1	Guayaquil	2025-09-01	25.69510	27.54952	26.90664
2	Guayaquil	2025-10-01	26.00233	28.36335	27.54484
3	Guayaquil	2025-11-01	26.24444	28.87133	27.96064
4	Guayaquil	2025-12-01	26.43523	29.21445	28.25096
5	Guayaquil	2026-01-01	26.58557	29.45533	28.46045
6	Guayaquil	2026-02-01	26.70405	29.62862	28.61474
7	Guayaquil	2026-03-01	26.79742	29.75551	28.73001
8	Guayaquil	2026-04-01	26.87099	29.84972	28.81706
9	Guayaquil	2026-05-01	26.92897	29.92044	28.88336
10	Guayaquil	2026-06-01	26.97466	29.97401	28.93420
11	Guayaquil	2026-07-01	27.01067	30.01490	28.97340
12	Guayaquil	2026-08-01	27.03904	30.04631	29.00375
13	Guayaquil	2026-09-01	27.06140	30.07055	29.02734
14	Guayaquil	2026-10-01	27.07902	30.08933	29.04572
15	Guayaquil	2026-11-01	27.09291	30.10394	29.06008

Fuente: Elaboración propia

El objetivo de este paso fue obtener los datos para evaluar la correlación que tiene esta variable exógena con el comportamiento de la demanda histórica de los SKUs, donde se estableció que, cuando la correlación es mayor a 0.4, el pronóstico de temperatura generado se toma como input en los modelos de series temporales SARIMAX y XGBoost, los cuales se incluyen en la evaluación junto a los modelos previamente asignados a los cuadrantes de clasificación de demanda de aquellos SKUs que poseen más de 18 meses de datos históricos.

Con el fin de seleccionar el modelo de pronóstico más adecuado, se implementó un proceso de clasificación de la demanda, en el cual se calcularon indicadores como el *Average Demand Interval* (ADI) y el coeficiente de variación cuadrado (CV^2). Estos valores permitieron ubicar cada

SKU en uno de los cuadrantes definidos por la tipología de Syntetos y Boylan (2005), diferenciando entre patrones suaves, erráticos, intermitentes o con comportamiento lumpy.

Posteriormente, se aplicó un proceso de validación múltiple sobre los modelos candidatos. En primera instancia, se implementó un esquema de *backtesting* de corto plazo, simulando predicciones en tiempo real. Este procedimiento fue esencial para asegurar que los modelos no solo ajustaran adecuadamente los datos históricos, sino que también mantuvieran capacidad predictiva hacia adelante. Cada modelo generó pronósticos a tres pasos, los cuales se compararon con los valores reales más recientes de la serie. Con ello se calcularon métricas de error como RMSE y MASE, proporcionando una medida inicial de ajuste.

Para reforzar la robustez del análisis, se incorporó además una validación cruzada temporal mediante la función `tsCV()`, que ejecuta pronósticos en múltiples orígenes rodantes y permite evaluar la estabilidad del error a lo largo de la serie. La combinación de estas métricas evitó depender de un único indicador y permitió equilibrar la precisión de corto plazo con la consistencia global. El criterio principal de selección fue el MASE (Mean Absolute Scaled Error), considerado más objetivo y comparable frente a otros indicadores tradicionales, ya que mide la precisión del pronóstico en relación con un modelo de referencia *naïve*, independientemente de la escala de la serie. Según Hyndman y Koehler (2006) y *Forecasting: Principles & Practice* (Hyndman & Athanasopoulos, 2018), los valores de MASE se interpretan de la siguiente manera:

- **MASE < 0.5** → ajuste excelente
- **0.5 ≤ MASE < 1.0** → ajuste adecuado y útil.
- **1.0 ≤ MASE < 2.0** → el modelo sigue siendo interpretable, pero con errores altos.
- **MASE ≥ 2.0** → desempeño pobre; indica que el modelo no captura la estructura de la serie.

Figura 25: Resultados del pronóstico de la demanda de cada SKU con un horizonte de 15 meses

SKU	Cuadrante	Modelo	Criterio	Error	Cantidad de m	Mes.1	Mes.2	Mes.3	Mes.4	Mes.5	Mes.6	Mes.7	Mes.8	Mes.9	Mes.10	Mes.11	Mes.12	Mes.13	Mes.14	Mes.15
13606975 Erratic	Holt	MASE_BT	0.778778	28	10112.86	29248.39	0	0	0	0	0	0	0	0	0	0	0	0	0	0
13607005 Erratic	Holt	MASE_BT	0.396658	28	6066.839	37171.14	37876.14	38521.528	39112.35	39653.218	40148.357	40601.63	41016.583	41744.202	42062.55	42353.983	42620.775	42865.01	43119.98	43375.98
13611495 Erratic	Holt	MASE_BT	1.100099	29	18700.15	112851.8	113464.7	114041.91	114585.42	115097.22	115579.17	116033	116460.37	116917.134	117241.76	117598.62	117934.65	118251.09	118549.06	118849.06
13611505 Erratic	ARIMA	MASE_BT	1.040395	27	84089.12	513917.1	521178.8	526799.35	531149.51	534516.47	537122.44	539139.4	540700.51	542433.95	543567.76	544127.98	544661.57	544897.17	544897.17	544897.17
13611645 Erratic	ETS	MASE_BT	0.574564	27	1359.829	8158.977	8158.977	8158.9767	8158.9767	8158.9767	8158.9767	8158.977	8158.9767	8158.9767	8158.9767	8158.9767	8158.9767	8158.9767	8158.9767	8158.9767
13611675 Erratic	ETS	MASE_BT	3.247327	29	48604.55	291627.3	291627.3	291627.27	291627.27	291627.27	291627.27	291627.27	291627.3	291627.27	291627.27	291627.27	291627.27	291627.27	291627.27	291627.27
13611705 Lumpy	TSB	MASE_BT	6.231641	29	76772.38	460634.3	460634.3	460634.26	460634.26	460634.26	460634.26	460634.3	460634.26	460634.26	460634.26	460634.26	460634.26	460634.26	460634.26	460634.26
13611875 Erratic	Holt	MASE_BT	1.076731	29	9278.592	43046.46	30673.87	18548.723	6665.0833	0	0	0	0	0	0	0	0	0	0	0
13612675 Smooth	ARIMA	MASE_BT	0.12003	23	790.2778	4741.667	4741.667	4741.6667	4741.6667	4741.6667	4741.6667	4741.6667	4741.6667	4741.6667	4741.6667	4741.6667	4741.6667	4741.6667	4741.6667	4741.6667
14385805 Smooth	ARIMA	MASE_BT	3.327192	28	144464.3	1312272	1647496	1899749.2	2089567.4	2232404	2339887.2	2420767	2481628.9	421237.79	2561889.2	2587821.8	2607336	2622020.1	2633069.9	2633069.9
14405215 Erratic	Holt	MASE_BT	1.851156	21	1355.739	8803.797	9360.698	9824.0317	10209.518	10530.237	10797.072	11019.07	11203.775	11485.295	11591.665	11680.163	11753.793	11813.052	11853.052	11853.052
17021605 Erratic	ETS	MASE_BT	1.04339	7	472.6136	2702.348	2066.673	1490.8667	14559.367	14559.367	14559.367	14670.4	14670.403	2445.0671	14670.403	14670.403	14670.403	14670.403	14670.403	14670.403
17116745 Erratic	Holt	MASE_BT	3.593938	22	121483.4	730658.4	732381.3	734069.81	735724.53	737346.15	738935.34	740492.7	742019	123919.12	744980.55	746417.05	747824.82	749204.43	750556.45	750556.45
17133275 Erratic	Holt	MASE_BT	0.000237	19	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
17234825 Lumpy	CROST	MASE_BT	0.550169	17	4438.681	26632.08	26632.08	26632.083	26632.083	26632.083	26632.083	26632.08	26632.083	4438.6806	26632.083	26632.083	26632.083	26632.083	26632.083	26632.083
17305645 Erratic	ARIMA	MASE_BT	0.068749	15	250	1500	1500	1500	1500	1500	1500	1500	1500	250	1500	1500	1500	1500	1500	1500
17311455 Smooth	SES	MASE_BT	1.028601	16	17289.51	103737.1	105702.9	117340.54	118867.55	114937.14	111225.43	103737.1	103737.07	17121.728	105158.55	105833.57	107012.55	106668.45	107477.23	107477.23
17311465 Erratic	Holt	MASE_BT	1.026924	16	12825.32	77577.72	78103.46	78545.125	78916.168	79227.88	79489.747	79709.74	79894.555	13341.636	80180.252	80289.83	80381.885	80459.222	80524.19	80524.19
17524005 Erratic	ETS	MASE_BT	1.093777	6	32434.82	194608.9	194608.9	194608.92	194608.92	194608.92	194608.92	194608.92	194608.92	32434.819	194608.92	194608.92	194608.92	194608.92	194608.92	194608.92

Fuente: Elaboración propia

Basado en este criterio, se seleccionaba el mejor modelo. En la implementación práctica, las fórmulas teóricas de los modelos de pronóstico (Media Móvil, SES, Holt-Winters, ETS, ARIMA, SARIMAX, Croston y TSB) no fueron programadas de manera manual, sino que se ejecutaron automáticamente mediante los paquetes estadísticos disponibles en **RStudio**. Entre ellos destacan los siguientes modelos:

Media móvil Simple (MA)

$$\hat{y}_{t+1} = \frac{1}{k} \sum_{i=0}^{k-1} y_{t-i}$$

Suavizamiento exponencial simple (SES)

$$\hat{y}_{t+1} = \alpha y_t + (1 - \alpha) \hat{y}_t$$

Holt-Winters (aditivo)

$$\hat{y}_{t+h} = (\ell_t + hb) + s_{t-m+h}$$

ETS (Error, Trend, Seasonality)

$$\hat{y}_{t+h} = \ell_t + b_t h + s_{t+h-m}$$

Arima (p,d,q)

$$\phi(B)(1-B)^d y_t = \theta(B) \epsilon_t$$

SArimax (con variables exógenas)

$$\phi(B)(1-B)^d - B^s)^D y_t = \theta(B) \epsilon_t$$

Croston

$$\hat{y}_{t+h} = \frac{\hat{z}_t}{\hat{p}_t}$$

TSB (Teunter –Syntetos-Babai)

$$\hat{y}_{t+1} = p_t z_t$$

Cabe mencionar que el output generado consistió en pronósticos puntuales (point forecasts) para cada SKU con un horizonte fijo de 15 meses, acompañados de intervalos de predicción al 80% y 95% de confianza. La incorporación de estos intervalos respondió a la necesidad de ofrecer no solo un valor esperado, sino también un rango de posibles escenarios que reflejara la incertidumbre inherente a la demanda. Tal como señalan Hyndman y Athanasopoulos (2018). En la herramienta desarrollada, los intervalos se calcularon automáticamente a partir de la varianza de los residuos de los modelos seleccionados.

Los resultados obtenidos fueron:

El **SKU 13606975** (*Erratic*, Holt) alcanzó un MASE de **0.77**, dentro del rango aceptable. El modelo representa adecuadamente la variabilidad de la serie.

El **SKU 13607005** (*Erratic*, Holt) obtuvo un MASE de **0.39**, lo que corresponde a un ajuste altamente preciso.

El **SKU 13611495** (*Erratic*, Holt) registró un MASE de **1.10**, justo en el umbral. Se considera aceptable, aunque refleja que el modelo apenas entra en el rango adecuado.

El **SKU 13611505** (*Erratic*, ARIMA) alcanzó un MASE de **1.04**. Indica un ajuste eficiente.

El **SKU 13611645** (*Erratic*, ETS) obtuvo un MASE de **0.57**, claramente aceptable.

El **SKU 13611675** (*Erratic*, ETS) presentó un MASE de **3.24**, aquí se presenta el primer modelo no adecuado dentro de los pronósticos.

El **SKU 13611705** (*Lumpy*, TSB) alcanzó un MASE de **6.23**, fuera del rango; el modelo no captura bien la dinámica de la serie.

El **SKU 13611875** (*Erratic*, Holt) registró un MASE de **1.07**, pronóstico al límite de la aceptabilidad por lo que se sugiere incidir en otros modelos.

El **SKU 13612675** (*Smooth*, ARIMA) obtuvo un MASE de **0.12**, excelente ajuste.

El **SKU 14405215** (*Erratic*, Holt) registró un MASE de **1.85**, por encima del rango; ajuste pobre.

El **SKU 17021605** (*Erratic*, ETS) alcanzó un MASE de **1.04**, dentro del rango aceptable.

El **SKU 17116745** (*Erratic*, Holt) obtuvo un MASE de **3.59**, ajuste pobre.

El **SKU 17133275** (*Erratic*, Holt) mostró un MASE de **0.000023**, el más bajo de la muestra; ajuste casi perfecto.

El **SKU 17234825** (*Lumpy*, Croston) alcanzó un MASE de **0.55**, confirmando la idoneidad del modelo para series intermitentes.

El **SKU 17305645** (*Erratic*, ARIMA) obtuvo un MASE de **0.06**, desempeño sobresaliente.

El **SKU 17311455** (*Smooth*, SES) alcanzó un MASE de **1.02**, muy positivo y coherente con el tipo de cuadrante.

El **SKU 17311465** (*Erratic*, Holt) presentó un MASE de **1.02**, aún dentro de la tolerancia; se considera aceptable, aunque con margen estrecho.

El **SKU 17524005** (*Erratic*, ETS) alcanzó un MASE de **1.09**, dentro del límite; se clasifica como válido al igual que los otros modelos que rondan por este valor del error.


De los 19 SKUs analizados:

- **15 SKUs (79%)** presentan un MASE dentro del rango aceptable. (Eficiencia de la herramienta)
- **4 SKUs (21%)** muestran errores por encima de 1 o 1.1, reflejando ajustes deficientes.

Esto indica que la herramienta logra seleccionar modelos adecuados para aproximadamente tres de cada cuatro SKUs, con especial solidez en cuadrantes *Smooth* y *Lumpy*, mientras que los cuadrantes *Erratic* siguen siendo los más desafiantes lo cual hace sentido teóricamente ya que es uno de los tipos de demanda con más variabilidad

Un aspecto relevante fue la aparición de SKUs con pronósticos de valor **0** para los próximos 15 meses. Al analizar sus series históricas, se observó un patrón de declive progresivo hasta la desaparición de ventas, lo que confirma que la herramienta proyecta la salida natural de estos productos, consistente con la realidad actual de la empresa.


Figura 26: Serie de tiempo del SKU 17133275 con patrón de declive progresivo.



Fuente: Elaboración propia

Finalmente, se identificó que algunos SKUs con **valores de MASE elevados** fueron aquellos en los que el modelo asignado generó pronósticos prácticamente constantes. Este comportamiento ocurre con mayor frecuencia en series erráticas con picos aislados, lo que limita la capacidad de los modelos tradicionales para identificar tendencias o estacionalidad.

Figura 27: Serie de tiempo de SKU 13611675 con picos aislados



Fuente: Elaboración propia

En tales casos, se recomienda explorar modelos alternativos que incorporen mayor flexibilidad y permitan capturar mejor la variabilidad observada.

En conjunto, este análisis demuestra que la herramienta desarrollada no solo automatiza la selección de modelos, sino que también proporciona resultados confiables en la mayoría de los casos, con un desempeño especialmente sólido en cuadrantes Smooth y Lumpy, mientras que los patrones Erratic continúan representando un desafío por su inherente volatilidad.

Para evaluar de manera puntual la mejora en la precisión del pronóstico, se empleó la misma fórmula utilizada por la empresa como referencia oficial de medición. Con este propósito, se generó el pronóstico mediante la herramienta desarrollada para el mes de julio de 2025, cuyos valores estimados fueron comparados con la demanda real registrada en ese período. Al aplicar la fórmula correspondiente, se obtuvo una precisión del 71%, lo que evidencia una mejora significativa frente a los niveles previamente alcanzados y valida la efectividad de la propuesta en condiciones reales de operación.

1.1.5 Análisis de sensibilidad

Con el propósito de evaluar la robustez de la herramienta y su comportamiento ante variaciones en las condiciones iniciales, se planteó un escenario de sensibilidad que permitió observar la estabilidad y flexibilidad del modelo frente a cambios en la demanda histórica.

Escenario: Incremento de la demanda histórica

Se aumentó en un 20% la demanda histórica de cada SKU, con el objetivo de analizar si la herramienta mantiene su capacidad de clasificación y selección de modelos bajo un mayor volumen de información.

Figura 28: Resultados del pronóstico con un incremento del 20% de la demanda en cada SKU.

SKU	Cuadrante	Modelo	Criterio	Error	Cantidad de m	Mes.1	Mes.2	Mes.3	Mes.4	Mes.5	Mes.6	Mes.7	Mes.8	Mes.9	Mes.10	Mes.11	Mes.12	Mes.13	Mes.14	Mes.15
13606975 Erratic	Holt	MASE_BT	0.978778	28	12135.43	35098.07	0	0	0	0	0	0	0	0	0	0	0	0	0	0
13607005 Erratic	Holt	MASE_BT	0.396658	28	7280.207	44605.37	45451.37	46225.834	46934.82	47583.862	48178.028	48721.96	49219.9	8279.2903	50093.042	50475.06	50824.78	51144.93	51438.012	51732.088
13611495 Erratic	Holt	MASE_BT	1.100099	29	22440.18	135422.2	136157.7	136850.3	137502.5	138116.67	138695.01	139239.6	139752.45	23372.561	140690.12	141118.34	141521.58	141901.3	142258.88	142626.12
13611505 Erratic	ARIMA	MASE_BT	1.040935	27	100906.9	616700.5	625414.6	632159.21	637379.42	641419.76	644546.92	646967.3	648840.61	108381.75	651412.74	652281.31	652953.57	653473.89	653876.61	654290.83
13611645 Erratic	ETS	MASE_BT	0.574564	27	1631.795	9790.772	9790.772	9790.772	9790.772	9790.772	9790.772	9790.772	9790.772	1631.7953	9790.772	9790.772	9790.772	9790.772	9790.772	9790.772
13611675 Erratic	ETS	MASE_BT	3.247327	29	58325.45	349952.7	349952.7	349952.73	349952.73	349952.73	349952.73	349952.73	349952.73	58325.455	349952.73	349952.73	349952.73	349952.73	349952.73	349952.73
13611705 Lumpy	TSB	MASE_BT	6.231641	29	92126.85	552761.1	552761.1	552761.11	552761.11	552761.11	552761.11	552761.11	552761.11	92126.851	552761.11	552761.11	552761.11	552761.11	552761.11	552761.11
13611875 Erratic	Holt	MASE_BT	1.076731	29	11134.31	51655.75	36808.64	22258.468	7999.3	0	0	0	0	0	0	0	0	0	0	0
13612675 Smooth	ARIMA	MASE_BT	0.12003	23	948.3333	5690	5690	5690	5690	5690	5690	5690	5690	948.33333	5690	5690	5690	5690	5690	5690
14385805 Smooth	ARIMA	MASE_BT	3.480106	28	173357.2	1574726	1976995	2279699	2507480.9	2678884.8	2807864.6	2904921	2977954.7	505485.35	3074267	3105386.2	3128803.1	3146424.2	3159683.8	3172345.5
14405215 Erratic	Holt	MASE_BT	1.851156	21	1626.887	10564.56	11252.84	11788.838	12251.422	12636.284	12956.486	13222.89	13444.53	2271.489	13782.354	13909.998	14016.196	14104.552	14178.062	14250.518
17021605 Erratic	ETS	MASE_BT	1.04339	7	567.1363	3242.818	2480.008	1789.04	17471.24	17471.24	17471.24	17604.48	17604.484	2934.0807	17604.484	17604.484	17604.484	17604.484	17604.484	17604.484
17116745 Erratic	Holt	MASE_BT	3.593938	22	145780.1	876790	878857.6	880883.77	882869.43	884815.38	886722.4	888591.3	890422.8	148702.95	893976.66	895700.46	897389.78	899045.32	900667.74	902340.16
17133275 Erratic	Holt	MASE_BT	0.045237	19	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
17234825 Lumpy	CROST	MASE_BT	0.550169	17	5326.417	31958.5	31958.5	31958.5	31958.5	31958.5	31958.5	31958.5	31958.5	5326.4167	31958.5	31958.5	31958.5	31958.5	31958.5	31958.5
17305645 Erratic	ARIMA	MASE_BT	0.068749	15	300	1800	1800	1800	1800	1800	1800	1800	1800	300	1800	1800	1800	1800	1800	1800
17311455 Smooth	SES	MASE_BT	1.020241	16	20747.41	124484.5	126843.5	140808.65	142641.06	137924.57	133470.52	124484.5	124484.49	20546.073	126190.26	127000.28	128415.06	128002.14	128972.68	129787.22
17311465 Erratic	Holt	MASE_BT	1.026924	16	15390.38	93093.26	93724.15	94254.15	94699.402	95073.456	95387.696	95651.69	95873.466	16009.963	96216.302	96347.796	96458.262	96551.066	96629.028	96707.092
17524005 Erratic	ETS	MASE_BT	1.093777	6	38921.78	235530.7	235530.7	235530.7	235530.7	235530.7	235530.7	235530.7	235530.7	38921.783	235530.7	235530.7	235530.7	235530.7	235530.7	235530.7

Fuente: Elaboración propia

Los resultados obtenidos evidenciaron que la clasificación de patrones de demanda (Smooth, Erratic, Lumpy, Intermittent) se mantuvo estable, lo que indica que el sistema es consistente frente a variaciones significativas en los datos de entrada. Asimismo, la selección de modelos estadísticos coincidió con los obtenidos en el escenario base, lo que refleja que el algoritmo conserva su criterio de decisión aún en condiciones de mayor exigencia.

En cuanto a la precisión, el MASE promedio mostró un ligero incremento en algunos de ellos:

El SKU 13606975 pasó de un MASE de 0.978 a 0.778

El SKU 14385805 pasó de un MASE de 3.480 a 3.327

El SKU 17133275 pasó de un MASE de 0.045 a 0.0002

El SKU 17311455 pasó de un MASE de 1.020 a 1.028

Las variaciones se encuentran dentro de los rangos aceptables, confirmando que el desempeño del modelo no se degrada de manera significativa. Adicionalmente, los pronósticos generados se ajustaron de forma proporcional al incremento en la demanda, garantizando coherencia y confiabilidad en los resultados proyectados.

Este análisis demuestra que la herramienta es estable y robusta frente a variaciones en la demanda, lo que fortalece la confianza en su aplicabilidad práctica y en la veracidad de la información obtenida a partir de su implementación

Con respecto a las especificaciones de diseño de la herramienta, se comprobó que la herramienta de pronóstico de la demanda cumplió con los criterios establecidos, dado que se incluyó una variable exógena (temperatura del agua), y se alcanzó una precisión de pronóstico de 71%, lo que disminuyó los reprocesos y como consecuencia el costo promedio de reformulación de los productos en un 6.09%. Asimismo, redujo el tiempo de generación de pronósticos, ya que la ejecución de los cálculos se realiza de manera automática en R Studio. Además, logró una detección de valores atípicos superior al 90% empleando validaciones cruzadas, backtesting y clasificación con base en el patrón de la demanda de los SKUs.

1.1.6 Análisis del Impacto Social, Económico y Ambiental

1.1.6.1 Impacto Social.

Para medir el impacto social se aplicó una encuesta de percepción dirigida a la Demand Planner de la empresa, orientada a evaluar distintos aspectos de la herramienta, como: su claridad y facilidad de uso, su utilidad para la planificación y su valor percibido.

En primer lugar, los resultados de la claridad y facilidad de uso evidenciaron que la herramienta fue percibida como altamente comprensible. La Demand Planner asignó la máxima puntuación (5/5) a la facilidad de entendimiento y a la claridad de los resultados, mientras que

calificó con un 4/5 la simplicidad de la navegación. Lo cual sugiere que, incluso en una fase preliminar, la interfaz y el flujo de trabajo son considerados intuitivos y amigables.

En cuando a la utilidad para la planificación, los resultados señalaron que, con relación a la reducción del tiempo de preparación de pronósticos (5/5), la automatización permite liberar horas actualmente invertidas en tareas manuales. La confianza en los pronósticos y la reducción de retrabajos alcanzaron 4/5, lo cual refleja una percepción positiva, aunque con margen de mejora. En conjunto, la percepción es que la herramienta incrementa la eficiencia y robustez del proceso de planificación.

Por último, el valor percibido de la herramienta fue elevado: 4/5 en satisfacción personal, y 5/5 tanto en aporte de valor como en recomendación de implementación. Esto evidencia que la herramienta no solo es vista como una solución funcional, sino también como un recurso que agrega valor estratégico a la empresa y que podría ser adoptado formalmente en el futuro.

Los resultados de la encuesta en conjunto arrojaron un 100% de satisfacción, dado que las respuestas obtuvieron puntuaciones de 4 y 5 en la escala Likert, lo cual refuerza que la herramienta contribuye a disminuir la frustración derivada de métodos tradicionales, optimizar la experiencia de toma de decisiones y mejorar la satisfacción del personal de planificación.

1.1.6.2 Impacto Económico

En el ámbito económico, el análisis comparativo entre los costos reales y proyectados antes de la herramienta mostró una brecha del 22,1% de sobre costo, atribuible en gran medida a la baja precisión del pronóstico (56%).

Con la aplicación de la nueva herramienta, se logró que una precisión del pronóstico de la demanda de 71.4%, lo que representa una mejora relativa del 27.5%% en la capacidad predictiva. Proyectando esta mejora sobre la brecha de costos histórica, se estima que la herramienta podría

generar una reducción del sobrecosto de manufactura por reformulaciones del 6.09% frente al escenario previo.

Este resultado evidencia que la dimensión económica se ve fortalecida por la herramienta, dado que la mejora en la calidad del pronóstico se traduce en una mayor eficiencia en el uso de recursos productivos generando menores sobrecostos por reformulación.

1.1.6.3 Impacto Ambiental

En el análisis ambiental, se identificó que, aun con la aplicación de la herramienta de pronóstico, el 28.6% de la demanda es pronosticada incorrectamente o con desviación significativa, lo que incrementa la probabilidad de reprogramaciones de la producción, las cuales generan reprocesos y, en consecuencia, un mayor consumo de energía, materias primas y recursos logísticos. Para estimar el impacto ambiental de estas reprogramaciones, se tomó en cuenta que la empresa ha registrado un mínimo de 10% de reproceso sobre la demanda pronosticada incorrectamente. Asimismo, se consideró un factor de emisión de 2.4 kg CO₂e por tonelada reprocesada, basado en el reporte de sostenibilidad de la compañía. Se utilizó el factor de emisión de Chile como referencia, ya que este país de la región refleja de manera representativa el consumo energético adicional y las emisiones asociadas al transporte y manipulación de materiales.

En consecuencia, la herramienta desarrollada permite una reducción del 35% en la huella de carbono aportando de forma significativa a la sostenibilidad ambiental, al disminuir la necesidad de reformulaciones y optimizar el uso de materias primas y energía.

Capítulo 4

4.1 Conclusiones y recomendaciones

4.1.1 Conclusiones

Una vez que se desarrolló la herramienta de pronóstico de demanda, se procedió a evaluar sus características y desempeño respecto a los objetivos planteados en el proyecto. En este proceso, se examinó el comportamiento histórico de la demanda de los SKUs con mayor rotación, a partir del cual se diseñaron modelos estadísticos robustos. Finalmente, se validaron los pronósticos generados por el modelo seleccionado en la herramienta. Con base en ello, se presentan las siguientes conclusiones:

La herramienta desarrollada en RStudio permitió mejorar de manera significativa la precisión de los pronósticos de la demanda, incrementando el nivel de exactitud de un 56% a un 71,4%, superando la meta planteada del 65%. Este resultado valida la efectividad de la propuesta y evidencia su aporte a la optimización de la planificación de producción y abastecimiento.

Se logró clasificar los SKUs más representativos (80% del volumen total) en los patrones Smooth (3 SKUs), Erratic (14 SKUs) y Lumpy (2 SKUs), lo que permitió seleccionar y aplicar los modelos de pronóstico más adecuados para cada comportamiento de la demanda. Este procedimiento garantizó una adaptación más precisa a las particularidades de cada serie temporal, reduciendo errores en la estimación.

La implementación de modelos estadísticos robustos (ARIMA, ETS, Holt, SES, Croston, TSB, Holt-Winters y SARIMAX con variables exógenas climáticas) amplió la capacidad explicativa y predictiva de la herramienta, incorporando factores externos relevantes que influyen en el comportamiento de la demanda acuícola.

Mediante la aplicación de backtesting y validación cruzada temporal (tsCV), se comprobó que el 79% de los SKUs alcanzó un MASE en rangos aceptables, lo que demuestra la consistencia y estabilidad de la herramienta incluso ante escenarios de variaciones de $\pm 20\%$ en la demanda. Estos resultados confirman que el sistema desarrollado es confiable, escalable y adaptable a condiciones cambiantes del mercado.

De igual manera, tras evaluar la herramienta bajo el enfoque de las tres dimensiones se la sostenibilidad se obtuvo resultados satisfactorios, dado que, en el ámbito social, la satisfacción laboral se incrementó en un 79.86%, destacando en aspectos como la claridad, facilidad de uso, utilidad para la planificación y valor percibido de la herramienta estadística. En el ámbito económico, la mejora en la precisión del pronóstico de la demanda permitió proyectar una reducción de 6.09% en los sobrecostos de manufactura causados por las reformulaciones, optimizando así la eficiencia operativa. Por último, en el aspecto ambiental, como producto de la disminución de reprocesos por reformulaciones, se produce una reducción del 35% en la huella de carbono.

Finalmente, se concluye que la herramienta no solo cumple con los objetivos técnicos planteados, sino que también aporta beneficios económicos al reducir costos asociados a la planificación deficiente, beneficios sociales al mejorar la confianza y eficiencia de los procesos internos, y beneficios ambientales al disminuir el impacto de reprocesos y reformulaciones. En conjunto, se trata de una solución integral que fortalece la competitividad y sostenibilidad de la empresa en el sector acuícola.

4.1.2 Recomendaciones

Dado que las condiciones del mercado y la dinámica de la demanda son variables, se recomienda recalibrar los modelos de manera periódica (trimestral o semestral), con el fin de

mantener la precisión de los pronósticos y asegurar que la herramienta se mantenga alineada con los cambios en el entorno.

Para garantizar la sostenibilidad del proyecto, se sugiere capacitar al equipo de planificación y cadena de suministro en el uso de la herramienta, de modo que puedan interpretar adecuadamente los resultados, realizar ajustes cuando sea necesario y aprovechar al máximo su potencial en la toma de decisiones estratégicas.

Asimismo, es fundamental mantener altos estándares de calidad en los datos históricos, ya que la herramienta depende de las tendencias y patrones de estacionalidad presentes en esta información. Por ello, se recomienda establecer un proceso continuo de depuración, validación y trazabilidad de los registros de ventas, que permita una reducción de errores y se incremente la confiabilidad en la herramienta.

Finalmente, se aconseja ampliar progresivamente la cobertura de la herramienta hacia más SKUs del portafolio, de manera que se incremente su impacto en la planificación global de la empresa y se fortalezcan los beneficios económicos, sociales y ambientales asociados a su implementación.

Referencias bibliográficas

- Bandara, K., Bergmeir, C., & Smyl, S. (2020). Forecasting across time series databases using recurrent neural networks on groups of similar series: A clustering approach. *Expert Systems with Applications*, 140, 112896. <https://doi.org/10.1016/j.eswa.2019.112896>
- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2016). *Time series analysis: Forecasting and control* (5th ed.). Wiley.
- Chase, C. W. (2013). *Demand-driven forecasting: A structured approach to forecasting*. Wiley.
- Gardner, E. S. (2006). Exponential smoothing: The state of the art—Part II. *International Journal of Forecasting*, 22(4), 637–666. <https://doi.org/10.1016/j.ijforecast.2006.03.005>
- Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and practice* (3rd ed.). OTexts. <https://otexts.com/fpp3/>
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2018). Statistical and machine learning forecasting methods: Concerns and ways forward. *PLOS ONE*, 13(3), e0194889. <https://doi.org/10.1371/journal.pone.0194889>
- IBF (Institute of Business Forecasting & Planning). (2020). *Best practices in demand planning and forecasting*.
- Syntetos, A. A., & Boylan, J. E. (2005). The accuracy of intermittent demand estimates. *International Journal of Forecasting*, 21(2), 303–314. <https://doi.org/10.1016/j.ijforecast.2004.10.001>
- Skretting. (2022). *The carbon footprint of our products*. <https://www.skretting.com/en/sustainability/sustainability-reporting/sustainability-report-2022/roadmap-2025/climate-and-circularity/the-carbon-footprint-of-our-products/>

Ren, X., Wang, Q., Shao, H., Xu, Y., Liu, P., & Li, J. (2021b). Effects of low temperature on shrimp and crab physiology, behavior, and growth: A review. *Frontiers In Marine Science*, 8. <https://doi.org/10.3389/fmars.2021.746177>

Ministerio de Producción, Comercio Exterior, Inversiones y Pesca (MPCEIP). (2025). *Análisis trimestral de comercio exterior 2024*. Recuperado de <https://www.produccion.gob.ec/wp-content/uploads/2025/02/Analisis-trimestral-de-comercio-exterior-2024.pdf>