



**UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO**  
PROGRAMA DE MAESTRÍA Y DOCTORADO EN INGENIERÍA  
INGENIERÍA EN SISTEMAS – INGENIERÍA INDUSTRIAL

USO DEL PRONÓSTICO DE LA DEMANDA PARA PROPONER UN PLAN DE VENTAS  
Y  
OPERACIONES EN EMPRESAS DE SERVICIOS.

TESIS  
QUE PARA OPTAR POR EL GRADO DE:  
MAESTRO EN INGENIERÍA

PRESENTA:  
CYNTHIA ALEXIA ALVAREZ MONTIEL

TUTOR PRINCIPAL  
M.I. FRANCISCA IRENE SOLER ANGUIANO  
FACULTAD DE INGENIERÍA

Ciudad Universitaria, Ciudad de México, febrero 2023



Universidad Nacional  
Autónoma de México

Dirección General de Bibliotecas de la UNAM

**Biblioteca Central**



**UNAM – Dirección General de Bibliotecas**  
**Tesis Digitales**  
**Restricciones de uso**

**DERECHOS RESERVADOS ©**  
**PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL**

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

**JURADO ASIGNADO:**

Presidente: Dra. Flores De La Mota Idalia

Secretario: Dr. Rivera Colmenero José Antonio

Vocal: M. I. Soler Anguiano Francisca Irene

1 er. Suplente: Dr. Del Moral Dávila Manuel

2 d o. Suplente: M. en I. Rodríguez Rubio Jorge

Universidad Nacional Autónoma de México, Facultad de Ingeniería.

**TUTOR DE TESIS:**

M. I. Soler Anguiano Francisca Irene

  
-----  
**FIRMA**

## AGRADECIMIENTOS

A mis padres por su apoyo incondicional y por su esfuerzo para que mis hermanas y yo podamos superarnos personal y profesionalmente.

A mis hermanas, a Nini y a mi familia por su cariño y por acompañarme en todo momento.

A la Universidad Nacional Autónoma de México por todas las oportunidades que me ha dado, por permitirme cursar mi licenciatura y mis estudios de maestría.

A la unidad de posgrado por la beca otorgada para la realización de mis estudios de maestría mediante el Programa de Becas de la CEP.

A SOFTING por brindarme la oportunidad de aprender y por permitir el desarrollo de este trabajo de investigación.

A las maestras Francis Soler y Carmen García por su apoyo y guía para la realización de este trabajo y durante mis estudios de maestría.

A mi amiga Ale Márquez por acompañarme de principio a fin en esta etapa de mi vida, por las risas, desvelos, por todo su apoyo y por motivarme a seguir aprendiendo y creciendo profesionalmente.

A mis amigos Samuel Romero, Alan Trejo y Alex Roa por acompañarme, apoyarme y por estar siempre presentes aún a la distancia.

A mis compañeros por compartir sus experiencias, conocimientos y por su apoyo.

A los miembros del jurado: la Dra. Idalia Flores De La Mota, el Dr. José Antonio Rivera Colmenero y el Maestro Jorge Rodríguez Rubio por sus aportaciones, apoyo y dirección en el trabajo de tesis.

Y al Dr. Manuel Del Moral Dávila por impulsarme, por compartir su conocimiento y experiencias, por contribuir en mi crecimiento personal y profesional y por creer en mí desde el primer momento.

## DEDICATORIA

*A mis familiares que ya no están con nosotros, pero de quienes guardo su recuerdo, amor y enseñanzas y sin quienes hoy no sería la persona que soy.*

*En especial para mi tía Nieves Machado y para mi abuelo Blas Montiel.*

# Índice

ÍNDICE DE SIGLAS Y ABREVIACIONES	I
ÍNDICE DE ILUSTRACIONES	II
ÍNDICE DE TABLAS	III
RESUMEN	IV
ABSTRACT	V
INTRODUCCIÓN	1
CAPÍTULO 1. LA CADENA DE SUMINISTRO	3
1.1 Factores de impacto en la Cadena de Suministro: la volatilidad de la demanda.	5
1.2 Importancia de la planeación de la producción y de los pronósticos de la demanda en la Cadena de Suministro.	7
CAPÍTULO 2. PLANEACIÓN DE LA PRODUCCIÓN Y PRONÓSTICOS DE LA DEMANDA	9
2.1 Planeación de la demanda	14
2.1.1 Planeación de la demanda en el sector servicios	15
2.2 Categorización de la demanda	18
2.2.1 Categorización de demanda con patrones irregulares	19
2.3 Pronósticos de la demanda	22
2.3.1 Técnicas clásicas de pronóstico	23
2.3.2 Previsión de demanda intermitente y Lumpy	28
2.4 Errores de pronóstico clásicos	31
2.5 Error de pronóstico para series de demanda intermitentes y lumpy	32
2.5.1 Costo del Error de Predicción orientados al Mantenimiento de Existencias (SPEC)	32
2.6 Planeación de la producción y pronósticos de la demanda: herramientas de apoyo.	34
CAPÍTULO 3. MODELOS PREDICTIVOS DE DEMANDA BASADOS EN INTELIGENCIA ARTIFICIAL	36
3.1 Modelos predictivos basados en Machine Learning para pronosticar la demanda de productos.	37
3.1.1 Redes neuronales artificiales	37

3.1.2 Perceptrón Multicapa (Multi Layer Perceptron o MLP)	38
3.1.3 Árboles de clasificación y regresión (CART)	39
3.1.4 Máquinas de soporte vectorial (SVM)	40
3.2. Conjuntos de entrenamiento, validación y prueba.	41
3.3. Comparación de modelos de pronóstico tradicionales con modelos basados en Inteligencia Artificial: estado del arte.	41
3.3.1 Modelos de pronóstico basados en Inteligencia Artificial para demanda “Lumpy”	42
3.3 Desventajas de utilizar modelos de pronóstico de demanda basados en ML	43
3.4 Minería de datos y Machine Learning	44
3.4.1 Metodología CRISP-DM	45
CAPÍTULO 4. PROPUESTA METODOLÓGICA	47
CAPÍTULO 5. CASO DE ESTUDIO	50
5.1 Antecedentes del caso de estudio	50
5.2 Selección de variables de interés	52
5.3 Recolección y análisis de datos	52
5.3.1 Análisis de datos (Administrador XML)	53
5.4 Preparación de los datos	58
5.5 Modelado	60
5.5.1 Selección del modelo de pronóstico	60
5.5.2 Desarrollo de modelos de predicción	61
5.6 Evaluación del modelo	65
5.7 Análisis de resultados	76
5.7.1 Análisis de resultados de acuerdo con la métrica MAD	80
5.7.2 Análisis de resultados de acuerdo con la métrica MSE	80
5.7.3 Análisis de resultados de acuerdo con la métrica SPEC	80
5.8 Propuesta del plan de ventas y operaciones S&OP	85

Modelo de las 5 fuerzas de Porter	86
Balanced Scorecard	88
5.8.1 Plan de demanda	89
5.8.2 Plan de oferta	94
5.8.3 Revisión financiera Pre - S&OP	96
5.8.4 Junta S&OP	97
Indicadores de desempeño	99
CONCLUSIONES Y RECOMENDACIONES	102
REFERENCIAS	104
ANEXOS	108
Anexo 1. Análisis estadístico de la serie de tiempo de ventas del AXML en Jupyter (Código)	108
Anexo 2. Preparación de los datos: transformación de serie de tiempo a problema de aprendizaje supervisado (Código)	109
Anexo 3. Creación y compilación de la red neuronal para los modelos MLP de una variable y multivariable (Código)	111
Anexo 5. Error de pronóstico de los modelos MLP (Código y resultados)	113
Anexo 6. Pronóstico de demanda de períodos futuros (Código)	116
Anexo 7. Error de pronóstico del modelo de SyB (Código y resultados)	117
Anexo 8. Estrategia de marketing	118
Anexo 9. Plantillas de entregables de la reunión Financiera	119
Anexo 10. Acta de reunión S&OP	121

## Índice de siglas y abreviaciones

ADI: Promedio del Intervalo entre Demandas

ANN: Redes neuronales artificiales

*AXML: Administrador XML*

BSC: Cuadro de mando (Balanced Scorecard)

CART: Árboles de clasificación y regresión

CS: Cadena de Suministro

$C_V^2$ : Coeficiente de Variación Cuadrática

DM: Minería de datos (Data mining)

IA: Inteligencia Artificial

MAD: Promedio del Intervalo entre Demandas (ADI)

MAPE: Error porcentual medio absoluto

ML: Machine Learning

MLP: Perceptrón Multicapa (Multi-Layer Perceptron)

MSE: Error cuadrado medio

RNAs: Redes Neuronales

SAE: Suma acumulada de errores de pronóstico

SPEC: Costo del Error de Predicción orientados al Mantenimiento de Existencias

SVM: Máquinas de soporte vectorial

S&OP: Plan de Ventas y Operaciones

## Índice de ilustraciones

Ilustración 1. Partes de la Cadena de Suministro.	4
Ilustración 2. Cadena de Suministro desde el enfoque sistémico.	5
Ilustración 3. Factores que han impactado en la Cadena de Suministro de las empresas.	6
Ilustración 4. Factores de impacto en la Cadena de Suministro por tipo de industria.	7
Ilustración 5. Comparación de volúmenes de planeación, producción realizada con relación a los planes de las empresas y planeación de materia prima del sector manufacturero en México durante el primer trimestre del año 2020.	8
Ilustración 6. Modelo S&OP	9
Ilustración 7. Proceso S&OP.	10
Ilustración 8. Balanced Scorecard.	12
Ilustración 9. Las cinco fuerzas competitivas de Porter.	13
Ilustración 10. Modelo de Madurez del proceso S&OP	13
Ilustración 11. El Ciclo de Demanda-Producción.	14
Ilustración 12. Estrategias para gestionar la capacidad en empresas de servicios.	17
Ilustración 13. Patrones de Demanda.	19
Ilustración 14. Demanda irregular, errática o aleatoria.	19
Ilustración 15. Demanda intermitente.	20
Ilustración 16. Demanda de movimiento lento.	20
Ilustración 17. Demanda Lumpy.	21
Ilustración 18. Esquema de categorización de demanda.	22
Ilustración 19. Algoritmo método Croston	29
Ilustración 20. Categorización de la demanda y modelo de previsión.	30
Ilustración 21. Propiedades de las métricas estadísticas clásicas y SPEC.	33
Ilustración 22. Modelo de Redes Neuronales.	38
Ilustración 23. Representación de MLP con una capa oculta.	39
Ilustración 24. Árboles de clasificación y regresión.	40
Ilustración 25. Máquinas de soporte vectorial.	41
Ilustración 26. Metodología CRISP-DM	45
Ilustración 27. Metodología propuesta para el caso de estudio.	47
Ilustración 28. Organigrama por áreas de Softing.	50
Ilustración 29. Serie de tiempo de ventas del AXML	54
Ilustración 30. Serie de tiempo de ventas del AXML (unidades y actualizaciones)	54
Ilustración 31. Esquema de categorización de demanda: Unidades y Actualizaciones vendidas del AXML.	57
Ilustración 32. Correlación entre las variables "unidades" y "actualizaciones".	58
Ilustración 33. Vista de los datos de la serie de tiempo	58
Ilustración 34. Ejemplo de serie de tiempo vs aprendizaje supervisado.	59
Ilustración 35. Preparación de los datos: transformación de la serie de tiempo a un problema de aprendizaje supervisado para el modelo de una variable.	59
Ilustración 36. Preparación de los datos: transformación de la serie de tiempo a un problema de aprendizaje supervisado para el modelo de dos variables.	60
Ilustración 37. Visualización de los datos de entrada para el modelo MLP de una variable.	61
Ilustración 38. Visualización de los datos de entrada para el modelo MLP de dos variables.	62
Ilustración 39. Ejemplo de una neurona artificial.	63
Ilustración 40. Keras Model Life-Cycle.	63
Ilustración 41. Validate loss del modelo de una variable en Jupyter	65
Ilustración 42. Validate loss del modelo multivariable en Jupyter	66
Ilustración 43. Precisión del modelo de una variable en Jupyter	66
Ilustración 44. Precisión del modelo multivariable en Jupyter	67
Ilustración 45. Pronóstico vs demanda real del modelo MLP de una variable en Jupyter	67
Ilustración 46. Pronóstico vs demanda real del modelo MLP multivariable en Jupyter	68
Ilustración 47. Datos de entrada para el pronóstico de periodos futuros en Jupyter	70
Ilustración 48. Datos de entrada para el pronóstico con una variable en Jupyter	71
Ilustración 49. Datos de entrada para el pronóstico con dos variables en Jupyter	71

Ilustración 50. Pronóstico de periodos futuros con el modelo MLP de una variable en Jupyter	72
Ilustración 51. Valores del pronóstico de periodos futuros con el modelo MLP de una variable en Jupyter	72
Ilustración 52. Pronóstico de periodos futuros con el modelo MLP multivariable en Jupyter	73
Ilustración 53. Valores del pronóstico de periodos futuros con el modelo MLP multi variable en Jupyter	73
Ilustración 54. Formato de datos para el modelo de Syntetos y Boylan	74
Ilustración 55. Vista previa de la aplicación del algoritmo de Croston en Excel	75
Ilustración 56. Pronóstico de la demanda vs demanda real usando el modelo SyB en Jupyter	76
Ilustración 57. Comparación de los modelos de pronóstico vs la demanda real en Jupyter	77
Ilustración 58. Comparación de modelos de pronóstico segunda mitad en Jupyter	78
Ilustración 59. Modelo SyB con 40 periodos de prueba.	82
Ilustración 60. Pronóstico de la demanda vs pronóstico real utilizando SyB durante 40 periodos	83
Ilustración 61. Comparación de los pronósticos de periodos futuros de los tres modelos.	83
Ilustración 62. Comparación de los pronósticos de periodos futuros de los tres modelos.	84
Ilustración 63. Propuesta del proceso de S&OP en el caso de estudio.	86
Ilustración 64. Mapa estratégico de Softing	89
Ilustración 65. Proceso de plan de demanda.	90
Ilustración 66. Árbol estructural de servicio para la venta de una licencia del AXML.	91
Ilustración 67. Calendario de actividades del proceso S&OP.	98

## Índice de tablas

Tabla 1. Métodos cualitativos	25
Tabla 2. Métodos de series de tiempo	26
Tabla 3. Métodos causales de pronóstico	27
Tabla 4. Servicios que ofrece la empresa Softing	51
Tabla 5. Descripción estadística de la serie de tiempo.	55
Tabla 6. Indicadores de categorización de la demanda	56
Tabla 7. Métricas de desempeño de los modelos MLP	69
Tabla 8. Errores de pronóstico del modelo estadístico SyB	75
Tabla 9. Comparación de error de pronóstico de los tres modelos	80
Tabla 10. Pronóstico para los periodos futuros	85
Tabla 11. Lista estructurada de servicios para la venta de una licencia del AXML	92
Tabla 12. Programación de colaboradores y costos para satisfacer la demanda.	93
Tabla 13. Capacidad máxima del elemento colaboradores.	95
Tabla 14. Asignación de tareas del proceso S&OP por área.	97
Tabla 15. Indicadores de desempeño para el BSC.	99
Tabla 16. Indicadores de desempeño para el nivel de madurez 1 del proceso S&OP.	100
Tabla 17. Estrategias de Marketing	118

## Resumen

El pronóstico de la demanda es un paso esencial para el desarrollo de una planeación eficiente dentro de las empresas, ya sean manufactureras o de servicios, pues es una herramienta que permite reducir la incertidumbre que existe en su ambiente. Si bien una de las características del pronóstico es que comúnmente es incorrecto, permite tener una base para tomar decisiones ante los eventos futuros que pueden presentarse y anticipar estos cambios adaptando la Cadena de Suministro (CS).

Por ello, en los últimos años se han aprovechado las nuevas tecnologías y se han renovado las técnicas para pronosticar la demanda con el fin de mejorar su precisión y hoy en día pueden ocuparse no solo modelos basados en la estadística sino también en inteligencia artificial.

El objetivo de este proyecto es desarrollar un plan de ventas y operaciones con base en el pronóstico de la demanda utilizando herramientas de Machine Learning (ML) en una empresa de servicios, para lo que se hace una comparación entre el modelo Multi-Layer Perceptron de una variable y de dos variables basado en ML y un modelo estadístico (algoritmo de Croston modificado por Syntetos y Boylan).

El presente trabajo de investigación se desarrolla de la siguiente manera:

En el **Capítulo 1** se hace una revisión de la cadena de suministro desde el enfoque sistémico, los factores de impacto en la cadena y la importancia del pronóstico de demanda y la planeación de la producción en la CS.

En el **Capítulo 2** se explica en qué consiste la planeación de la producción, el plan de ventas y operaciones y el pronóstico de la demanda, así como su categorización incluyendo los tipos de demanda intermitente y grumosa o lumpy, las técnicas que se utilizan para calcularlo y las métricas de error de pronóstico.

En el **Capítulo 3** se realiza una revisión de literatura sobre los modelos predictivos basados en inteligencia artificial, se explican las ciencias y técnicas involucradas (IA, ML y Minería de Datos) así como los diferentes algoritmos y se presenta la metodología CRISP-DM utilizada para el trabajo de análisis y minería de datos.

En el **Capítulo 4** se presenta la propuesta metodológica a seguir en el caso de estudio.

En el **Capítulo 5** se desarrolla la metodología, se hace la descripción del caso de estudio, la selección de variables de interés para el pronóstico, la recolección y análisis de datos, el desarrollo de los modelos de pronóstico, su interpretación y la propuesta del plan de ventas y operaciones.

Finalmente se presentan las conclusiones y recomendaciones.

## Abstract

Demand forecasting is an essential step for the development of efficient planning in companies, whether they are manufacturing or service companies, as it is a tool that allows reducing the uncertainty that exists in their environment. Although one of the characteristics of forecasting is that it is commonly incorrect, it provides a basis for making decisions about future events that may occur and anticipating these changes by adapting the Supply Chain (SC).

For this reason, new technologies have been taken advantage of and techniques for forecasting demand have been renewed to improve their accuracy and nowadays not only models based on statistics but also on artificial intelligence can be used.

The objective of this project is to develop a sales and operations plan (S&OP) based on demand forecasting using Machine Learning (ML) tools in a service company, for which a comparison is made between the Multi-Layer Perceptron model of one variable and two variables based on ML and a statistical model (Croston algorithm modified by Syntetos and Boylan).

The present research work is developed as follows:

**Chapter 1** reviews the supply chain from the systemic approach, the impact factors in the chain and the importance of demand forecasting and production planning in SC.

**Chapter 2** explains what production planning, the sales and operations plan and demand forecasting consist of, as well as its categorization, including the types of intermittent and lumpy demand, the techniques used to calculate it and the forecast error metrics.

**Chapter 3** reviews the literature on artificial intelligence-based predictive models, explains the sciences and techniques involved (AI, ML and Data Mining) as well as the different algorithms and presents the CRISP-DM methodology used for the analysis and data mining.

**Chapter 4** presents the methodological proposal to be followed in the case study.

**Chapter 5** develops the methodology, describes the case study, the selection of variables of interest for the forecast, the data collection and analysis, the development of the forecast models, their interpretation and the proposed sales and operations plan.

Finally, conclusions and recommendations are presented.

## Introducción

Actualmente las compañías enfrentan diferentes retos asociados con mejorar su participación en el mercado y con el incremento de la lealtad de sus clientes. Entre las causas que originan estos retos se puede mencionar, principalmente, la incertidumbre.

La cadena de suministro (CS) de las empresas juega un papel importante en la rentabilidad de esta, en su crecimiento y desarrollo. Una CS eficaz permite que las empresas logren tal cometido a través de la satisfacción y lealtad de los clientes y proveedores, en la reducción de costos y en la eficiencia de procesos y, además, su correcta gestión colabora con el adecuado manejo de la incertidumbre.

Sin embargo, la CS de las empresas enfrentan distintos retos para lograr su correcto funcionamiento. Entre estos destaca la volatilidad de la demanda dado que es uno de los factores que las empresas no pueden controlar.

No obstante, la demanda es un elemento que las empresas pueden prever y, por tanto, les permite prepararse considerando sus recursos y así tomar decisiones para continuar con su desarrollo y alcanzar sus objetivos. Para ello es fundamental que dentro de los negocios se desarrollen pronósticos de demanda con el objetivo de tener una herramienta que permita tener una base para la toma de decisiones para anticiparse a tendencias y exigencias que las actividades de planeación requieran.

Actualmente existen diferentes herramientas que pueden utilizarse para calcular el pronóstico de la demanda, dado que se ha buscado que estos mejoren su exactitud para alcanzar un valor cercano a la demanda real y así reducir la incertidumbre que generan en la toma de decisiones. Una de estas herramientas son las basadas en la Inteligencia Artificial (IA).

El uso de esta tecnología ha causado gran impacto en la gestión de la cadena de suministro, pues ha aportado en la mejora del proceso de toma de decisiones a través de sus aplicaciones, así como la creación de escenarios que permiten predecir la demanda, formados mediante la evaluación de parámetros que permiten dar aproximaciones más cercanas a la demanda real.

De este modo, la implementación de un modelo de pronóstico de la demanda basado en IA aporta una base más confiable para la planeación y toma de decisiones, además de tener una visión anticipada a los posibles cambios en la demanda e identificar los factores que influyen en ello.

Por esta razón, en este trabajo de investigación se desarrolla un plan de ventas y operaciones con base en el pronóstico de la demanda utilizando herramientas de Machine Learning (ML); cuyos objetivos específicos son: caracterizar el pronóstico y la planeación de la demanda, identificar los modelos que se utilizan actualmente para la obtención de pronósticos, implementar herramientas basadas en Machine Learning para poder diseñar la oferta a la medida utilizando los parámetros seleccionados y evaluar si la aplicación del modelo de predicción ayuda en la toma de decisiones en la planeación.

Uso del pronóstico de la demanda para proponer un plan de ventas y operaciones en empresas de servicios.

---

El alcance del presente trabajo es proponer un modelo de Machine Learning para el pronóstico de demanda como herramienta para el desarrollo de un plan de ventas y operaciones en una empresa.

## Capítulo 1. La Cadena de Suministro

La cadena de suministro (CS) es parte vital de las empresas pues de ella depende la coordinación de procesos clave para el correcto funcionamiento de esta, para obtener flujos más eficientes y eficaces y ventaja competitiva; para la correcta comprensión de esta es importante conocer a que se refiere.

Krajewski, Ritzman y Malhotra definen a la Cadena de Suministro como “la red de servicios, materiales y flujos de información que vincula los procesos de relaciones con los clientes, surtido de pedidos y relaciones con los proveedores de una empresa con los procesos de sus proveedores y clientes” (Krajewski, Ritzman, & Malhotra, 2008). Entonces, la Cadena de Suministro abarca todos los procesos que van desde el o los proveedores hasta el cliente final y está integrada por un conjunto de empresas (proveedores, fabricantes, distribuidores y vendedores) que se relacionan entre sí y tienen como propósito cumplir un objetivo en común.

De esta manera, las empresas han entrado a esta “red de servicios, materiales y flujos de información” y comparten un objetivo en común tanto con sus proveedores como con sus distribuidores y con los vendedores encargados de hacer llegar su producto al cliente final. Lo que se busca al final es un ganar-ganar.

A partir de dicha información es posible considerar la CS como un sistema, refiriéndonos a sistema como “un conjunto de dos o más elementos que exhibe las siguientes características:

- Las propiedades o el comportamiento de cada elemento del conjunto tienen un efecto en las propiedades o comportamiento del todo;
- Las propiedades o el comportamiento de cada elemento y la forma en que afectan al todo dependen de las propiedades y comportamiento de al menos otro elemento del conjunto;
- Cada subgrupo posible exhibe las dos propiedades anteriores” (Fuentes, 1995).

Con la finalidad de lograr una Cadena de Suministro eficiente es importante tomar en cuenta el correcto funcionamiento de cada una de las partes que la componen, ya que, cada una de las partes modifica la CS e influye la manera en que interactúan entre sí y el entorno en el que se desarrolla.

Dicha integración está conformada por: proveedores, producción, distribuidor, cliente intermediario (vendedores) y cliente final.

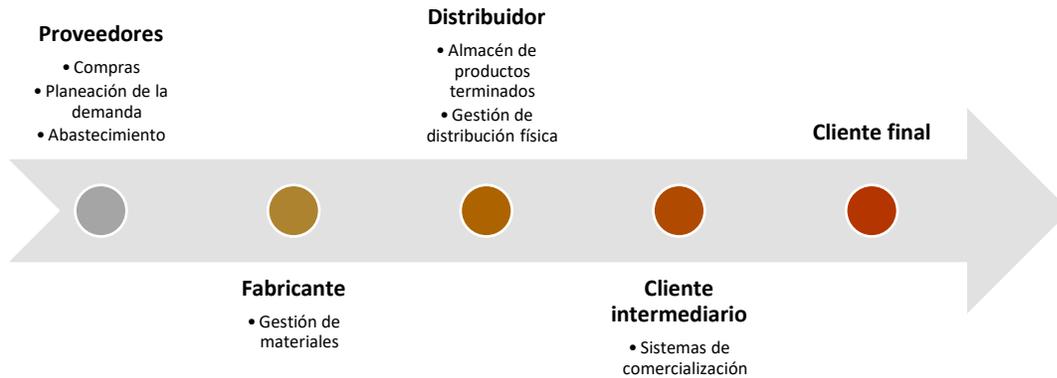


Ilustración 1. Partes de la Cadena de Suministro.  
Fuente: Elaboración propia con base en (Del Moral, 2020).

Una vez establecidas las partes de la Cadena de Suministro, se presenta la cuestión de reconocer la división entre el sistema y su entorno. Sin embargo, “la filosofía de la cadena de suministro definida como sistema no permite distinguir fácilmente sus límites frente a su entorno, pues el número de elementos del sistema puede ser muy complejo e incluso no poder utilizar sus límites para regular la diferencia con su entorno. Esto se debe al persistente y alto nivel de interacciones entre el conjunto de empresas “factibles” para integrarse a la cadena” (Jiménez Sánchez & Hernández García, 2002).

Jiménez y Hernández (2002) mencionan que un sistema tiene un entorno específico y uno genérico.

El entorno específico de una empresa se refiere al conjunto de organizaciones con las que puede establecer algún tipo de relación de interacción para desarrollar operaciones de tercerización, cooperación de desarrollo tecnológico, negocios comerciales, etc. Entre estos se encuentran los clientes, proveedores, competidores, empresas de transporte.

En cuanto al entorno general, este comprende el sistema socioeconómico, definido por el conjunto de factores externos, económicos, políticos legales, sociales y tecnológicos que influyen en todos los aspectos de una organización (Jiménez Sánchez & Hernández García, 2002).

Por otra parte, también destacan los factores interactuantes y cambiantes más importantes en el entorno, los cuales son: innovación tecnológica, cambios en la demanda, cambios en los criterios de localización, nuevos enfoques organizacionales.

La Ilustración 2 Ilustración 2. Cadena de Suministro desde el enfoque sistémico. representa de manera gráfica la Cadena de Suministro vista desde el enfoque sistémico, mostrando la interacción de los componentes con el sistema y su entorno.

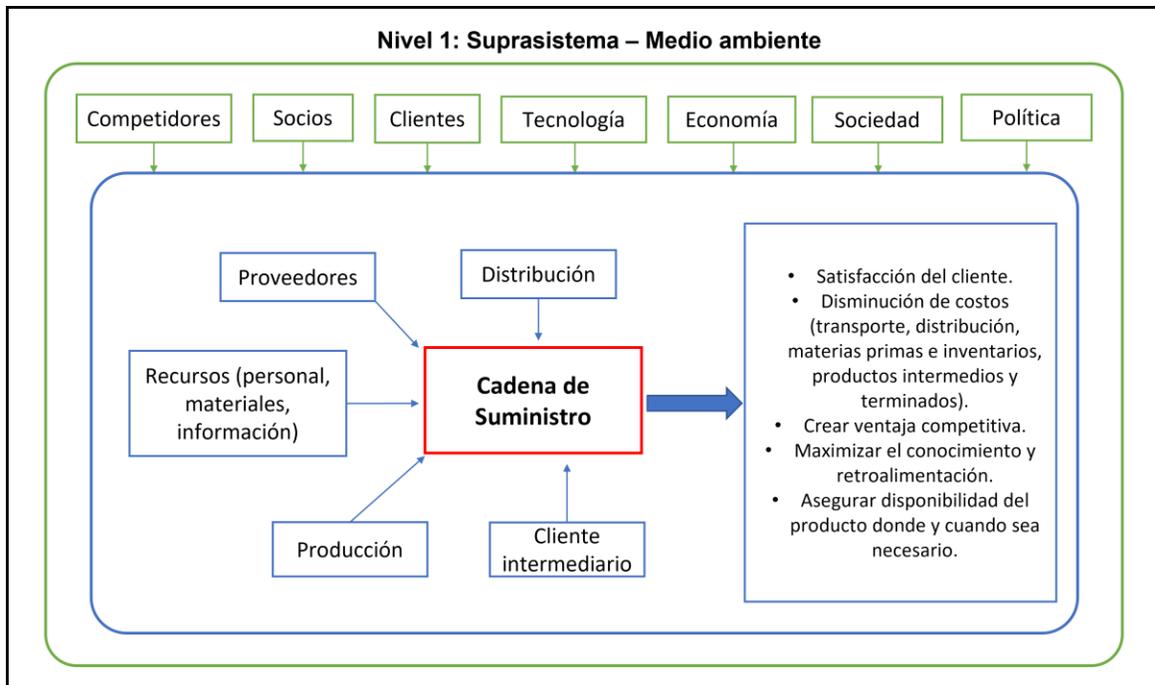


Ilustración 2. Cadena de Suministro desde el enfoque sistémico.  
Fuente: Elaboración propia.

El análisis de la cadena de suministro desde el enfoque sistémico permite conocer los factores principales y secundarios dentro de la misma, así como delimitar el alcance que tiene (delimitar el sistema con su entorno), el alcance de cada elemento que la compone y así, observarla funcionalmente. Siguiendo el enfoque, para el correcto funcionamiento de todo el sistema y para que este cumpla su objetivo es importante que cada una de sus partes funcionen de manera óptima.

### 1.1 Factores de impacto en la Cadena de Suministro: la volatilidad de la demanda.

Una Cadena de Suministro eficiente juega un papel trascendental en el desarrollo y crecimiento de las empresas, contribuyendo a reducir costos y con esto, ser más competitivas. La cadena de suministro incide en la satisfacción de clientes y proveedores por lo cual es importante que esta funcione impecablemente.

El contexto en el que las empresas existen es altamente incierto debido a que existen factores que impactan en variables relevantes sobre ella. La empresa debe tomar decisiones sobre factores controlables tomando en cuenta factores incontrolables (Romero & Romero, s.f.); esto implica que las empresas, y su cadena de suministro (CS), deben enfrentar la incertidumbre apoyándose de los recursos con los que cuenta y conociendo los factores que existen en su medio ambiente, sobre todo aquellos que son de mayor importancia en cuanto al impacto que podrían tener en ella.

Por tal motivo, el correcto funcionamiento de la CS es imprescindible para las empresas, la cual impacta en la satisfacción y lealtad de los clientes y proveedores, en la reducción de costos y en la eficiencia de procesos. Además, para Del Moral (2020) la gestión de la CS se ha convertido en el adecuado manejo de la incertidumbre.

En México los principales retos en la Cadena de suministro son la volatilidad financiera y demanda (Deloitte & SoyLogístico, 2017). En 2007, Anish Jain, director de operaciones de del Institute of Business Forecasting, señaló que “Al menos 7 de cada 10 empresas en México registran graves errores en sus pronósticos de negocio, lo que afecta importantemente a su productividad y a la gestión óptima de sus cadenas de suministro, además de poner en riesgo su capacidad competitiva y rentabilidad”. (inbound logistics México, 2007). La importancia de la planeación de la demanda recae no solo en el hecho de que está asociada con las ventas, sino también con la planificación de los suministros.

En una encuesta realizada por #SoyLogístico a 71 empresas en 2017 y analizada por Deloitte, se obtuvo que los factores que tienen un mayor impacto en la Cadena de Suministro de las empresas son las mostradas en la Ilustración 3.

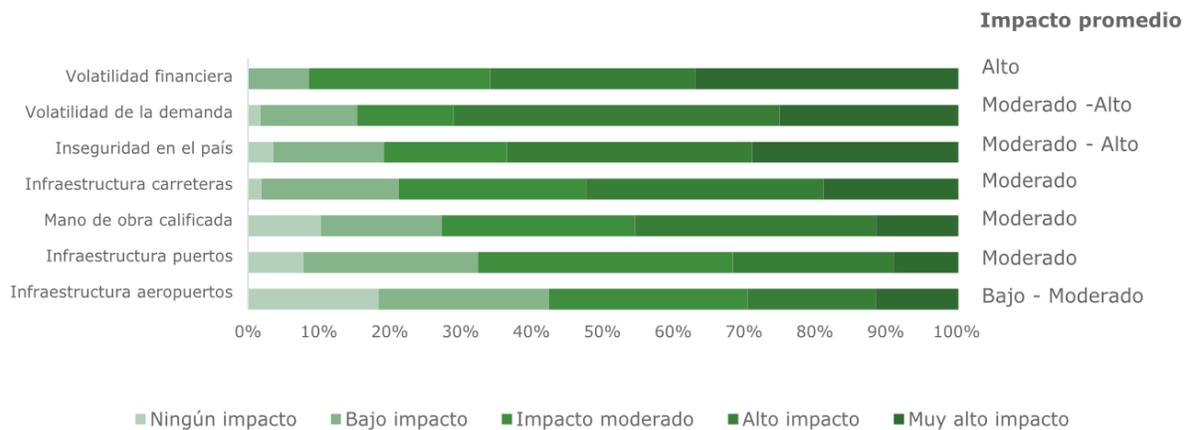
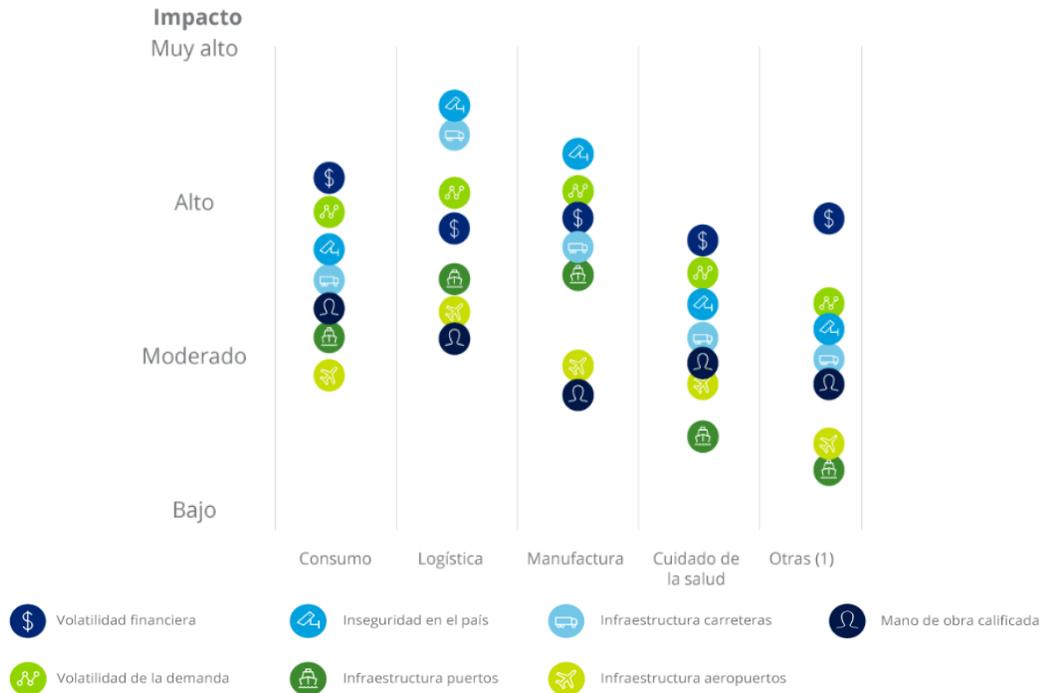


Ilustración 3. Factores que han impactado en la Cadena de Suministro de las empresas.  
Fuente: (Deloitte & SoyLogístico, 2017)

La volatilidad de la demanda es un factor incontrolable que se encuentra entre los factores que mayor impacto provocan a la Cadena de Suministro de las empresas, con un impacto promedio considerado Moderado – Alto.

En la Ilustración 4 se muestran los principales factores que han impactado en la Cadena de Suministro por tipo de industria. La volatilidad de la demanda se encuentra en los tres primeros factores que causan impacto en la Cadena de Suministro en las 10 industrias analizadas en el estudio. Esto quiere decir que, sin importar el sector, la incertidumbre causada por la demanda es importante en toda empresa.

Uso del pronóstico de la demanda para proponer un plan de ventas y operaciones en empresas de servicios.



(1) Otras industrias: Bienes raíces; energía y recursos naturales; servicios; servicios de aviación y transporte; servicios financieros; tecnología, medios y telecomunicaciones.

Ilustración 4. Factores de impacto en la Cadena de Suministro por tipo de industria. Fuente: (Deloitte & SoyLogístico, 2017) .

### 1.2 Importancia de la planeación de la producción y de los pronósticos de la demanda en la Cadena de Suministro.

Dada la incertidumbre en las operaciones de las organizaciones ocasionada por la demanda, es importante que dentro de estas se utilicen técnicas de pronóstico con las cuales sea posible determinar una demanda estimada muy cercana a la demanda real, con lo cual se reduce la incertidumbre futura, mediante la anticipación de eventos cuya probabilidad de ocurrencia sea alta, respecto a otros eventos posibles; apoyando la toma de decisiones y ayudando a prepararse ante estos eventos (Romero & Romero, s.f.)

De acuerdo con los datos proporcionados por la Encuesta Mensual de Coyuntura del sector manufacturero elaborada por el Banco de México en el primer trimestre del año 2020, las empresas registraron 70.8% de variación del volumen de producción en relación con el mes anterior, 55.87% de error de pronóstico en sus planes de producción y un 3.76% de error en la planeación de inventarios de materia prima para la producción en el mes de febrero; lo que muestra una imprecisión en los volúmenes de producción requeridos mes con mes, por lo cual es importante implementar herramientas para la predicción de la demanda.

Por lo que es importante que las empresas realicen el pronóstico de la demanda de sus productos o servicios al establecer el plan de ventas y operaciones de la empresa y tener una mejor visión en

cuanto a qué y cuánto producir, en qué tiempo y cómo distribuirlo. A este proceso se le llama “cultura de planeación” (Inbound Logistics México, 2007).

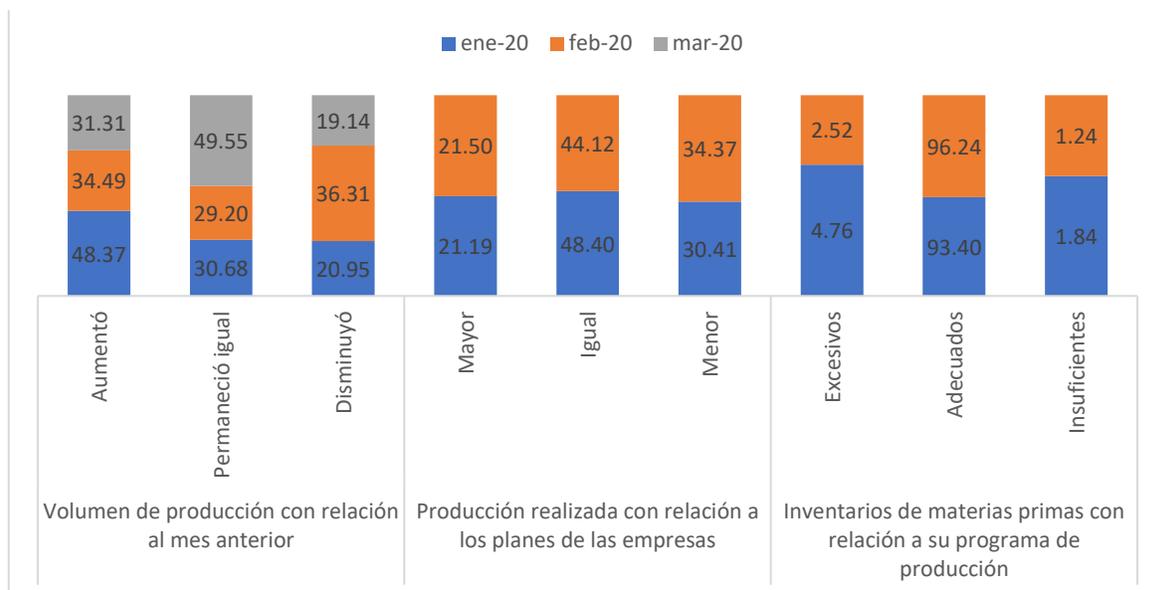


Ilustración 5. Comparación de volúmenes de planeación, producción realizada con relación a los planes de las empresas y planeación de materia prima del sector manufacturero en México durante el primer trimestre del año 2020.

Fuente: Elaboración propia con base en la Encuesta mensual de Coyuntura del sector manufacturero 2020.<sup>1</sup>

Esta cultura de planeación se logra mediante la implementación de herramientas que permitan la optimización del pronóstico y planeación de la demanda; tales como la IA (Inteligencia Artificial), que resulta de gran importancia ya que permite crear escenarios que facilitan la predicción de la demanda, formados mediante la evaluación de parámetros que permiten dar aproximaciones más cercanas a la demanda real. Dichas herramientas basadas en ML analizan decenas de parámetros para poder predecir (por ejemplo, picos de demanda inicialmente no esperados, retrasos en los tiempos de entrega, planificación de suministros las entregas) con mayor fiabilidad y pueden aportar una base más confiable para la toma de decisiones y proponer una visión anticipada a los posibles cambios en la demanda, además de identificar los factores que influyen en ello.

Así, una mala planeación de la demanda puede ocasionar problemas dentro de la organización, en los que se incluye un alto costo para los fabricantes y distribuidores, insatisfacción del cliente, artículos faltantes e inventarios altos, por lo cual es importante definir y tener en cuenta la definición y características de la demanda.

<sup>1</sup> Nota: Durante el mes de marzo (2020) los datos corresponden a las expectativas de los empresarios para los campos de producción realizada con relación a los planes del sector e inventarios de materias primas con relación a su programa de producción.

## Capítulo 2. Planeación de la producción y pronósticos de la demanda

Para que una empresa obtenga resultados adecuados, la planeación de la producción y los pronósticos de la demanda son de gran importancia; sin embargo, con la finalidad de lograr esto es necesario contar con una planeación de ventas y operaciones; ya que estos determinan la demanda de insumos.

La Planeación de Ventas y Operaciones (S&OP), es un proceso que integra los planes de marketing, planes de ventas, planes de inventarios, planes de compras y el enfoque del cliente como parte de la administración de la cadena de suministro (Pinedo Chapa, 2018). Así, el proceso S&OP permite conciliar la planificación y que exista consenso en las áreas de una empresa para lo que es necesario realizar un análisis interno de la empresa y un estudio de mercado, es decir, tener un conocimiento tanto interno como externo de la compañía.



Ilustración 6. Modelo S&OP  
Fuente: Elaboración propia con base en (Peña Andrés, 2015).

Otras de las razones por las que se recomienda implementar del proceso S&OP son la existencia de diferentes pronósticos en diferentes departamentos y con diferentes propósitos (como ventas y compras), la falta de comunicación entre áreas, la falta de alineación para alcanzar los objetivos y que cada área tenga diferentes planes con diferentes propósitos.

S&OP permite entender las estrategias de negocios y desarrollar planes que permitan integrar un plan estratégico para la compañía y así, cumplir con los siguientes objetivos (Pinedo Chapa, 2018):

- Desarrollar para cada familia de producto un plan de venta y proponer un margen esperado que aporte contribución a la compañía.
- Asegurar que los planes sean válidos y realistas según el mercado.
- Integrar los procesos de inventarios, compras, planificación, distribución y abastecimiento con las actividades del plan de negocios.
- Desarrollar una estrategia que permita conocer la demanda.
- Eliminar las decisiones ocultas.
- Alcanzar un consenso con todas las áreas involucradas para obtener un solo plan operativo.
- Alinear el plan operacional con los objetivos corporativos.

Es recomendable que el proceso de S&OP se realice mensualmente, este consta de las siguientes etapas:

1. Recolección de datos: Recolección de información sobre el mes anterior y actualización de planes futuros.
2. Planeación de la demanda: Se analiza la variación del plan realizado para el mes anterior contra lo planificado, se identifican los factores que influyeron en ello y se genera un nuevo plan de demanda.
3. Planeación de cadena de suministro: Desarrollo de nuevos planes de abastecimiento basados en el plan de demanda y se evalúan las capacidades de producción.
4. Conciliación de planes: Se concilian los planes de demanda, suministros y plan financiero.
5. Reunión ejecutiva S&OP: Se analizan los indicadores claves de la organización referentes al mes anterior, se evalúan los nuevos planes y se comparan con la estrategia de la organización y luego se realizan recomendaciones para los planes, se toman decisiones.



Ilustración 7. Proceso S&OP.  
Fuente: (Brand Ortiz )

Los resultados obtenidos del proceso se plasman en distintos planes estratégicos de la organización que se seleccionan de acuerdo con las necesidades y objetivos de la empresa, entre estos se encuentran:

- a) Plan ciclo de vida del producto: duración de los productos o servicios que la empresa ofrece en el mercado en el portafolio de productos de la organización.
- b) Plan de mercadeo: estrategias de marketing.
- c) Para ello pueden ser utilizadas las técnicas de inbound y outbound marketing (marketing de entrada y salida). Según (Carreras, Miguel, Pulido, Rodríguez, & Salazar, 2018), la primera se refiere a la publicidad tradicional la cual está centra en el producto, en mostrar sus ventajas y los medios de difusión tienen como objetivo llamar la atención del cliente potencial. Ejemplos de publicidad son tv, radio y medios impresos.
- d) La técnica de inbound por otra parte, busca perseguir al cliente potencial y atraerlo. Se puede decir que se basa en la experiencia del usuario y los canales que utiliza son principalmente medios digitales como redes sociales, buscadores, blogs. Ejemplos de este tipo de marketing son: listas de emails y creación de contenido.
- e) Pronóstico de ventas: estimación de ventas futuras a partir de información recolectada de datos históricos. Estos resultados son la base para la realización de planes financieros y de abastecimiento.
- f) Plan flujo de caja: plan de cómo se comportará el flujo de caja en los próximos meses con base en las ventas y utilidad generada en el pronóstico de ventas y el plan de compras y manufactura.
- g) Presupuestos corporativos: contienen, entre otros, las ventas brutas de la compañía, la utilidad bruta y las compras de la organización.
- h) Plan de inventarios: se basan principalmente en el pronóstico de ventas y los presupuestos corporativos y deben proyectar el comportamiento de los inventarios de la compañía para así definir donde se tendrán excesos y que familias de productos deberán fabricarse.
- i) Plan de abastecimiento: es una simulación sobre cuales materias primas e insumos deben abastecerse según el plan de inventario a fabricarse.
- j) Plan de manufactura: este plan recoge el plan de inventario y el plan de abastecimiento donde se estima si se tiene la capacidad de manufactura disponible para realizar la producción necesaria, si se tendrán las materias primas disponibles para iniciar producción y cuál será el costo.

Una vez llegado al consenso en las reuniones mensuales, los acuerdos se plasman en actas donde se resumen los puntos principales de los temas tocados en la reunión donde es importante definir la carga de trabajo para cada área según la demanda prevista, la prioridad de tareas y las reflexiones o mejoras futuras en la planeación.

Para Peña Andrés (2015) también es importante que las empresas sean capaces de interpretar tendencias y visualizar los cambios a tiempo para lo que es importante el análisis de los datos adecuados mediante indicadores clave que permiten medir el desarrollo de las actividades y también con cuadros de mando o BSC (por sus siglas en inglés, Balanced Scorecard).

BSC es una herramienta de comunicación estratégica y de medición de desempeño de las empresas (Del Moral, 2020). Surge a partir de la visión de la empresa y traduce la estrategia en términos operacionales para brindar, a través de mediciones, una visión integral de la empresa y sus diferentes perspectivas: financiera, interna, del cliente e innovación.

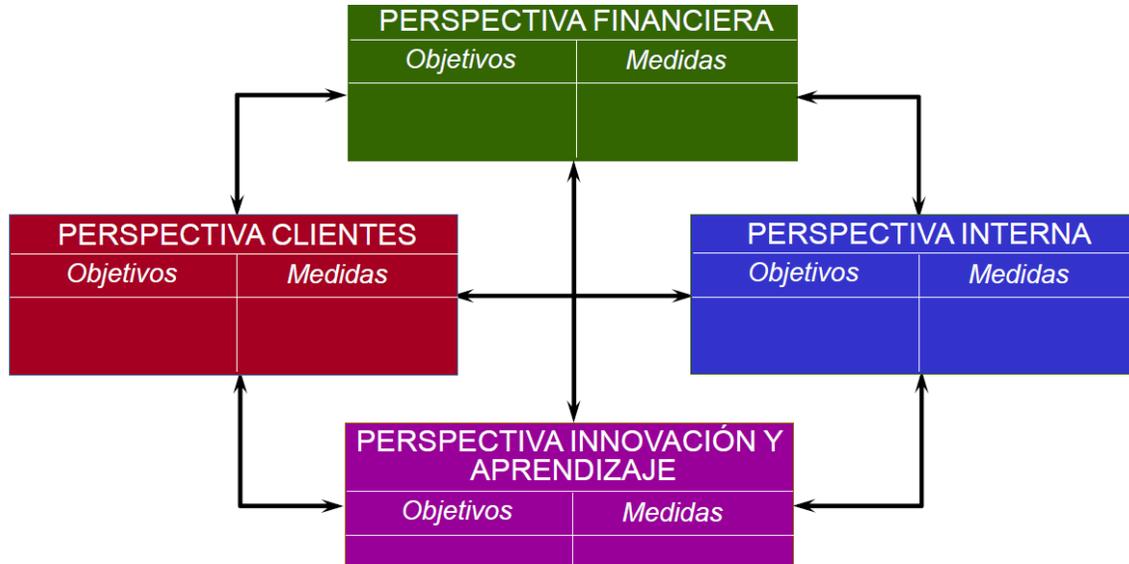


Ilustración 8. Balanced Scorecard.  
Fuente: (Del Moral, 2020).

Así como es necesario tener una perspectiva interna de la empresa, también lo es tener una perspectiva externa para comprender el ambiente de la organización.

Una herramienta que se utiliza para dicho fin es el modelo de las 5 fuerzas de Porter. Este modelo permite a las organizaciones hacer un análisis de su contexto para definir su nivel de competitividad en el mercado y para enfocar sus estrategias en acciones diferenciadoras que les permitan crear un valor único para el cliente y así, lograr tener una ventaja frente a la competencia.

En términos competitivos, para Porter (1986), el valor es la cantidad que los compradores están dispuestos a pagar por lo que una empresa les proporciona.

Para crear valor es necesario que una compañía se diferencie frente a sus competidores desde el punto de vista de los clientes. Porter engloba las reglas de competencia en lo que llama “Las cinco fuerzas competitivas”:

1. La entrada de nuevos competidores.
2. La amenaza de sustitutos.
3. El poder de negociación de los compradores.
4. El poder de negociación de los proveedores.
5. La rivalidad entre los competidores existentes.

Uso del pronóstico de la demanda para proponer un plan de ventas y operaciones en empresas de servicios.



Ilustración 9. Las cinco fuerzas competitivas de Porter. Fuente: Elaboración propia con base en (Porter, 1986).

Por otra parte, a manera de seguimiento del proceso de S&OP, también es importante conocer su nivel de desarrollo e implementación en una empresa. S&OP se puede clasificar de acuerdo con el nivel de madurez que ha alcanzado, un modelo para ello es el de Modelo de Grimson y Pyke (2007) que califica cinco dimensiones que corresponden a los procesos en el negocio: reuniones y colaboración, organización y medición del rendimiento y procesos de información (tecnología de la información e integración del plan S&OP).

	<b>Escenario 1: No hay proceso de S&amp;OP</b>	<b>Escenario 2: Reactivo</b>	<b>Escenario 3: Estándar</b>	<b>Escenario 4: Avanzado</b>	<b>Escenario 5: Proactivo</b>
<b>Reuniones y colaboración</b>	Ninguno	Alto nivel	Reuniones S&OP ejecutivas	Participación de proveedores y clientes	Basado en eventos
<b>Organización</b>	Ninguno	No hay equipos formales de S&OP	No hay roles dedicados a S&OP	Equipos formales de S&OP	S&OP en toda la empresa
<b>Mediciones</b>	Ninguno	Cumplimiento del plan de ventas	Escenario 2 más precisión de forecast o lead time	Escenario 2 más introducción de nuevo producto	Escenario 4 más rentabilidad
<b>Tecnología de la información</b>	Hojas de cálculo, sin consolidación	Hojas de cálculo, cierto grado de consolidación	Información centralizada con ERP	S&OP independiente y sistemas ERP	S&OP integrado con ERP
<b>Integración del plan S&amp;OP</b>	No hay un plan formal	Dirigido por ventas.	Cierta de integración, restricciones unidireccionales.	Alta integración, restricciones bidireccionales	Plan integral

Ilustración 10. Modelo de Madurez del proceso S&OP Fuente: (Eldridge & Hung Goh, 2015).

Para dar inicio con la implementación del proceso de S&OP debe llevarse a cabo el primer paso que es la recolección de los datos, es decir, contar con la información pertinente para la elaboración de los planes tal como los objetivos de la empresa, las ventas del mes anterior y el pronóstico de la demanda, siendo este uno de los datos principales a tener en cuenta para llevar a cabo los siguientes pasos: la planeación de la demanda y el plan de suministro.

## 2.1 Planeación de la demanda

Baca (2001) entiende por demanda la cantidad de bienes y servicios que el mercado requiere o solicita para buscar la satisfacción de una necesidad específica a un precio determinado; y se delimita en función del producto, del mercado y del tiempo (Universidad de Valencia, s.f.).

Es decir, la demanda puede variar dependiendo de factores como las necesidades o deseos que satisfaga el producto, su precio, el lugar y el poder adquisitivo del segmento de la población al que va dirigido, así como el entorno y la época o estación del año en la que se espera que el producto sea adquirido.

Para Sipper y Bulfin (1998) la relación entre el mercado y la instalación de producción está representada por un ciclo: “la demanda del mercado pide a la instalación de producción que fabrique el producto que se envía al mercado para satisfacer la demanda. Cuando se genera más demanda, el proceso se repite.”

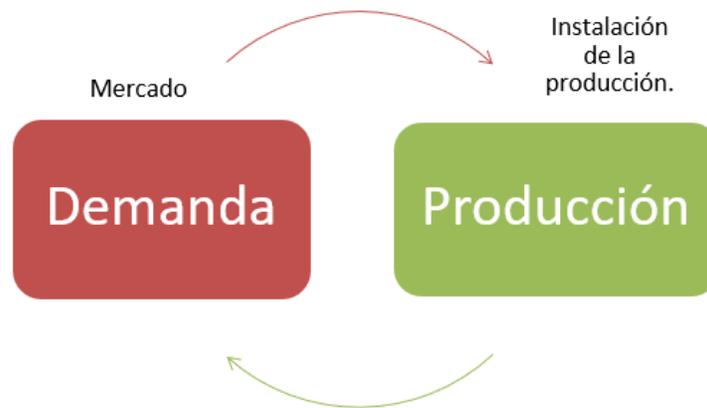


Ilustración 11. El Ciclo de Demanda-Producción.  
Fuente: (Sipper y Bulfin 1998).

Uno de los retos que se presenta en el ciclo de demanda-producción es lograr la correcta gestión de abastecimiento y, por ende, la gestión de la producción. Para ello es fundamental saber cómo y estar preparados para enfrentar la incertidumbre dada por la demanda, pues puede experimentar fluctuaciones a lo largo del tiempo debidas a los factores antes mencionados.

Cabe mencionar la distinción entre demanda independiente y demanda dependiente (que además repercute en la gestión de inventario). La demanda independiente se refiere a aquella que no está

relacionada con la demanda de algún otro producto, los productos terminados son los que normalmente presentan una demanda independiente la cual está sujeta a las condiciones del mercado. Por otro lado, la demanda dependiente se refiere a aquella que se deriva de la demanda de otro producto, pues está sujeta al requerimiento del otro artículo a manera de insumo o componente; por ejemplo, las llantas, carburadores o volantes para un automóvil.

La demanda independiente al estar sujeta a factores externos, suele ser más complicada de prever y, de igual manera, la administración del inventario de productos de demanda independiente y la gestión de su producción pueden resultar ser más complejos a comparación de productos con demanda dependiente. Por lo anterior el contar con una buena planificación de la demanda es de suma importancia.

La planificación de la demanda se entiende como “el proceso de analizar la evolución de las ventas y el mercado con el propósito de estimar sus valores en el futuro, esto como medio de anticipar las necesidades de los clientes y determinar estrategias de producción, compras e inventarios que puedan ofrecer elevada disponibilidad con alta rentabilidad” (Merino Nambo, 2013). Esto quiere decir que la planificación de la demanda consiste en pronosticar la demanda a corto, mediano o largo plazo y, una vez que se prevé y se analiza, la empresa se encarga de elaborar planes para garantizar la satisfacción de la demanda manteniendo el nivel de suministros necesarios, conociendo la capacidad de la empresa para ello. Los recursos necesarios para suministrar son mano de obra (número de trabajadores necesarios), materiales, inventarios, recursos financieros y capacidad del equipo.

Así como la planeación de demanda es importante en la industria manufacturera, también lo es en el sector de servicios en donde se destaca una mayor fluctuación de demanda debido a las necesidades y requerimientos más específicos por parte del cliente.

#### 2.1.1 Planeación de la demanda en el sector servicios

Debido a la mayor variabilidad de demanda en los servicios, para Martín Peña y Díaz Garrido (2016) las empresas necesitan contar con una estrategia que le permita equilibrar las fluctuaciones de demanda utilizando diferentes mecanismos activos y pasivos.

De acuerdo con las autoras esta problemática dificulta la estimación de la capacidad que necesita la empresa en un periodo de tiempo dado y lo atribuyen a tres principales razones:

1. Los servicios son perecederos, a diferencia de la manufactura no pueden ser guardados para utilizarlos en otro momento por lo que el inventario no puede nivelar la demanda cuando existen picos.
2. Los clientes tienen diferentes necesidades y suelen requerir de transacciones y tiempo diferente para ser atendidos, lo que contribuye a una variabilidad mucho mayor en el tiempo de procesamiento.
3. El comportamiento del cliente.

Por ello, Martín y Díaz proponen que las empresas de servicios pueden encontrarse con cuatro escenarios diferentes en donde hay un contraste entre la capacidad de la oferta y la demanda:

1. **Demanda en exceso:** cuando el nivel de demanda excede la capacidad máxima de la empresa. Existe un costo de oportunidad al tener que rechazar clientes que no pueden ser atendidos y los clientes que sí son atendidos pueden percibir que la calidad no es la esperada debido a una sobrecarga de capacidad en personal e instalaciones.
2. **La demanda excede la capacidad óptima:** en este escenario no se rechazan clientes, pero pueden notar que la calidad del servicio no es la adecuada por la sobrecarga de capacidad.
3. **La demanda y la oferta están equilibradas al nivel de capacidad óptima:** el personal y las instalaciones se utilizan a un nivel ideal. Nadie trabaja en exceso, las instalaciones se pueden mantener y los clientes reciben un servicio de calidad y sin retrasos indeseables.
4. **Capacidad en exceso:** la demanda está por debajo de la capacidad y hay recursos que se utilizan por debajo de su capacidad, lo que resulta en una pérdida de productividad e ineficiencia de recursos.

De acuerdo con las autoras la principal problemática en cualquiera de estos casos es implementar estrategias, como las que se muestran en el siguiente gráfico, para alinear la demanda y la oferta mediante la gestión de la capacidad, por lo que es importante planificar la oferta de los servicios ofrecidos por la empresa y la demanda.

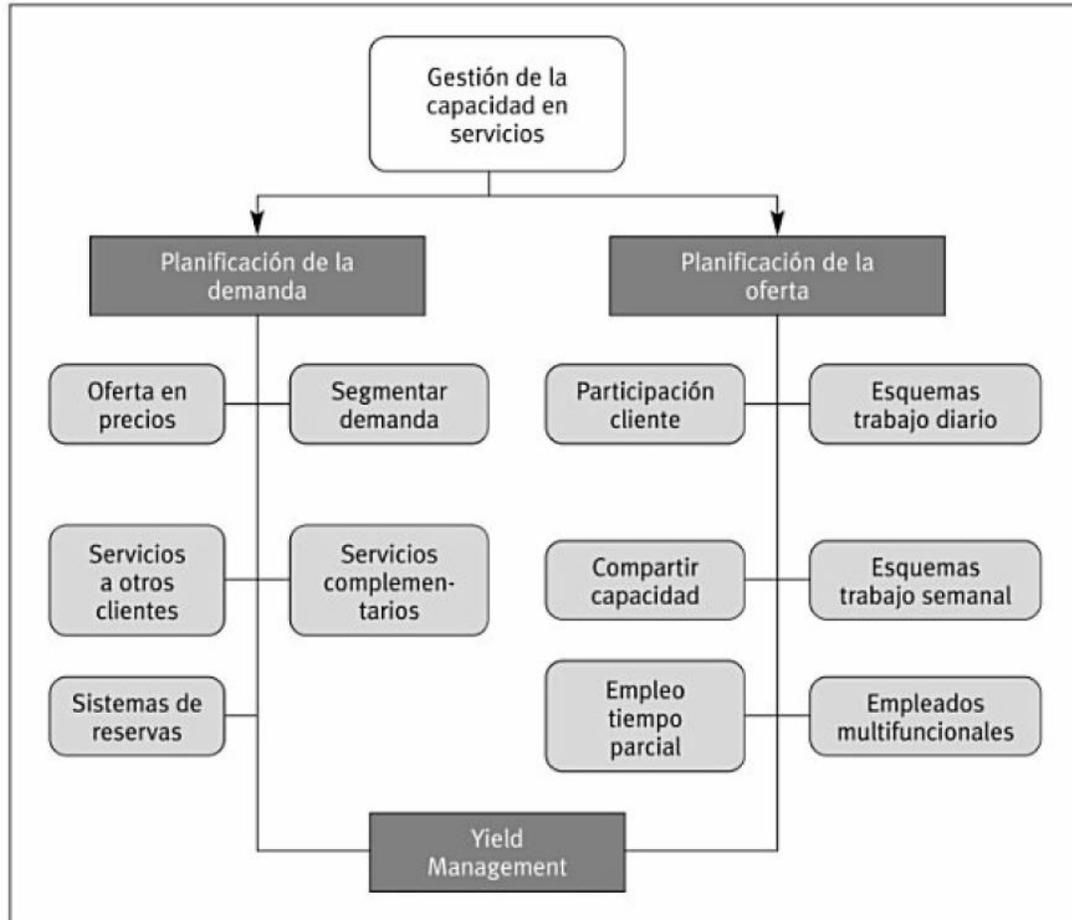


Ilustración 12. Estrategias para gestionar la capacidad en empresas de servicios.  
Fuente: (Martín Peña & Díaz Garrido, 2016)

La Gestión de ingresos (en inglés Yield Management), es una técnica que combina la gestión de la capacidad y la gestión de la demanda para obtener un máximo beneficio o rendimiento, es comúnmente utilizado en la industria hotelera y consiste en la adaptación de precios a la demanda existente.

Como se revisa, la planeación de la demanda tanto en el sector servicios como en el manufacturero, requiere de los recursos de la empresa para ser desarrollados, por lo que este proceso está relacionado con otros procesos de la cadena de suministros, así como la planeación del abastecimiento, la planeación de la producción, de los inventarios, ventas y distribución.

De esta manera, la planificación de la demanda es el comienzo de una planificación efectiva de la cadena de suministros, que permite obtener una visión de los requerimientos del mercado (Martín M. E., 2017). Dichos requerimientos se obtienen, generalmente, mediante el pronóstico de la demanda ya que la demanda cuenta con categorías específicas.

## 2.2 Categorización de la demanda

Para Meindl y Chopra (2008), la demanda observada puede ser dividida en dos componentes: uno sistemático (el cual es predecible) y uno aleatorio (el cual es el error del pronóstico respecto al valor real y representa aquella cantidad que no se puede controlar). De igual manera, otra característica importante de la demanda es su comportamiento en el tiempo, el cual puede ser representado mediante patrones (Ilustración 13):

- **Demanda estable u horizontal:** la demanda sigue un tipo de patrón constante o poco cambiante, en donde los datos fluctúan alrededor de una media. Este tipo de patrón es seguido por productos como leche, pan o servilletas que se consideran artículos maduros, ya que se utilizan de manera frecuente y cuya demanda no varía en gran medida.
- **Demanda con tendencia:** la demanda sigue patrones que muestran cambios graduales ya sean crecientes o decrecientes durante un periodo de tiempo. Este patrón puede ser lineal o no lineal. Este tipo de demanda puede ser notorio en el ciclo de vida de un producto en el que hay una etapa en las que las ventas aumentan y otra en las que las ventas empiezan a disminuir.
- **Demanda estacional:** la demanda sigue un patrón cambiante que muestra picos y valles que se repiten en ciertos periodos del año.
- **Demanda cíclica:** la demanda sigue un patrón cambiante que presenta incrementos y decrementos durante largos periodos de tiempo.
- **Demanda aleatoria:** la demanda sigue una variación que es imprevisible.

Estos patrones se reconocen según el comportamiento histórico que se ha observado en la demanda en un periodo de tiempo (serie de tiempo). Se analizan dichos datos para extrapolar el modelo hacia el futuro mediante diferentes métodos de pronóstico y así, poder prever la demanda.

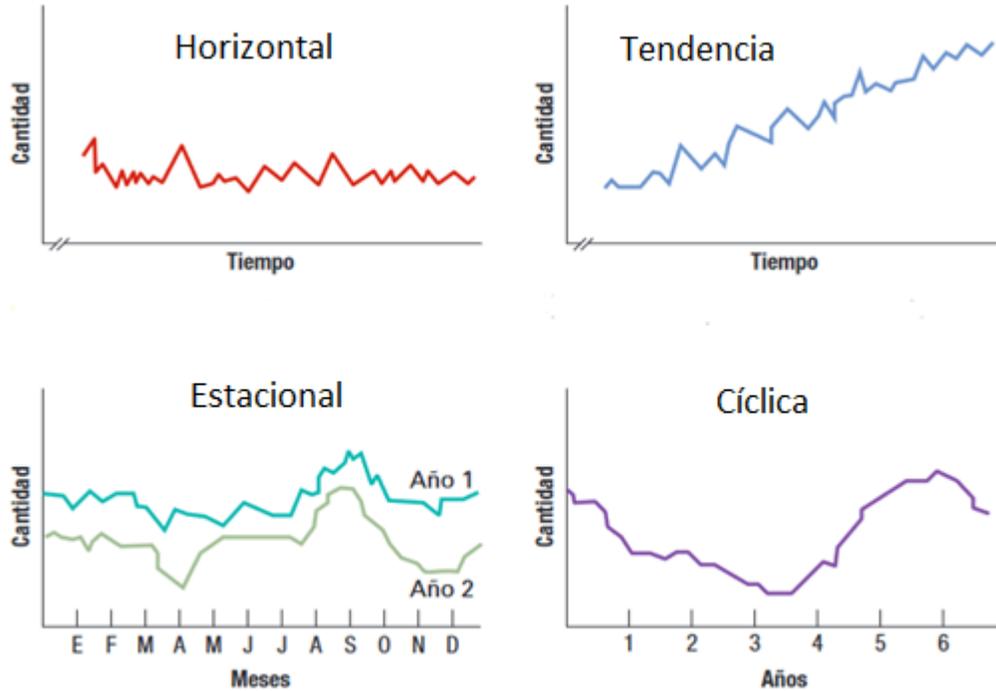


Ilustración 13. Patrones de Demanda.  
Fuente: (KRAJEWSKI, RITZMAN, & MALHOTRA, 2010).

### 2.2.1 Categorización de demanda con patrones irregulares

También puede presentarse un patrón irregular el cual se caracteriza por tener una mayor variabilidad de la demanda respecto a su promedio y no presenta una tendencia o evolución característica.

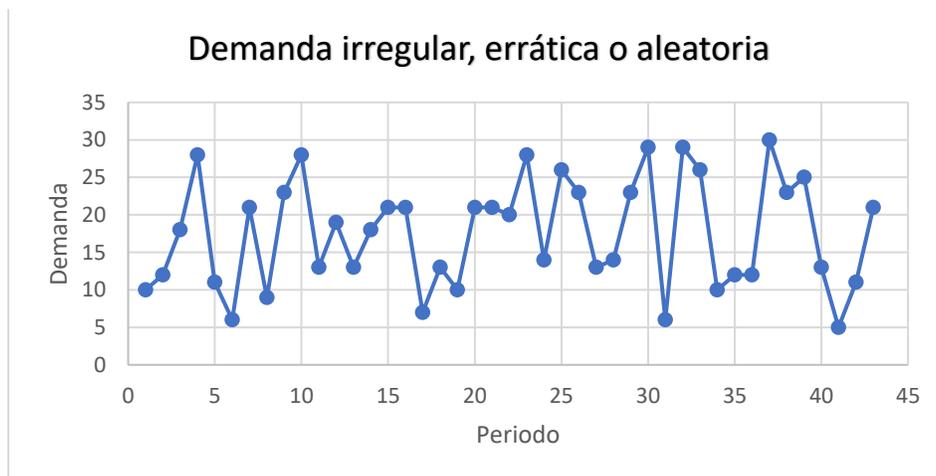


Ilustración 14. Demanda irregular, errática o aleatoria.  
Fuente: Elaboración propia con base en (Medina García, 2013).

Este tipo de patrón de demanda puede contener periodos con demanda nula, los cuales pueden ser del siguiente tipo:

- **Demanda intermitente:** se caracteriza por contener periodos en los que no se producen consumos, es decir, cuya demanda es cero. Los valores que son diferentes a cero pueden acercarse a un patrón estable, creciente o decreciente, estacional o irregular.



Ilustración 15. Demanda intermitente.  
Fuente: Elaboración propia con base en (Medina García, 2013).

- **Demanda de movimiento lento:** se caracteriza por presentar poca movilidad de ventas, es decir, presenta largos periodos en los que el consumo es igual a cero.

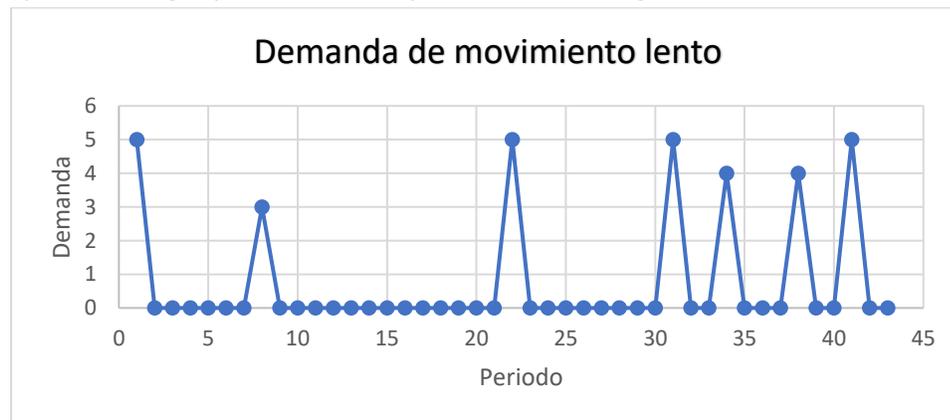


Ilustración 16. Demanda de movimiento lento.  
Fuente: Elaboración propia con base en (Medina García, 2013).

- **Demanda grumosa o lumpy:** este tipo de patrón muestra una intermitencia en la demanda y una alta disgregación de los datos en la serie histórica.

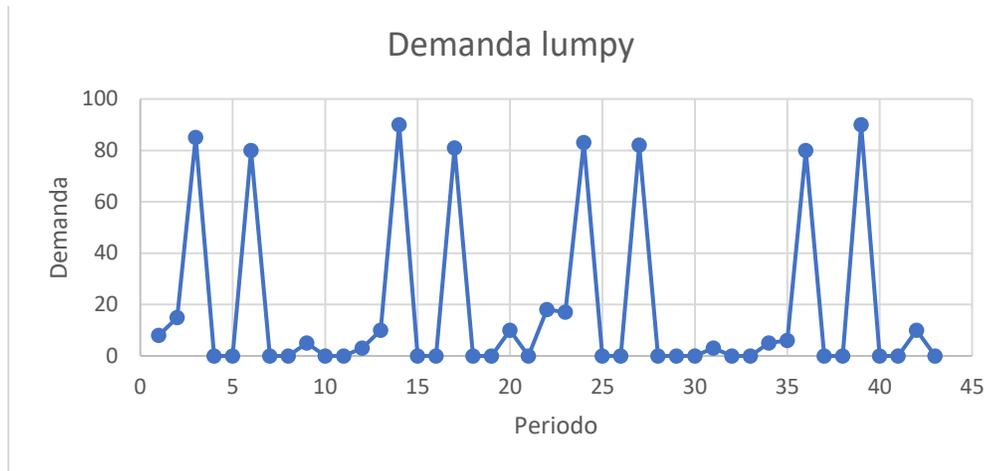


Ilustración 17. Demanda Lumpy.  
Fuente: Elaboración propia con base en (Medina García, 2013).

Cabe destacar la diferencia entre demanda intermitente y demanda irregular. La primera se caracteriza por presentar demanda nula en distintos periodos, mientras que la segunda se caracteriza por presentar grandes fluctuaciones en el tamaño de la demanda real (Martin, Spitzer, & Kühn, 2020).

Existen dos indicadores que ayudan a categorizar los tipos de demanda irregulares, estos son: el Coeficiente de Variación Cuadrática ( $C_V^2$ ) y el Promedio del Intervalo entre Demandas (ADI).

El primero relaciona el promedio de la serie con la desviación de los datos y muestra la variabilidad de una serie temporal, de modo que entre más alto sea el indicador, más alta será la variabilidad de la serie.

$C_V^2$  se calcula como:

$$C_V^2 = \left(\frac{\sigma}{\bar{x}}\right)^2$$

Donde:

$\sigma$ : desviación estándar de la demanda

$\bar{x}$ : demanda promedio

El ADI se refiere al intervalo medio en periodos de tiempo entre dos demandas no nulas y es una medida de intermitencia, lo que quiere decir que entre más alta sea más intermitente será la serie.

ADI se calcula como:

$$ADI = \frac{N}{n}$$

Donde:

$N$ : Número del total de períodos

$n$ : Número del total de períodos con demanda no nula

Con base en dichos indicadores, según Syntetos y Boylan (2005) es posible identificar el patrón de demanda de acuerdo con el siguiente esquema:

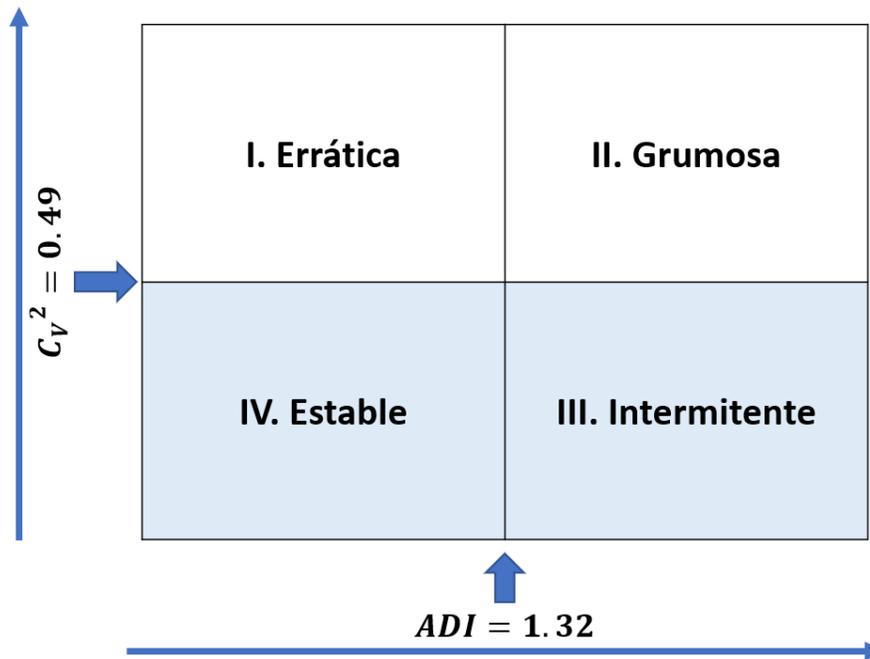


Ilustración 18. Esquema de categorización de demanda.  
Fuente: Elaboración propia con base en (Syntetos, 2005)

El análisis del patrón de la demanda es una tarea clave a realizar antes de calcular el pronóstico, pues existen diferentes horizontes y técnicas de previsión, pero es importante conocer cuál es la más adecuada para ser utilizada según el comportamiento de la demanda con el fin de que se obtenga una predicción lo más certera posible.

### 2.3 Pronósticos de la demanda

Un pronóstico es una predicción de acontecimientos futuros que se utiliza con propósitos de planificación (Krajewski, Ritzman, & Malhotra, 2008). El objetivo de los pronósticos es predecir la demanda a un horizonte de tiempo que determina hasta dónde se debe planear:

- **Corto plazo** (0 a 3 meses): Se utilizan para diseñar estrategias inmediatas; las decisiones se relacionan con la adquisición de materiales y la programación de trabajos y actividades específicas.

- **Mediano plazo** (3 meses a 2 años): Es muy utilizado en la planeación de producción y análisis de varios planes de operación, presupuestos, planeación de ventas y presupuesto de efectivo.
- **Largo plazo** (más de dos años): Se utiliza comúnmente para la planeación de las instalaciones y de los procesos.

Si el horizonte de planeación aumenta, la exactitud de los pronósticos disminuye.

El pronóstico es la base para la planificación de las operaciones de la empresa y debe proporcionar los datos de manera oportuna y se busca que los resultados sean los más cercanos a la demanda real.

De este modo, el pronóstico es una herramienta para la toma de decisiones referidas a las operaciones relacionadas con el diseño del proceso, la planeación de la capacidad y los inventarios; y también es la base para la toma de decisiones para otras áreas de la empresa como marketing, finanzas, contabilidad y recursos humanos.

Meindl & Chopra (2008) plantean las siguientes características de los pronósticos:

- Los pronósticos siempre están equivocados, por lo que también debe estimarse una medida de error del pronóstico.
- Los pronósticos a corto plazo son más precisos que los de largo plazo debido a que estos últimos tienen una desviación estándar mayor con relación a la media que los primeros.
- Los pronósticos agregados en general son más precisos que los desagregados.
- Mientras más arriba en la cadena se encuentre una compañía (más lejos del consumidor), más grande será el error de pronóstico. El pronóstico colaborativo con base en las ventas al cliente ayuda a las compañías corriente arriba a reducir el error de pronóstico.

Existen diferentes métodos para pronosticar la demanda. Para que una empresa elija cual es el conveniente necesita identificar los datos y las fuentes que tiene disponibles y cuáles necesita para llevar el proceso a cabo. Estos pueden incluir datos históricos, proyecciones de ventas, planes de promoción, objetivos corporativos, datos de participación de mercado, inventario comercial, acciones que ha tomado la competencia e investigación de mercado. También es importante determinar qué tan buena es cada fuente para predecir la demanda.

Entonces, hay múltiples ventajas de realizar pronósticos de demanda, entre los cuales se destacan la reducción de exceso de inventarios, ser más eficientes en la asignación de recursos, minimizar costos de producción, facilitar la toma de decisiones y ofrecer un mejor servicio al cliente, para realizar los pronósticos de demanda existen diferentes técnicas dependiendo del tipo de demanda con el que se cuente.

### 2.3.1 Técnicas clásicas de pronóstico

Las técnicas de pronóstico se clasifican de la siguiente manera (Schroeder, Meyer , & Rungtusanatham, 2011):

- **Cualitativos:** Se basan en juicios personales, en estimados y opiniones, por lo que son subjetivas. Son utilizados generalmente en el inicio de la empresa para la introducción de un nuevo producto para los que no se tienen datos de ventas o cuando estos no son confiables, entre estos se encuentran el método Delphi, juicios de expertos, encuestas/sondeos y prueba de mercado.
- **Series de tiempo:** “Los métodos de pronóstico de series de tiempo utilizan la demanda histórica para hacer pronósticos. Se basan en la suposición de que la historia de la demanda pasada es un buen indicador de la demanda futura [...] y es apropiado de implementar si la demanda básica no varía significativamente al año siguiente” (Meindl & Chopra, 2008). Este método para predecir la demanda se basa en el análisis de datos históricos para encontrar patrones que sean predecibles y repetibles para poder extrapolar el modelo al futuro (Figura 7). Entre este tipo de métodos se encuentran el método por promedio móvil simple, promedio móvil ponderado, suavización exponencial, análisis de regresión, Run Rate.
- **Causal:** Los métodos causales se utilizan cuando la demanda está altamente correlacionada o es causada por ciertos factores en el ambiente (estado de la economía, precios, tasas de interés, calidad, publicidad, competencia, acciones del gobierno). Estos métodos son normalmente utilizados para prever los cambios de la demanda a largo plazo.

Entre los métodos causales se encuentra la técnica de simulación los cuales combinan los métodos de series de tiempo y causales para hacer suposiciones sobre la relación entre variables internas y externas del modelo, por ejemplo, el impacto de una promoción en los precios, el impacto de un aumento de precios en la demanda o el impacto de la apertura de una tienda de la competencia.

Tabla 1. Métodos cualitativos

Métodos cualitativos	Descripción del método	Aplicaciones	Exactitud			Identificación de los puntos de inflexión	Costo relativo
			A corto plazo	A mediano plazo	A largo plazo		
<b>1. Delphi</b>	El pronóstico se desarrolla por medio de un panel de expertos que responden una serie de preguntas en rondas sucesivas. Las respuestas anónimas del panel se realimentan a todos los participantes en cada ronda. Se pueden requerir de tres a seis rondas para obtener la convergencia del pronóstico.	Pronósticos de ventas a largo plazo para la planeación de la capacidad de las instalaciones. Pronósticos tecnológicos para evaluar cuándo podrían ocurrir cambios tecnológicos.	Regular a muy buena	Regular a muy buena	Regular a muy buena	Regular a buena	Mediano a alto
<b>2. Estudios de mercado</b>	Grupos, cuestionarios, pruebas de mercado o estudios que se usan para obtener datos sobre las condiciones del mercado.	Pronósticos de las ventas totales de la compañía, De grupos de productos importantes o de productos individuales.	Muy buena	Buena	Regular	Regular a buena	Alto
<b>3. Analogía del ciclo de vida</b>	La predicción se basa en las fases de introducción, crecimiento y maduración de productos similares. Aplica la curva de crecimiento en ventas con forma de S.	Pronósticos de ventas a largo plazo para la planeación de la capacidad o de las instalaciones	Deficiente	Regular a buena	Regular a buena	Deficiente a regular	Mediano
<b>4. Criterio informado</b>	El pronóstico lo puede realizar un grupo o un individuo con base en la experiencia, presentimientos o hechos acerca de la situación. No se emplean métodos rigurosos.	Pronósticos de ventas totales y de productos individuales.	Deficiente a regular	Deficiente a regular	Deficiente a regular	Deficiente a regular	Bajo

Fuente: (Schroeder, Meyer , & Rungtusanatham, 2011)

Tabla 2. Métodos de series de tiempo

Métodos de series de tiempo	Descripción del método	Aplicaciones	Exactitud			Identificación de los puntos de inflexión	Costo relativo
			A corto plazo	A mediano plazo	A largo plazo		
<b>1. Promedios móviles</b>	El pronóstico se basa en un promedio aritmético o en un promedio ponderado de un número determinado de puntos de datos históricos.	Planeación a corto y mediano plazos para los inventarios, niveles de producción y programación. Es eficaz para muchos productos.	Deficiente a buena	Deficiente	Muy deficiente	Deficiente	Bajo
<b>2. Suavización exponencial</b>	Similar a los promedios móviles, pero se otorga un mayor peso exponencial a los datos recientes. Se adapta muy bien al uso de computadoras y cuando hay un alto número de elementos que deben pronosticarse	Lo mismo que un promedio móvil.	Regular a muy buena	Deficiente a buena	Muy deficiente	Deficiente	Bajo
<b>3. Modelos matemáticos</b>	Un modelo lineal o no lineal que se ajusta a datos de series de tiempo, de ordinario a través de métodos de regresión. Incluye líneas de tendencia, polinomios, logaritmos no lineales, series de Fourier, etcétera.	Lo mismo que un promedio móvil, pero limitado, debido a los gastos inherentes, a unos cuantos productos.	Muy buena	Regular a buena	Muy deficiente	Deficiente	Bajo a mediano
<b>4. Box-Jenkins</b>	Los métodos de autocorrelación se utilizan para identificar las series de tiempo fundamentales y para ajustar el mejor modelo. Requiere de cerca de 60 puntos de datos históricos	Limitado, debido a los gastos inherentes, a productos que requieren de pronósticos muy exactos a corto plazo.	Muy buena a excelente	Regular a buena	Muy deficiente	Deficiente	Mediano a alto

Fuente: (Schroeder, Meyer , & Rungtusanatham, 2011)

Tabla 3. Métodos causales de pronóstico

Métodos causales	Descripción del método	Aplicaciones	Exactitud			identificación de los puntos de inflexión	costo relativo
			A corto plazo	A mediano plazo	A largo plazo		
<b>1. Regresión</b>	Este método relaciona la demanda con otras variables externas o internas que tienden a ocasionar los cambios en la demanda. El método de regresión utiliza la técnica de mínimos cuadrados para obtener un mejor ajuste entre las variables.	Planeación a corto y a medianos plazos para la producción agregada o para un inventario que incluya un número pequeño de productos. Es de utilidad cuando existen fuertes relaciones causales.	Buena a muy buena	Buena a muy buena	Deficiente	Muy buena	Mediano
<b>2. Modelo econométrico</b>	Un sistema de ecuaciones de regresión interdependientes que describe algún sector de las ventas o de las utilidades de las actividades	Pronóstico de ventas por clases de productos para la planeación a corto y mediano plazos.	Muy buena a excelente	Muy buena	Buena	Excelente	Alto
<b>3. Modelo insumo-producto</b>	Un método de pronóstico que describe los flujos de un sector de la economía a otro. Predice los insumos necesarios para elaborar los productos requeridos en otro sector.	Pronósticos de las ventas globales de toda una compañía o localidad por sectores industriales.	No disponible	Buena a muy buena	Buena a muy buena	Regular	Muy alto
<b>4. Modelo de simulación</b>	Simulación del sistema de distribución que describe los cambios en las ventas y en los flujos de productos a lo largo del tiempo. Refleja los efectos del canal de distribución.	Pronósticos de las ventas globales de toda una compañía por grupos principales de productos.	No disponible	Buena a muy buena	Buena	Buena	Bajo

Fuente: (Schroeder, Meyer , & Rungtusanatham, 2011)

### 2.3.2 Previsión de demanda intermitente y Lumpy

Croston (Croston, 1972) fue uno de los primeros autores en estudiar y presentar una solución para el pronóstico de demanda para artículos de movimiento lento, es decir, cuando el comportamiento de los artículos no es suave ni continuo.

Para ello, fue necesario estudiar los patrones de comportamiento y las características de la demanda intermitente y lumpy como los valores de demanda nula y la alta variabilidad de la demanda pues representan un problema a la hora de intentar aplicar uno de los modelos clásicos de previsión como la atenuación exponencial, dado que genera desvíos importantes en la previsión de demandas intermitentes. Por ello, Croston mostró que era necesario hallar otro método que pudiera ser utilizado para garantizar una mayor precisión.

El método de Croston (CRO) está basado en el método de suavización exponencial, el cual es uno de los principales métodos más utilizados por permitir ponderar y desvalorizar los valores pasados de la serie de tiempo con relación de los más recientes.

Consiste en separar la serie de tiempo en dos partes: una serie con valores positivos de demanda y otra con los tiempos entre demandas consecutivas o nulas. En cada una de ellas se obtiene la previsión por medio de suavización exponencial y luego, ambos valores son actualizados cuando existe un valor no nulo de demanda (Santa Cruz & Correa, 2017).

Una particularidad del método CRO es que el resultado del pronóstico se expresa en términos de una tasa prevista de demanda intermitente, es decir, como la razón de demanda por periodo.

En la Ilustración 19 se presenta el algoritmo del método Croston:

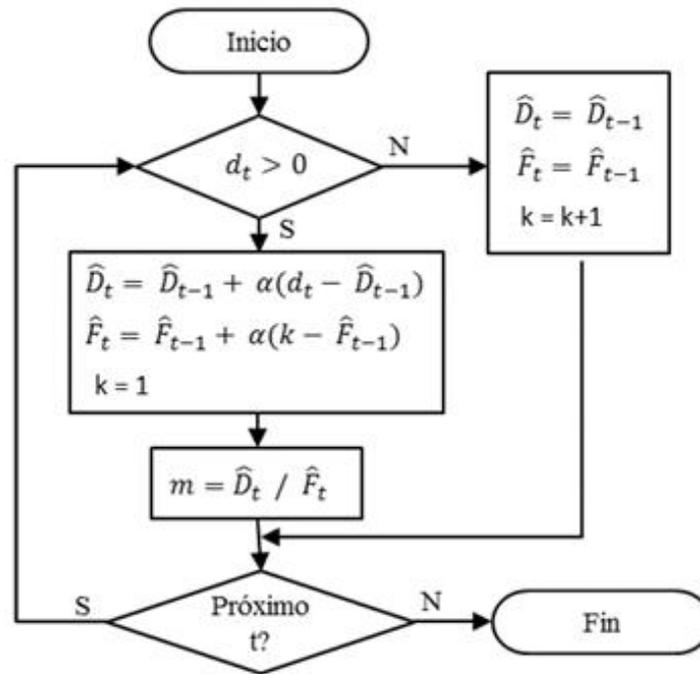


Ilustración 19. Algoritmo método Croston  
Fuente: (Santa Cruz & Correa, 2017)

Donde:

$d_t$  = demanda en el periodo  $t$ ;

$\hat{D}_t$  = previsión de la demanda no nula para el periodo siguiente  $t$ ;

$F_t = f_t - f_{t-1}$ ; intervalo de tiempo entre la demanda última y la anterior en el periodo;

$\hat{F}_t$  = previsión del intervalo de demanda;

$k$  = intervalo desde la última demanda no nula;

$\alpha$  = parámetro de atenuación

$m$  = pronóstico al final del periodo  $t$ , para el periodo siguiente (Vidal Holguín, 2010)

$$m_{t+1} = \frac{\hat{D}_t}{\hat{F}_t}$$

Croston sugiere que el parámetro de atenuación ( $\alpha$ ) o constante de suavización, tome valores entre  $0.1 \leq \alpha \leq 0.2$ , aunque en la práctica puede tomar valores entre  $0 \leq \alpha \leq 1$ .

El método de Croston fue el primer método para el cálculo de demanda intermitente y es el más utilizado. Posteriormente otros investigadores propusieron modificaciones en el método, tal como Syntetos y Boylan (2001) que demostraron que la técnica de Croston está sesgada pues identificaron un desvío en la estimación.

El sesgo consiste en que la previsión está significativamente por encima o por debajo de la demanda durante los periodos previstos.

Para corregir el error, propusieron una corrección en el modelo original que consiste en multiplicar el pronóstico de la demanda del periodo por un factor corrector del sesgo, de manera que la demanda en el periodo se calcula como:

$$m_{t+1} = \left(1 - \frac{\alpha}{2}\right) \frac{\hat{D}_t}{\hat{F}_t}$$

Este se conoce como el Método modificado de Croston o SBA (por las iniciales de los autores) y con él se ha comprobado que se obtienen mejores resultados al utilizarlos cuando las series de tiempo muestran un comportamiento errático, grumoso e intermitente (Santa Cruz & Correa, 2017).

En la siguiente imagen se muestran los métodos de previsión de demanda que se aconseja utilizar de acuerdo con la categorización de demanda, de acuerdo con Syntetos y Boylan (2005).

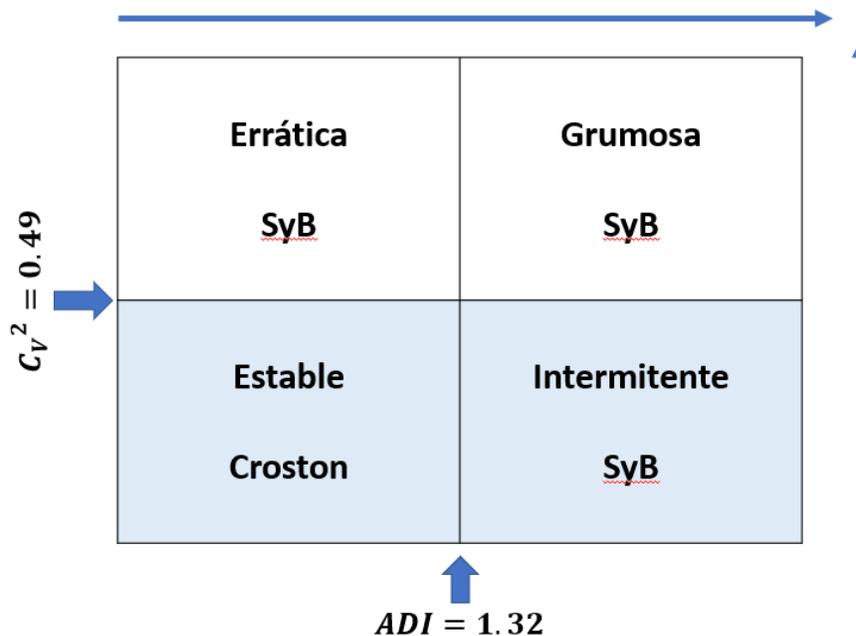


Ilustración 20. Categorización de la demanda y modelo de previsión.  
Fuente: (Syntetos, 2005)

A medida en que aumenta la complejidad a la que están sometidos procesos como pronosticar la demanda (o de manera general la gestión de la cadena de suministro) se ha recurrido al apoyo de

nuevas herramientas que permitan realizar este tipo de tareas de manera que se eviten errores en la mayor medida posible y así, minimizar el riesgo y garantizar una mejor toma de decisiones.

## 2.4 Errores de pronóstico clásicos

Calcular el error del pronóstico permite comparar los valores entre el pronóstico de demanda estimado en un periodo y el valor de la demanda real. Esto facilita la elección entre los distintos métodos de pronóstico a utilizar, así como los valores de parámetros que intervienen en estos.

De este modo, el error de pronóstico se determina mediante la diferencia entre el valor real de la demanda ( $d_t$ ) y el valor del pronóstico ( $f_t$ ) en el mismo periodo  $t$ :

Ecuación 1. Error de pronóstico

$$E_t = d_t - f_t$$

La suma acumulada de errores de pronóstico (SAE) refleja el sesgo en el método de pronóstico, es decir, indica las deficiencias en el enfoque del pronóstico. Se calcula como:

Ecuación 2. Métrica SAE

$$SAE = \sum_{t=1}^T E_t$$

Otra forma de cálculo de error de pronóstico es Desviación media absoluta (MAD), el cual evita que los errores positivos y negativos se cancelen entre sí:

Ecuación 3. Métrica MAD

$$MAD = \frac{\sum |d_t - f_t|}{T} = \frac{\sum |E_t|}{T}$$

Una tercera opción es el error cuadrado medio (MSE), el cual utiliza el cuadrado de cada término de error para que, al igual que en el MAD, evitar que los errores positivos y negativos se cancelen entre sí:

Ecuación 4. Métrica MSE.

$$MSE = \frac{\sum_{t=1}^T E_t^2}{T}$$

Finalmente, el error porcentual medio absoluto (MAPE) relaciona el error de pronóstico con el nivel de demanda y es útil para comparar los errores de pronósticos para diferentes datos. El MAPE es el mejor indicador para comparar debido a que el “MSE y el MAD dependerán mucho de la escala de datos por lo que se complica realizar comparaciones de los diversos intervalos de tiempo” (Lucas, 2017).

Ecuación 5. Métrica MAPE.

$$MAPE = \frac{\frac{\sum |E_t|}{T}}{D_t}$$

## 2.5 Error de pronóstico para series de demanda intermitentes y lumpy

Las series intermitentes y lumpy presentan periodos en los cuales la demanda es nula, la cual es su principal característica. Esto puede causar complicaciones para calcular el error del pronóstico utilizando los indicadores anteriormente citados dado a la presencia de periodos con demanda cero. Por ejemplo, al calcular el MAPE se obtendrían valores infinitos o indefinidos cuando los valores reales son o se acercan a cero, lo cual se presenta cuando se tienen series intermitentes y lumpy.

De este modo, las métricas anteriores funcionan con patrones de demanda suaves y lineales y se vuelven menos precisos cuando se presenta una frecuencia creciente de patrones intermitentes. Para evitar este problema, en la literatura se han propuesto diferentes métricas nuevas que toman en cuenta dicha problemática y que son más adecuadas para el tipo de demanda Lumpy. Una de ellas es la métrica SPEC.

### 2.5.1 Costo del Error de Predicción orientados al Mantenimiento de Existencias (SPEC)

Martin, et al. (2020) proponen una nueva métrica que consideran adecuada para evaluar modelos de predicción de series intermitentes: el Costo del Error de Predicción orientados al Mantenimiento de Existencias (SPEC, por sus siglas en inglés).

Su trabajo de investigación fue enfocado para los casos de demanda lumpy e intermitente que se caracterizan por presentar demanda nula en diferentes periodos por lo que una de sus desventajas es que no se pueden utilizar diferentes métricas tradicionales al no poder dividir entre cero.

	Aspectos estadísticos				Aspectos del negocio	
	Independencia de escala	No división por cero	Insensibilidad a valores atípicos	Simetría	Interpretabilidad	Consideraciones económicas
<b>Errores Absolutos</b>						
- MAE / MdAE	○	●	○	●	●	○
- MSE	○	●	○	●	●	○
- RMSE	○	●	○	●	●	○
<b>Errores Porcentuales</b>						
- MAPE / MdAPE	●	○	○	○	●	○
- RMSPE	●	○	○	○	●	○
<b>Errores Simétricos</b>						
- sMAPE	●	○	○	○	○	○
<b>Errores de escala</b>						
- MASE	○	○	●	●	●	○
- RMSSE	○	○	●	●	●	○
SPEC (this work)	●	●	○	●	●	●

Ilustración 21. Propiedades de las métricas estadísticas clásicas y SPEC.  
Fuente: (Martin, Spitzer, & Kühn, 2020).

SPEC es una métrica que asemeja el proceso de periodos en stock aplicado al cálculo del error de pronóstico para series intermitentes y lumpy. Este consta del cálculo dos términos: el costo de oportunidad y el coste de mantenimiento de existencias, los cuales, desde el punto de vista de la gestión de inventarios, son los dos costos que deben equilibrarse en la cadena de suministro.

Esto entendiendo que los costos de mantenimiento de existencias se producen por mantener productos en el almacén y que surgen costes de oportunidad dados por pedidos insatisfechos si los artículos no están disponibles en el momento en que existe demanda.

Así, mientras menor sea el valor de SPEC, este se aproxima a un almacenamiento óptimo al alcanzar una mayor precisión en el pronóstico y si aumenta significa que existen costes de oportunidad y de mantenimiento por una predicción imprecisa.

SPEC se calcula como:

Ecuación 6. Métrica SPEC

$$SPEC_{\alpha_1, \alpha_2} = \frac{1}{n} \sum_{t=1}^n \sum_{i=1}^t \left( \max \left[ 0; \min \left[ y_i; \sum_{k=1}^i y_k - \sum_{j=1}^t f_j \right] \cdot \alpha_1; \min \left[ f_i; \sum_{k=1}^i f_k - \sum_{j=1}^t y_j \right] \cdot \alpha_2 \right] \cdot (t - i + 1) \right)$$

En donde:

$n$  = longitud de la serie de tiempo

$t$  = momento en el tiempo

$y_t$  = demanda real en el momento  $t$

$f_t$  = *pronóstico de la demanda* en el momento  $t$

$\alpha_1$  = *costo de oportunidad*

$\alpha_2$  = *costo de mantenimiento*

La recomendación que dan los autores es elegir los valores de  $\alpha_1$  y  $\alpha_2$  tal que su suma sea 1, para ello proponen la relación:

$$\alpha_1 = 1 - \alpha_2$$

Así, a diferencia de otras métricas, SPEC permite tener en cuenta los costos de oportunidad o de mantenimiento de existencias en lo que respecta a las unidades pendientes o en stock.

De acuerdo con Martin, Spitzer, y Kühn (2020) el cálculo de la métrica se basa en la supuesto de que el inventario se representa mediante previsiones y demandas en un stock ficticio. DE manera que el pronóstico representa las entregas y el almacenamiento en un momento dado. Por otro lado, las demandas representan las salidas del almacén en el momento correspondiente.

A pesar de que esta métrica se desarrolló principalmente para evaluar el pronóstico de demanda de productos, los autores afirman que sus campos de aplicación no son limitadas, pues son aplicables en todos los posibles ámbitos en los que exista una demanda parcial esporádica. Tal como en servicios para los que los costes de una entrega tardía o demasiado temprana, causada por un error de previsión, se puede incurrir en ellos.

## 2.6 Planeación de la producción y pronósticos de la demanda: herramientas de apoyo.

Actualmente existen muchas herramientas de apoyo para hacer pronósticos de la demanda que van desde softwares especializados basados en modelos estadísticos que son capaces de elegir de manera automática el método óptimo a utilizar a partir de los datos históricos, de graficar las series obtenidas y compara los datos reales con el pronóstico mediante el cálculo de los errores de pronóstico.

De igual manera, dichas herramientas sirven de apoyo para la planeación de la producción a partir del cálculo de pronóstico. Las tecnologías de planeación de demanda buscan reducir los inventarios, fomentar la colaboración y ayudan a los fabricantes a (Brandt):

- Establecer predicciones de ventas de línea base al incorporar múltiples insumos;
- Realizar análisis sofisticados que mejoren su uso de recursos humanos y de capital;
- Optimizar las capacidades de precios;
- Entender mejor sus mercados y clientes.

Estas herramientas representan un factor fundamental para la base de la Cadena de Suministro y para la diferenciación de la empresa por el contexto en el que existen hoy en día, es decir, la cuarta revolución industrial, que se caracteriza por acelerados procesos de cambio productivos y tecnológicos y por el desarrollo de economías cada vez más basadas en la expansión de herramientas tecnológicas como el Big Data, Inteligencia Artificial y Machine Learning.

Estas nuevas tecnologías se han ido aplicando al área de gestión de la producción y con ello a la planeación de la demanda y a los pronósticos. Los aportes que brinda a diferencia de los modelos tradicionales son (Pérez, 2017):

- Toma en cuenta los factores que pueden influir en la demanda, así como marketing, inventarios, desarrollo de nuevos productos.
- Combinan la experiencia humana acumulada durante décadas en la gestión de inventario con nuevas técnicas de minería de datos.
- Analizan datos estructurados y también no estructurados.
- Trabajan utilizando patrones dinámicos, es decir, los algoritmos de inteligencia artificial tienen en cuenta los comportamientos de los clientes pasados, presentes y futuros.
- Son capaces de aprender de forma indefinida sin ser programado explícitamente, creciendo y adaptándose a los nuevos datos.

## Capítulo 3. Modelos predictivos de demanda basados en Inteligencia Artificial

Las empresas cambian con el tiempo y están obligadas a adaptarse a los nuevos avances sociales, políticos, económicos y tecnológicos para sobrevivir. Es por esto por lo que se han renovado y desde años atrás han comenzado a implementar nuevas tecnologías en sus procesos volviéndolos automáticos, lo cual les ha permitido no solo facilitar sus tareas sino también obtener ventaja competitiva e incluso han sido capaces de situarse delante de otras.

Una de estas tecnologías ha sido la Inteligencia Artificial (IA). En la actualidad hay herramientas basadas en Machine Learning (ML) que analizan decenas de parámetros para poder predecir.

El término Inteligencia Artificial (IA) fue acuñada por John McCarthy en 1956 en una conferencia en el Dartmouth Collage, esta fue la primera conferencia dedicada a la IA.

La IA se entiende como el campo de estudio que se enfoca en la explicación y emulación de la conducta inteligente en función de procesos computacionales (Ponce Cruz, 2010).

Entonces, la IA tiene el propósito de estudiar y lograr que las máquinas simulen la inteligencia humana, es decir, que aprendan y razonen como un ser humano.

Entre las áreas de estudio de las que se compone la IA se encuentran:

- Aprendizaje de las máquinas (machine learning)
- Minería de datos (data mining)
- Sistemas expertos
- Procesamiento del lenguaje natural
- Robótica
- Lógica
- Incertidumbre y “lógica difusa”

Hoy en día la IA tiene muchas áreas de aplicación, así como en el reconocimiento de imágenes y de voz, procesamiento de idiomas, vehículos autónomos, y otras más que pueden encontrarse en la vida cotidiana (chatbots, dispositivos en el hogar, anuncios personalizados) así como en la industria, apoyando en distintos procesos en sectores como servicios financieros, transporte, comercio, salud, retail, aeroespacial y manufactura.

Una de las aplicaciones de la IA es en la predicción de pronósticos. Actualmente existen distintos modelos que fueron generados para este fin y se basan principalmente en Machine Learning.

Para (Kelleher, Mac Namee, & D'Arcy, 2015) el análisis predictivo de datos es el arte de construir y utilizar modelos que hacen predicciones basadas en patrones extraídos de datos históricos.

En este campo, el concepto de predicción se refiere a la asignación de un valor a una variable que es desconocida. Entonces, el análisis predictivo de datos se encarga de entrenar modelos para predecir los valores de sus variables en base a un conjunto de datos históricos.

El machine learning es la herramienta que se utiliza para entrenar estos modelos y se define como un proceso automatizado que busca reconocer patrones dentro de un conjunto de datos, para posteriormente realizar un aprendizaje y por último poder construir un modelo que represente a dicho conjunto (Rodríguez & Cerecedo, 2021).

Los modelos que se utilizan en las aplicaciones de análisis de datos predictivos se construyen a través de la técnica de aprendizaje automático supervisado, las cuales aprenden automáticamente de la relación entre datos de entrada y de salida deseados.

Entonces, se puede decir que ML es un conjunto de técnicas que permite interpretar información y obtener nueva información a partir de ella. Permite crear modelos que simulen el comportamiento de un sistema, determinar si la información analizada presenta tendencia y hacer predicciones a futuro a partir del comportamiento de los datos.

Los algoritmos más usados en el área de Machine Learning son: regresión lineal, regresión no lineal, árboles de clasificación, máquinas de soporte vectorial y redes neuronales, siendo esta última la técnica más utilizada para pronósticos.

Dada la capacidad de estos tipos de algoritmos, la implementación de un modelo de pronóstico de la demanda basado en IA aporta una base más confiable para la toma de decisiones, además de tener una visión anticipada a los posibles cambios en la demanda e identificar los factores que influyen en ello.

### 3.1 Modelos predictivos basados en Machine Learning para pronosticar la demanda de productos.

Las técnicas de pronóstico de demanda y ventas han ido evolucionando y se han propuesto nuevos modelos con el paso del tiempo debido a las nuevas necesidades que se van presentando en las empresas.

A medida que las técnicas de pronóstico y el número de parámetros incrementa, se vuelve más difícil elegir el método apropiado a utilizar en un contexto en particular. Una solución que se encontró ante esta situación es el uso de algoritmos conocidos como “aproximadores universales” los cuales son capaces de aproximar cualquier función con una precisión arbitraria. Así, permiten aprender cualquier función requerida entre los datos pasados y futuros lo que hace que otras técnicas de pronóstico sean un subconjunto de las funciones que los aproximadores universales pueden aprender. (Carbonneau, Vahidov, & Laframboise, 2016).

Las técnicas de ML como redes neuronales artificiales y máquinas de soporte vectorial son aproximadores universales y son algoritmos que se han utilizado recientemente para prever la demanda.

#### 3.1.1 Redes neuronales artificiales

Las redes neuronales (RNAs) son sistemas de aprendizaje que tratan de reproducir el proceso de solución de problemas del cerebro humano. Así como los humanos aplican el conocimiento ganado con la experiencia a nuevos problemas o situaciones, una red neural toma como ejemplos

problemas resueltos para construir un sistema que toma decisiones y realiza clasificaciones (Ponce Cruz, 2010).

Este sistema se compone por unidades interconectadas donde cada una de ellas recibe datos de entrada, los procesa y produce un valor de salida. Tanto las entradas como las salidas pueden venir o servir de entrada a otra unidad.

La información que entra en la red atraviesa las diferentes capas de neuronas, donde se somete a las entradas a diferentes operaciones matemáticas que secuencialmente producen modificaciones a estas entradas hasta obtener diversos valores de salida (Rodríguez & Cerecedo, 2021).

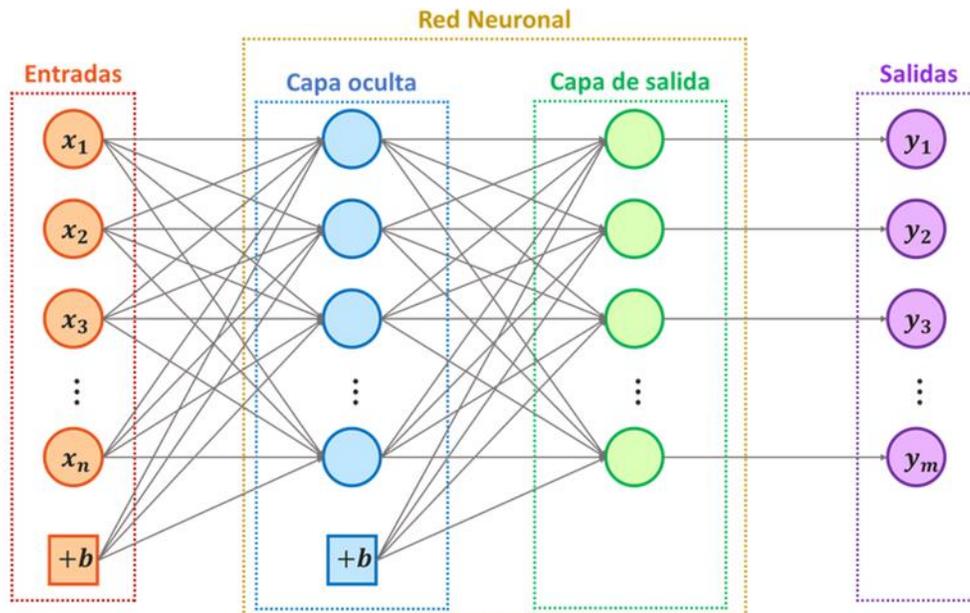


Ilustración 22. Modelo de Redes Neuronales.  
Fuente: (Rodríguez & Cerecedo, 2021).

RNAs son utilizadas con frecuencia para predecir series de tiempo y la bondad de estos algoritmos consiste en que realiza la propagación del error hacia atrás al tiempo que permite que la red neuronal aprenda patrones.

### 3.1.2 Perceptrón Multicapa (Multi Layer Perceptron o MLP)

Perceptrón multicapa (MLP por sus siglas en inglés) o también conocido como Feed Forward Neural Network es un modelo de Redes Neuronales que trabajan como aproximadores (Menzies, Kocagüneli, Minku, Peters, & Turhan, 2015).

La red se compone de tres tipos de capas: las capas de entrada, las capas ocultas y las capas de salida. Las primeras reciben la señal de entrada a ser procesada, las capas ocultas realizan el cálculo del MLP y las capas de salida realizan los ejercicios de predicción o clasificación.

En MLP los datos fluyen en dirección de la capa de entrada a la capa de salida y entre los algoritmos que existen para entrenar la red se encuentra el algoritmo Propagación hacia atrás (Backpropagation).

Tener capas ocultas permite resolver problemas no lineales, entre más capas ocultas se utilicen se pueden resolver problemas más complejos. MLP está diseñado para aproximar cualquier función continua y puede resolver problemas que no son linealmente separables.

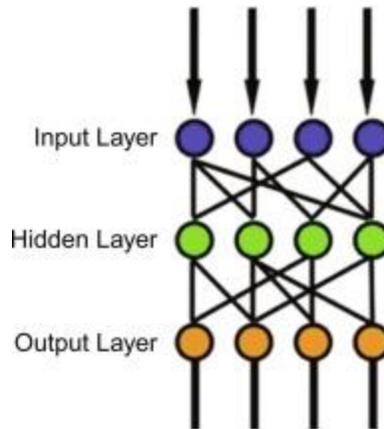


Ilustración 23. Representación de MLP con una capa oculta.  
Fuente: (Abirami & Chitra, 2020)

### 3.1.3 Árboles de clasificación y regresión (CART)

Los métodos basados en árboles pretenden explicar o predecir una variable a partir de un conjunto de variables predictoras utilizando un conjunto de reglas sencillas. Esta técnica se puede utilizar tanto en una regresión como en un contexto de clasificación.

Los CART consisten en dividir el espacio de la característica en varias regiones regulares simples. Tras ser entrenado, el algoritmo se realiza una serie de preguntas con el fin de clasificar adecuadamente los datos.

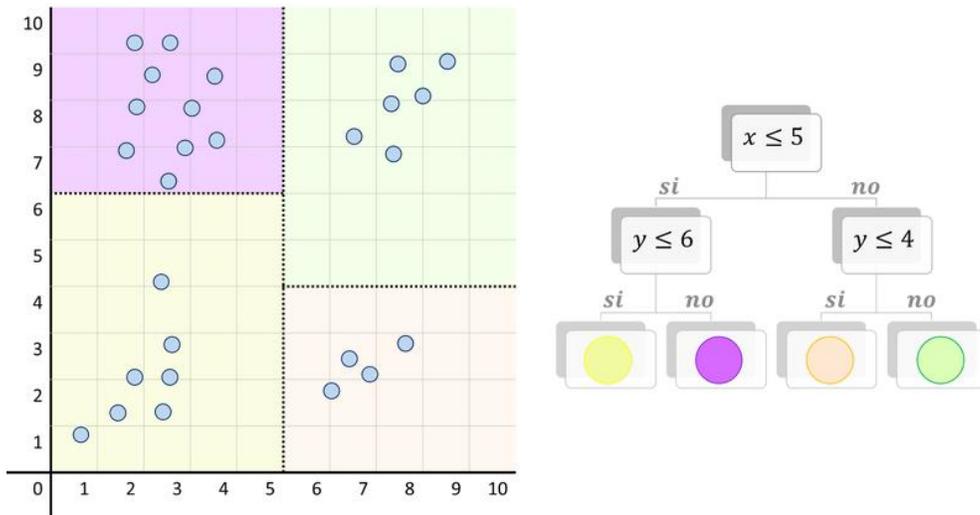


Ilustración 24. Árboles de clasificación y regresión.  
Fuente: (Rodríguez & Cerecedo, 2021).

Para obtener una predicción por una observación en particular, se utiliza la media o la moda de las respuestas de la región de entrenamiento. El objetivo al utilizar este algoritmo es minimizar algún tipo de criterio de error, como pudiera ser el MSE.

### 3.1.4 Máquinas de soporte vectorial (SVM)

Las máquinas de soporte vectorial (SVM por sus siglas en inglés) son un conjunto de algoritmos de aprendizaje supervisado que pueden ser aplicados para predicciones de tipo regresión y para clasificación.

SVM funciona construyendo una curva o hiperplano que modela la tendencia de los datos, a partir de ella se forman dos bandas una en el lado positivo y otra en el lado negativo, tratando de abarcar la máxima cantidad de datos posible y manteniendo la misma distancia de cada una con el hiperplano. El algoritmo se utiliza para separar de forma óptima a los puntos que componen diferentes categorías unos de los otros y así, predecir a que categoría pertenecerá un nuevo punto del que no se tenía información con anterioridad.

De este modo, lo que busca el SVM es hallar la curva que modele la tendencia de los datos y a partir de ella predecir cualquier otro dato en el futuro.

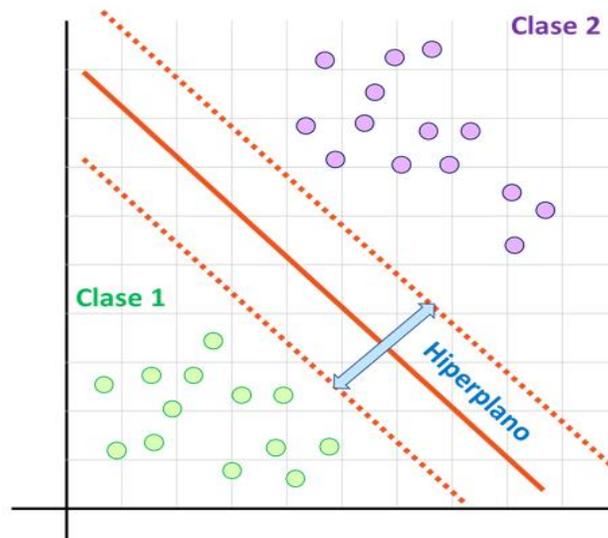


Ilustración 25. Máquinas de soporte vectorial.  
Fuente: (Rodríguez & Cerecedo, 2021).

### 3.2. Conjuntos de entrenamiento, validación y prueba.

Uno de los primeros pasos al desarrollar un modelo de ML es subdividir el conjunto de datos en conjuntos de entrenamiento (train), validación y test. Este procedimiento sirve para poder evaluar la calidad del modelo de ML cuantificando mediante métricas el rendimiento del modelo, siendo Accuracy la más común ya que mide la proporción de aciertos en el modelo (Ruiz Reina, 2017).

El conjunto de entrenamiento suele ser el subconjunto más grande. Como su nombre lo indica, es el conjunto que permite entrenar el modelo y ajustar los parámetros que requiere el modelo.

El conjunto de validación permite evaluar los hiperparámetros del modelo y ajustarlos.

El conjunto de prueba ayuda a evaluar el rendimiento del modelo utilizando datos con los que no ha trabajado y es el que se utiliza al final, ya que se ha entrenado el modelo y se han ajustado los hiperparámetros. Este conjunto permite obtener un estimado de cómo funcionará el modelo con nuevos datos.

Como regla general, en la literatura se recomienda dividir el conjunto de entrenamiento con un 80% de los datos y el de prueba con un 20%.

### 3.3. Comparación de modelos de pronóstico tradicionales con modelos basados en Inteligencia Artificial: estado del arte.

Debido al auge de estas herramientas diversos estudios comparativos han sido realizados tales como el presentado por Salazar y Cabrera (2007) quienes realizaron un estudio en el que desarrollaron un modelo de RNAs aplicado al pronóstico de series de tiempo para hallar la demanda de una empresa de telecomunicaciones. Los autores partieron de la premisa de la exactitud del pronóstico de la RNA depende de varias decisiones críticas en cuanto a la definición de los

parámetros que intervienen en el modelo, así como de la arquitectura de RNA que se esté utilizando. Lo que su trabajo propone es una metodología para la selección adecuada de los parámetros de un modelo de RNAs y se comprueba mediante el caso práctico.

Los resultados que obtuvieron fueron comparados con los resultados que se obtienen al utilizar métodos estadísticos tradicionales y concluyeron que las RNAs construidas con la metodología propuesta superó el desempeño de los modelos estadísticos, siendo el método de suavizado exponencial doble el más competitivo entre los modelos tradicionales utilizados.

Usuga Cadavid, Lamouri y Grabot (2018) realizaron una revisión de literatura con el propósito de identificar las nuevas tendencias y técnicas de ML aplicadas a los pronósticos de demanda y ventas (D&SF por sus siglas en inglés) en diferentes industrias. En su análisis también realizaron la comparación entre algoritmos de ML (como SVM, arboles de decisión, RNAs, modelos de variables exógenas y endógenas, por mencionar algunas) y los métodos clásicos de pronósticos (como regresión polinomial, regresión lineal múltiple, ARIMA, promedios móviles).

Dados los resultados obtenidos tras su análisis, concluyeron que las técnicas de ML fueron más precisas que los métodos tradicionales de pronóstico, particularmente cuando los modelos contienen variables exógenas y endógenas<sup>2</sup>. Además, encontraron un estudio en el que se propuso utilizar un modelo híbrido, es decir, un modelo en el que combinaron dos métodos: el de regresión polinomial y el ELM (Extreme Learning Machine) cuyo objetivo fue reducir el tiempo del cálculo del pronóstico cuando se trabaja con numerosos SKU. También encontraron que las técnicas de ML permiten identificar patrones ocultos en la demanda que se pueden utilizar como base para identificar nuevas tendencias de mercado.

Peña (2021) realizó un estudio utilizando datos históricos de la venta de chocolate en un año de una compañía en donde comparó la eficacia de los métodos de pronóstico para predecir la demanda de ventas. Concluyó que los métodos estadísticos superaron en precisión a los algoritmos de ML: el método ARIMA fue el mejor método de pronóstico para la organización en cuestión y el método de Holt Winters presentó un gran rendimiento y rapidez en ejecución.

Sin embargo, también obtuvo que los algoritmos de ML mostraron mejorías frente a los métodos estadísticos al combinar diferentes Redes Neuronales o al reconfigurar las técnicas de reconfiguración y validación.

### 3.3.1 Modelos de pronóstico basados en Inteligencia Artificial para demanda “Lumpy”

A pesar de que en la literatura se pueden encontrar opiniones de autores que afirman que no se puede desarrollar un pronóstico de productos cuya demanda contiene patrones lumpy o intermitentes o que esto es una causa perdida, existen avances en la investigación de este tipo de demanda en las que se han desarrollado técnicas avanzadas que demuestran una mejoría en la exactitud del pronóstico para demanda lumpy e intermitente.

---

<sup>2</sup> Entendiendo por variables exógenas a aquellas que son ajenas a la empresa y por variables endógenas a aquellas cuyo valor está determinada por las relaciones establecidas dentro de la empresa (López, 2018).

Por ejemplo, Sahin, Kızılaslan, & Demirel (2013) realizaron un estudio en donde compararon los métodos de previsión de demanda intermitente tomando los modelos basados en el modelo de Croston y Syntetos y Boylan, modelos basados en Redes Neuronales Artificiales y modelos basados en Máquinas de Soporte Vectorial para pronosticar la demanda de piezas de repuesto de aviación que corresponden a las categorías de demanda errática, intermitente y lumpy. Sus resultados muestran que, tanto para la demanda de tipo intermitente y lumpy, los métodos con mejor rendimiento son los métodos basados en RNAs, específicamente el modelo Time-Delay Network (TDNN) y Multi-Layer Perceptron (MLP) usando 3 capas ocultas utilizando el algoritmo Back Propagation y para la demanda errática el mejor modelo es el de Leven & Segerstedt, basado en el método de Croston.

Assaghir, Makki et al (2017) realizaron un trabajo en el que utilizaron datos históricos de ventas de piezas de recambio para la industria siderúrgica utilizando varios métodos de previsión: Redes neuronales artificiales (ANN) utilizando el método MLP con una capa oculta y dos nodos, Máquinas de soporte vectorial (SVM) y el método de Croston (CM). Realizaron la previsión para tres diferentes productos con comportamiento de demanda diferente. Los resultados de acuerdo al MAE, son que el método de ANN es superior a los otros dos para demanda intermitente y SVM funciona mejor que CM mientras más alto sea el  $C_V^2$ .

Por otra parte, Kiefer, Bauer et al. (2021) realizaron un estudio comparativo para pronosticar la demanda intermitente y lumpy utilizando métodos estadísticos, de ML y deep learning, el cual es un subcampo de Machine Learning y funciona mediante una estructura jerárquica de redes neuronales artificiales la cual permite realizar el análisis de datos de forma no lineal (Centeno Franco, 2019).

Los resultados muestran que para el tipo de demanda lumpy, el modelo con mejor desempeño es el método de Croston, seguido por los métodos Long Short-Term Memory (LSTM) y LSTM-2 basados en DL y en cuarto lugar el método Bosques Aleatorios basado en ML.

### 3.3 Desventajas de utilizar modelos de pronóstico de demanda basados en ML

Los métodos tradicionales de pronósticos se basan en series de tiempo, es decir, funcionan bajo la hipótesis de que la demanda futura puede ser estimada estadísticamente mediante la demanda pasada. Estas herramientas presentan un buen desempeño al aplicarse en mercados cuya demanda es estable, sin embargo, este no siempre es el caso pues la demanda puede depender de factores que no están vinculados con los datos pasados. Entre estos factores se pueden mencionar los cambios climáticos, desastres naturales, la situación de la economía, cambio de precio de productos o servicios sustitutos, cambio de precio de productos o servicios complementarios y ofertas.

Existen otros tipos de modelos que ayudan a resolver este problema: los modelos causales. Estos modelos proponen métodos que incluyen elementos exógenos como variables macroeconómicas, condiciones climáticas, estrategias de marketing, etc. (Usuga Cadavid, Lamouri, & Grabot, 2018).

Los modelos basados en ML tienen la capacidad de encontrar correlaciones lo que puede considerarse como suficiente para la mayoría de las aplicaciones comerciales como podría ser en la

predicción de precios o en la clasificación de objetos. Sin embargo, “los sistemas de aprendizaje automático sobresalen en el aprendizaje de las conexiones entre los datos de entrada y las predicciones de salida, pero carecen de razonamiento sobre las relaciones causa-efecto o los cambios ambientales” (Gonfalonieri, 2020).

A pesar de dicha problemática a la que se enfrentan los modelos basados en ML, durante los últimos años ha existido un avance en cuanto al desarrollo de la inferencia causal en el área. Un sistema que comprendiera la causa-efecto, sería más eficiente pues podría identificar la manera en que los factores exógenos afectarían la demanda e inclusive podría identificar nuevos factores a los previstos.

Por otro lado, tras la revisión de la literatura se puede deducir que el éxito de la implementación de modelos de ML en pronósticos recae, entre otros factores, en identificar los parámetros correctos a incluir en el modelo y en seleccionar el modelo adecuado para un caso en particular que incluso pueden ser modelos híbridos, dependiendo del caso de estudio, ya que un método tradicional de pronóstico puede ser el más eficiente.

Como primeros pasos para el desarrollo de estos modelos es necesario contar con la información útil con la que puedan ser alimentados, lo cual puede implicar una problemática al tener que ser extraída de grandes conjuntos de datos. La minería de datos es la ciencia que se encarga de esta tarea y al ser utilizada en conjunto con la IA permite construir modelos de ML.

### 3.4 Minería de datos y Machine Learning

Para Palacios (2019) Minería de Datos (DM) se refiere a la ciencia de extraer información útil de grandes conjuntos o bases de datos cuyo objetivo principal es explorar y descubrir hechos significativos en la historia de la organización que permitan vislumbrar, explicar y pronosticar el comportamiento de sus variables; de manera que dicha ciencia permite estimar el comportamiento de una empresa en un futuro cercano.

La Minería de Datos difiere de ML por su objetivo y los procesos que conllevan. Mientras que la primera busca identificar “patrones interesantes y novedosos, así como de modelos descriptivos, comprensibles y predictivos a partir de datos a gran escala” (Zaki & Meira, 2014), ML busca reproducir los patrones conocidos y hacer predicciones con base en ellos, además de que utiliza algoritmos de autoaprendizaje para mejorar su rendimiento en una tarea, a partir del aprendizaje automático de parámetros de los modelos basándose en los datos (Palacios Morales, 2019).

Así, los modelos de Machine Learning se construyen con el conjunto de técnicas utilizadas en Minería de Datos e Inteligencia Artificial.

Dada la relevancia y utilidad de la MD, existen diferentes metodologías que han surgido a manera de guía para que estas técnicas sean utilizadas en proyectos de diferentes tipos en la industria, ya sean de minería de datos, ML o Big data. Una de ellas es la metodología CRISP-DM.

### 3.4.1 Metodología CRISP-DM

La metodología CRISP-DM (Cross-Industry Standard Process for Data Mining, por sus siglas en inglés) es una de las metodologías que se recomienda seguir para el trabajo de análisis y minería de datos.

La metodología CRISP-DM está compuesta por 6 fases cuya secuencia no es estricta, dado que los proyectos pueden avanzar y retroceder entre fases en caso de que sea necesario.

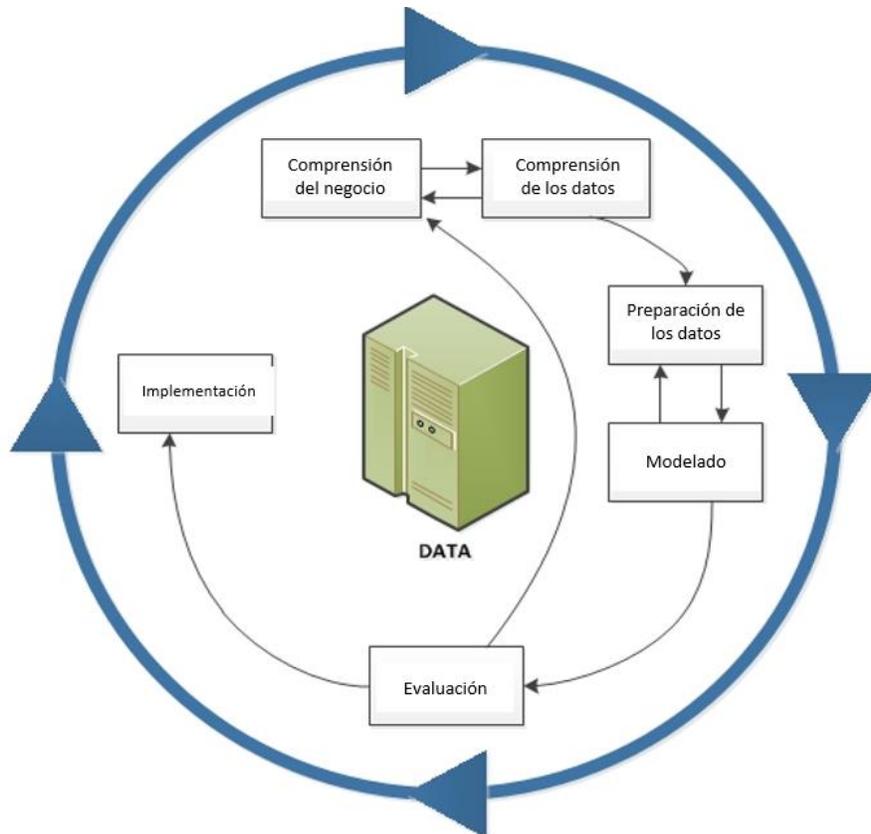


Ilustración 26. Metodología CRISP-DM

Fuente: (IBM, s.f.).

1. **Comprensión del negocio.** La primera fase consta en la comprensión de los objetivos y requisitos del proyecto desde una perspectiva de negocio. Con el fin de convertirlos en objetivos técnicos y en un plan de proyecto. En esta fase se incluyen tareas como la determinación de los objetivos, la evaluación de la situación y la elaboración del plan de proyecto.
2. **Comprensión de los datos.** En esta fase se realizan las siguientes actividades: la recolección inicial de los datos, descripción de los datos, exploración de los datos y verificación de la calidad de los datos.
3. **Preparación de los datos.** En esta fase se realiza la selección de datos a los que se aplicará la técnica de modelado (variables y muestras), la limpieza de los datos, la generación de

variables adicionales, la integración de diferentes conjuntos de datos y cambios de formatos.

4. **Modelado.** En esta fase se seleccionan las técnicas apropiadas para el desarrollo del proyecto. La técnica por emplearse debe ser seleccionada en función a los siguientes criterios: ser apropiada al problema, disponer de los datos adecuados, cumplir con los requerimientos del problema y el conocimiento de la técnica. Las tareas que se desarrollan en esta fase son: la selección de la técnica de modelado, la generación del plan de prueba, la construcción del modelo y la evaluación del modelo.
5. **Evaluación:** En esta fase se evalúa el modelo, pero no desde el punto de vista de los datos sino del cumplimiento de los requerimientos iniciales. Se debe revisar todo el proceso teniendo en cuenta los resultados obtenidos e identificando los errores que llevan a repetir algún proceso anterior. Las tareas para realizar en esta fase son: evaluación de los resultados, revisión del proceso y determinación de los próximos pasos a seguir.
6. **Implementación:** Una vez que se determinó que el modelo generado es válido, es decir, que se realizó la evaluación, se procede a su implementación y aplicación. La metodología dicta que los proyectos de minería de datos normalmente no terminan con la implementación de los modelos, sino que se deben documentar y presentar los resultados de manera comprensible para alcanzar un mejor entendimiento del conocimiento. En esta fase se elabora un plan de implementación y se realiza una monitorización y mantenimiento (Palacios Morales, 2019).

## Capítulo 4. Propuesta metodológica

En este capítulo se describe la metodología seleccionada para el proyecto de investigación, la cual consiste en las siguientes fases y toma como referencia la metodología CRISP-DM:

1. Comprensión del negocio
2. Selección de las variables de interés.
3. Recolección y análisis de datos.
4. Preparación de los datos.
5. Modelado
6. Evaluación del modelo (underfit/overfit)
7. Análisis de resultados
8. Propuesta del plan de ventas y operaciones (S&OP)



Ilustración 27. Metodología propuesta para el caso de estudio.

### 1. Comprensión del negocio

La primera fase consta de la comprensión de la empresa, de sus operaciones, misión y visión con el fin de desglosar su estrategia e iniciativas comerciales clave para identificar las necesidades de la organización y posteriormente desarrollar del plan de ventas y operaciones.

### 2. Selección de las variables de interés

Para realizar una proyección a futuro de la demanda es necesario recopilar los datos históricos sobre la demanda en la organización, pero también es preciso identificar las variables que impacten en el comportamiento de la demanda a través del tiempo.

Para utilizar un modelo de pronóstico basado en ML, se precisa de los datos históricos ayuden al algoritmo a aprender el comportamiento de los datos para predecir, así como información extra que afecte de alguna manera la tendencia de los datos.

### 3. Recolección y análisis de datos

Se recolecta la información necesaria para la aplicación del modelo de pronóstico, el tamaño de muestra de los datos debe ser el adecuado para asegurar la eficacia del modelo (entre más información se obtenga más certero será el pronóstico), también implica realizar la descripción y la calidad de los datos.

#### **4. Preparación de los datos**

Para trabajar con los modelos ML la representación de los datos es muy importante para obtener buenos resultados, por lo que es fundamental realizar un preprocesamiento de datos.

Dicho tratamiento de los datos consiste en ejecutar una revisión con la finalidad de ordenarlos, limpiarlos, generar variables adicionales, detectar inconsistencias y realizar cambios de formatos.

#### **5. Modelado**

Se identifica el comportamiento de la demanda analizando su composición, es decir, si presenta una tendencia, ciclos, una forma definida o aleatoria, estacionalidad, etc., para determinar qué tipo de modelo será el adecuado para la predicción de la demanda.

Se seleccionan las técnicas apropiadas para formular el modelo del pronóstico, se genera el plan de prueba y se construye el modelo, para el cual previamente se inicia la identificación del conjunto de datos de entrenamiento del algoritmo para que aprenda el comportamiento de los datos y del conjunto de prueba que incluye los datos con los que se evalúa la precisión del pronóstico.

La aplicación del modelo se lleva a cabo por completo utilizando el lenguaje de **programación Python**, con el que se realiza la formulación del modelo y entrenamiento de los datos. Tras la aplicación del modelo se obtendrá la predicción de la demanda futura, así como los gráficos permitentes.

#### **6. Evaluación del modelo**

En esta fase se evalúa el modelo, pero no desde el punto de vista de los datos sino del cumplimiento de los requerimientos iniciales. Se revisan los resultados y el proceso para lo que se cuenta con técnicas para medir la calidad de los resultados: estos son los errores de pronóstico y la comparación entre el comportamiento de los conjuntos de entrenamiento, validación y prueba.

#### **7. Análisis de resultados**

En el análisis de resultados se hace la comparación del modelo predictivo utilizando ML con un modelo tradicional para evaluar la efectividad de la herramienta.

De igual manera, se revisa el impacto del uso de la herramienta en la planeación de la producción y en el S&OP con el fin de realizar propuestas de mejora con base en la predicción de la demanda.

Se realiza la interpretación del resultado en cuanto al impacto que tiene sobre el plan de ventas y operaciones.

#### **8. Propuesta del plan de ventas y operaciones (S&OP)**

Uso del pronóstico de la demanda para proponer un plan de ventas y operaciones en empresas de servicios.

---

Con base al resultado obtenido del modelo de pronóstico se desarrolla un plan de ventas y operaciones que sirva como apoyo a la dirección de la empresa para la toma de decisiones.

En este trabajo, el S&OP incluye los planes de: ventas, operaciones, finanzas.

## Capítulo 5. Caso de estudio

Este trabajo se centra en el desarrollo de un plan de ventas y operaciones (S&OP), tomando como principal variable de entrada el pronóstico de la demanda del producto principal de la empresa (Administrador XML), debido a que los demás procesos dependen de ella. EL S&OP tiene como enfoque principal conseguir una base operativa para evaluar la demanda y garantizar que se disponga de los recursos suficientes en toda la empresa para satisfacerla, apoyándose en la coordinación entre la planificación de las ventas y la planificación de la producción.

El objetivo de la propuesta de un S&OP es equilibrar la oferta y la demanda y construir un puente entre el plan estratégico del negocio y los planes operativos de la empresa. Aunque es un proceso que comúnmente es utilizado en empresas pertenecientes al sector manufacturero, también es aplicable a empresas de servicios, considerando que tienen necesidades y condiciones diferentes.

### 5.1 Antecedentes del caso de estudio

*Softing* es una microempresa que cuenta con más de 25 años de experiencia en el mercado dirigidos a analizar, diseñar, desarrollar e implementar soluciones con desarrollo de software a la medida y a la venta de software administrativo de una compañía comercial reconocida. El segmento al que sus servicios están dirigidos se compone por pequeñas y medianas empresas pertenecientes a diferentes sectores como el financiero, comercial, industrial y logístico.

El organigrama por áreas de la empresa se muestra en la siguiente imagen:

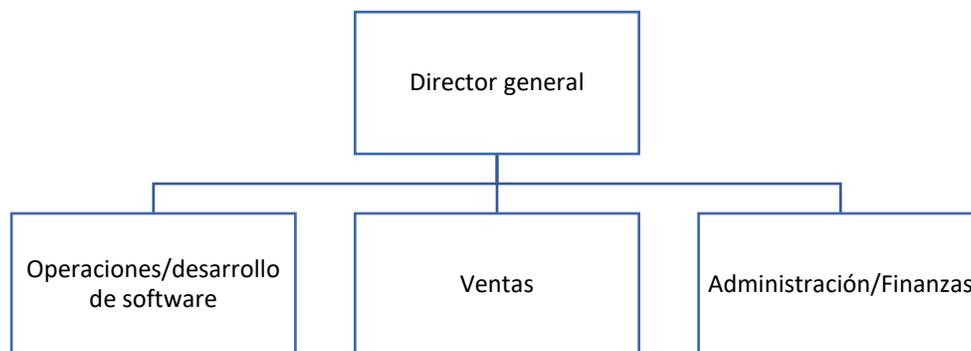


Ilustración 28. Organigrama por áreas de Softing.

A raíz del crecimiento tecnológico que se vive actualmente debido al aprovechamiento de los datos, la empresa ha dirigido sus esfuerzos al estudio, desarrollo e implementación de aplicaciones de escritorio y aplicaciones web utilizando Big Data.

La empresa se dedica a la creación de soluciones y automatización de procesos en el área administrativa de las empresas, en la que se abordan la facturación electrónica, ventas, remisiones, devoluciones, nómina, proveedores (órdenes y recepciones de compra), cobranza, contabilidad e

inventarios, por mencionar algunos, a través del diseño y desarrollo de aplicaciones de escritorio, aplicaciones web y aplicaciones móviles.

Además del área de diseño y desarrollo de software, también ofrece servicios de consultoría, capacitación, comunicaciones digitales y de distribución de hardware y de un producto comercial conocido como un software administrativo que está dirigido a pequeñas y medianas empresas, el cual había sido el sustento financiero de la empresa que le ha permitido comenzar con el desarrollo de software propio.

La diversificación de servicios que ofrece la empresa se resume en la Tabla 4:

Tabla 4. Servicios que ofrece la empresa *Softing*

Servicio	Descripción
<b>1. Diseño y desarrollo de aplicaciones (Software)</b>	<p>Entre las soluciones que ofrece la empresa se encuentran los siguientes softwares desarrollados y comercializados por la misma (además de servicios de capacitación y asesoría de estos):</p> <ul style="list-style-type: none"> <li>• Portal de documentos digitales</li> <li>• Administrador XML Total/single</li> <li>• Contabilidad electrónica</li> <li>• Control de almacén</li> <li>• Control de gastos</li> <li>• Live Picking</li> <li>• Factura electrónica</li> </ul>
<b>2. Servicios</b>	<p>Los servicios que ofrece la empresa son, de manera general:</p> <ul style="list-style-type: none"> <li>• Comunicaciones digitales: soporte de redes, administración de redes, acceso remoto seguro a aplicaciones y respaldo de servidores.</li> <li>• Soporte TI</li> <li>• Capacitación</li> <li>• Asesorías</li> <li>• Instalación</li> <li>• Servicios de implementación</li> <li>• Servicios en la nube</li> </ul>
<b>3. Distribución de software administrativo</b>	<p>Distribución del software comercial de una compañía externa y los servicios de instalación, capacitación, renovación de licencias, etc.</p>
<b>4. Hardware</b>	<p>Otro de las áreas a las que se dedica la empresa es a la comercialización de equipo, así como al servicio de planeación de crecimiento de base tecnológica instalada y al mantenimiento preventivo y correctivo de computadoras.</p>

Fuente: Elaboración propia

Para la comprensión del negocio, se enuncian a continuación la misión y la visión de la empresa:

- Misión: *Softing* ofrece a los clientes soluciones innovadoras que dan resultados a sus procesos y modelos de negocio con uso de tecnología a la vanguardia. *Softing* es capaz de llevar las últimas tendencias tecnológicas para alcanzar resultados y obtener valor en los datos.
- Visión: Ser una empresa competitiva y sostenible en el mercado a través de la innovación y creatividad de soluciones Big Data, dando soluciones y valor a nuestros clientes.

La empresa ha identificado el área de oportunidad del uso de herramientas para la ciencia y analítica de datos como el Big Data como una forma de innovación y de ofrecer valor a los clientes. De este modo, el desarrollo de soluciones tecnológicas utilizando herramientas de Big Data es parte de la visión de la empresa y para su implementación, es necesario que centre sus esfuerzos en esta área. La empresa ha comenzado a crecer y a ser reconocida por el uso de esta tecnología con la venta del software “Administrador XML” (AXML) y del “Portal de documentos digitales”.

Esto lleva a que el desarrollo de esta investigación se centre en ellos productos AXML y Portal de documentos digitales porque representan el área (diseño y desarrollo de aplicaciones) en la que la empresa tiene como objetivo destacar y crecer, deslindándose de productos externos. Para ello es necesario hallar en el mercado el área de oportunidad de la demanda de los productos antes mencionados.

Para fines de realizar este trabajo de investigación, solo se realiza el análisis del “AXML” dado que el “portal de documentos digitales” no cuenta con una base de datos de ventas históricas lo suficientemente robusta.

## 5.2 Selección de variables de interés

El propósito del modelo a aplicar es realizar un pronóstico de ventas del “AXML” de la empresa *Softing* para mejorar su precisión y de esta manera, anticipar y realizar la planeación de los recursos requeridos para su venta y para el crecimiento de estas.

Los datos de entrada del modelo es la información histórica de las ventas del “AXML” que en este caso son las ventas de un periodo de 5 años y 8 meses o 165 periodos (quincenas), para los cuales las variables de interés son la fecha y el número ventas de la licencia del software y la cantidad de actualizaciones vendidas.

Esta última variable es de interés dado que la empresa lanza actualizaciones del software y con ella se puede analizar el comportamiento de los clientes y evaluar su frecuencia de compra.

## 5.3 Recolección y análisis de datos

Para la recolección de los datos la empresa proporciona la información sobre sus ventas en el software Microsoft Excel en la cual la información correspondiente a las variables antes definidas es capturada para posteriormente. organizarla y manipularla.

Se realiza un primer análisis de los datos con el fin de hallar el comportamiento de la demanda y para saber si, en dado caso, sería conveniente recolectar otro tipo de variables de interés. De igual manera, es pertinente realizar la limpieza de datos y un análisis de datos faltantes.

#### 5.3.1 Análisis de datos (Administrador XML)

Para el desarrollo de los procesos de análisis y preparación de datos, aplicación de modelo y análisis de resultados se utiliza el entorno Python 3.6 *Anaconda* que provee las Jupyter Notebooks. De igual manera se aprovechan las librerías *pandas* y *numpy* para el análisis y el manejo de datos y para impulsar las herramientas de ML, también se usa la librería *matplotlib* para graficar.

La información de las ventas del AXML se presenta en la Ilustración 29, la cual se agrupó en periodos quincenales.

El periodo de análisis se elige de quince días dado que, al tener una mayor cantidad de periodos, también se tendrá una mayor cantidad de datos con los cuales alimentar el modelo de pronóstico y así, obtener una mayor precisión.

En la literatura el horizonte sugerido para que se lleven a cabo las reuniones formales entre las funciones de ventas y operaciones de la empresa para dar seguimiento al plan es de un mes, por lo cual este periodo de revisión es el indicado para el plan S&OP con la finalidad de evaluar si el plan se está cumpliendo o no según lo esperado respecto a las ventas o si es necesario realizar ajustes o diseñar alguna estrategia inmediata que esté asociada con las operaciones diarias.

Por otro lado, como se explicó anteriormente, el periodo de análisis del pronóstico de demanda será quincenal por cuestión de la cantidad de datos con los que se cuentan del caso de estudio.

En la siguiente ilustración se observan las ventas del AXML en donde la serie en color azul muestra las unidades y la serie en color naranja muestra las actualizaciones del software que fueron vendidas.

## Uso del pronóstico de la demanda para proponer un plan de ventas y operaciones en empresas de servicios.

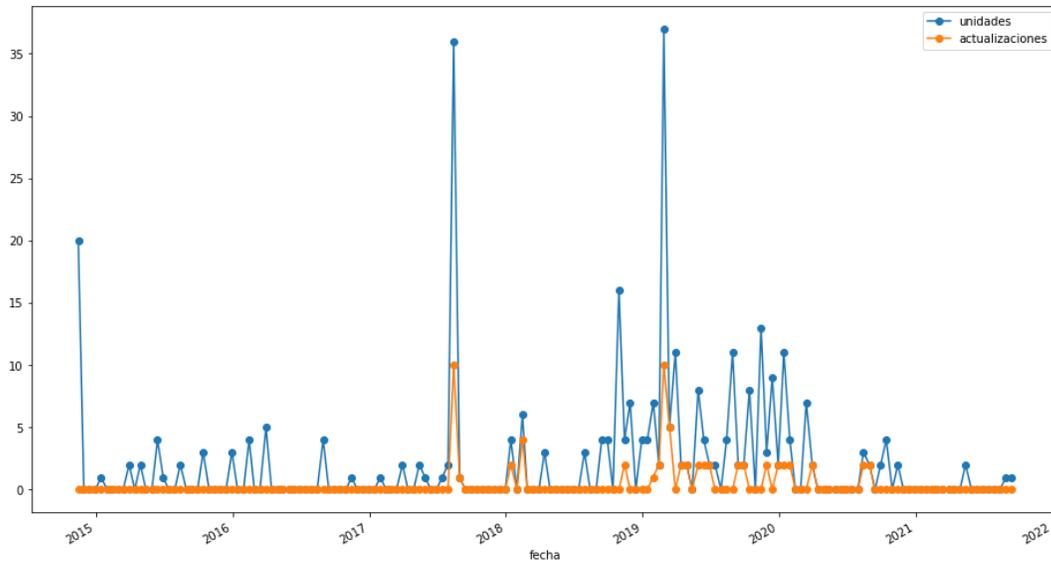


Ilustración 29. Serie de tiempo de ventas del AXML

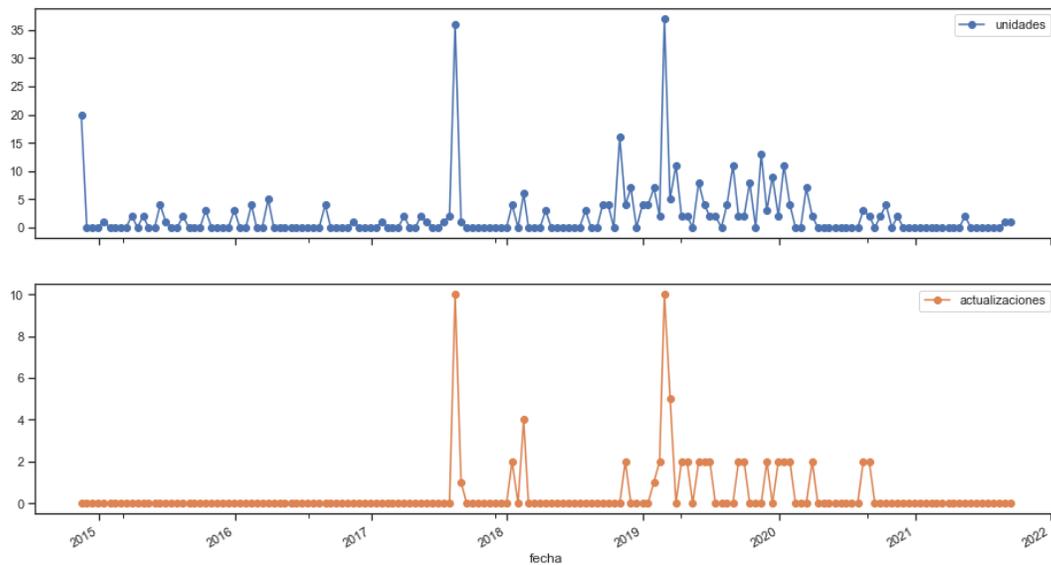


Ilustración 30. Serie de tiempo de ventas del AXML (unidades y actualizaciones)

Como puede observarse en la representación gráfica de la serie de tiempo, existen periodos con ventas nulas, las cuales se deben principalmente a la ausencia de marketing para dar a conocer el producto en el mercado durante algunos periodos y, posteriormente, a la crisis de las MiPymes por la pandemia que inició en México en marzo de 2020 y que trajo como consecuencia para muchas empresas la inestabilidad económica para adquirir cualquier tipo de productos que no sean esenciales para sus negocios.

De igual manera, se observan principalmente tres picos de demanda que representan los datos atípicos de los datos históricos. Estos registros de ventas se dieron en el primer mes de ventas del producto dada la promoción que se dio en un inicio (posterior a ello no se le dio continuidad al

marketing) y los dos picos siguientes se dieron en periodos en los que se realizaron actualizaciones al software, lo que trajo como consecuencia el aumento de dichas ventas.

La descripción estadística de los datos se muestra en la siguiente tabla (ver Anexo 1):

Tabla 5. Descripción estadística de la serie de tiempo.

Indicador	Descripción
$N = 165$	La serie de tiempo está conformada por 165 periodos.
$n_U = 64$	Los datos correspondientes a Unidades están conformados por 64 registros con un valor diferente a 0
$n_A = 23$	Los datos correspondientes a Actualizaciones están conformados por 23 registros con un valor diferente a 0
$\bar{x}_U = 20.02$	La media la demanda de las Unidades es de 20.02
$\bar{x}_A = 0.39$	La media de la demanda de las Actualizaciones es 0.39
$\sigma_U = 4.92$	La desviación estándar de la demanda de las Unidades vendidas es de 4.92
$\sigma_A = 1.32$	La desviación estándar de la demanda de las Actualizaciones vendidas es de 1.32
$Min_U = 0$	La demanda mínima de las Unidades es 0
$Min_A = 0$	La demanda mínima de las Actualizaciones es 0
$Max_U = 37$	La demanda máxima de las Unidades es 37
$Max_A = 10$	La demanda máxima de las Actualizaciones es 10

Fuente: Elaboración propia

Para caracterizar la demanda se utiliza el esquema de categorización de la demanda (Ilustración 18) para lo que se calcula el Coeficiente de Variación Cuadrática ( $C_V^2$ ) y el Promedio del Intervalo entre Demandas (ADI).

Tabla 6. Indicadores de categorización de la demanda

	$C_V^2$	ADI
Unidades	5.9	2.57
Actualizaciones	11.21	7.17

Fuente: Elaboración propia

La primera hipótesis sobre el comportamiento intermitente de la demanda queda descartada dados los indicadores anteriores. Según los resultados, las series de tiempo tanto de Unidades como de Actualizaciones presentan un patrón de demanda de tipo grumosa o Lumpy. Esta conclusión hace sentido (además del  $C_V^2$  y del ADI), por su representación gráfica, puesto que, a diferencia de una demanda Intermitente, la demanda Lumpy presenta mayor variabilidad entre los datos.

ADI muestra el intervalo medio en periodos de tiempo entre dos demandas no nulas, es decir, que en el caso de *unidades* se presenta una demanda no nula cada 2.57 periodos y en *actualizaciones* cada 7.17 periodos.

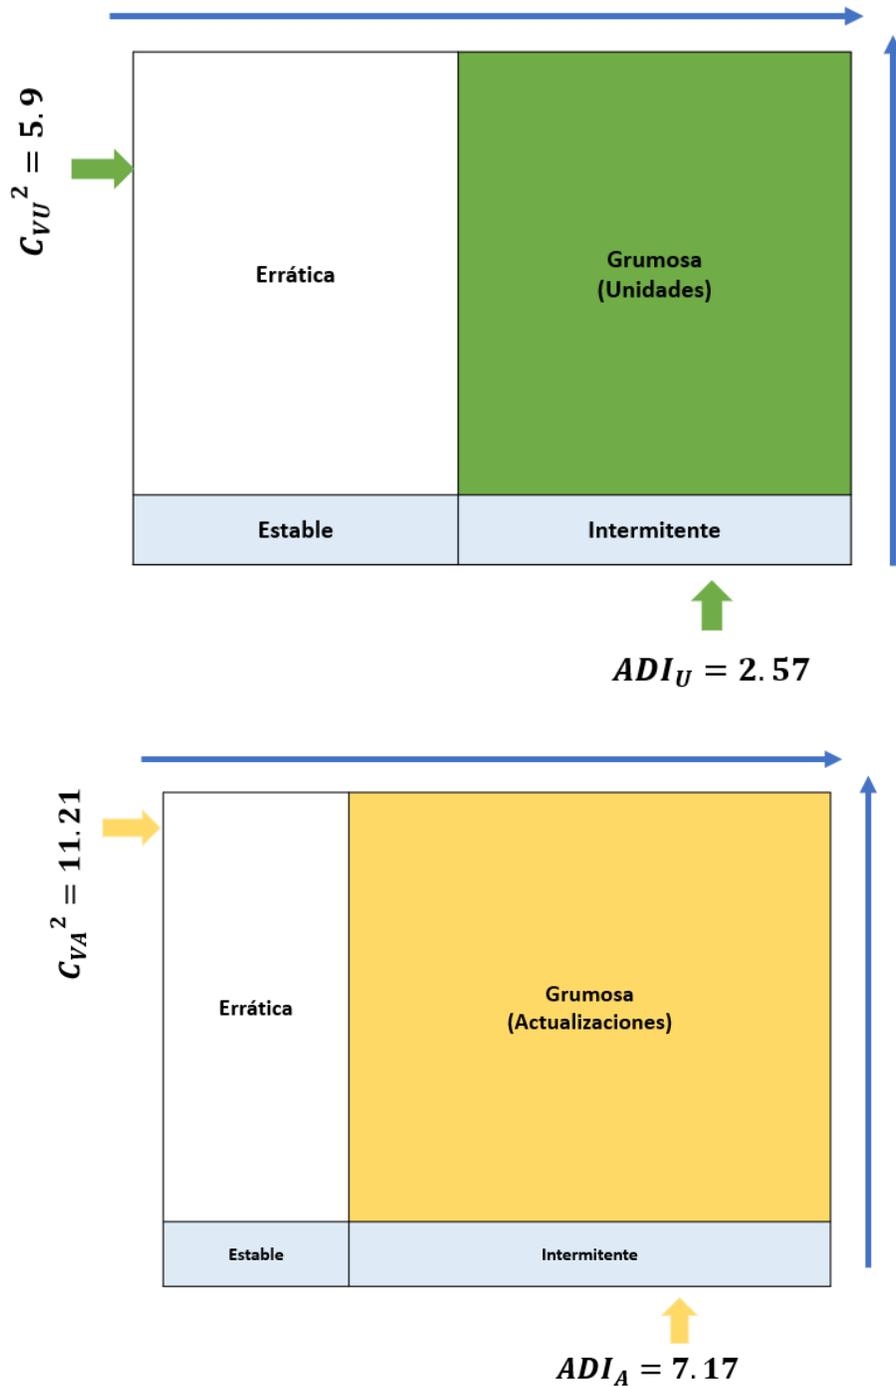


Ilustración 31. Esquema de categorización de demanda: Unidades y Actualizaciones vendidas del AXML.

Otro análisis realizado fue la correlación entre las variables “unidades” y “actualizaciones” mostrado por el mapa de calor en la siguiente imagen.

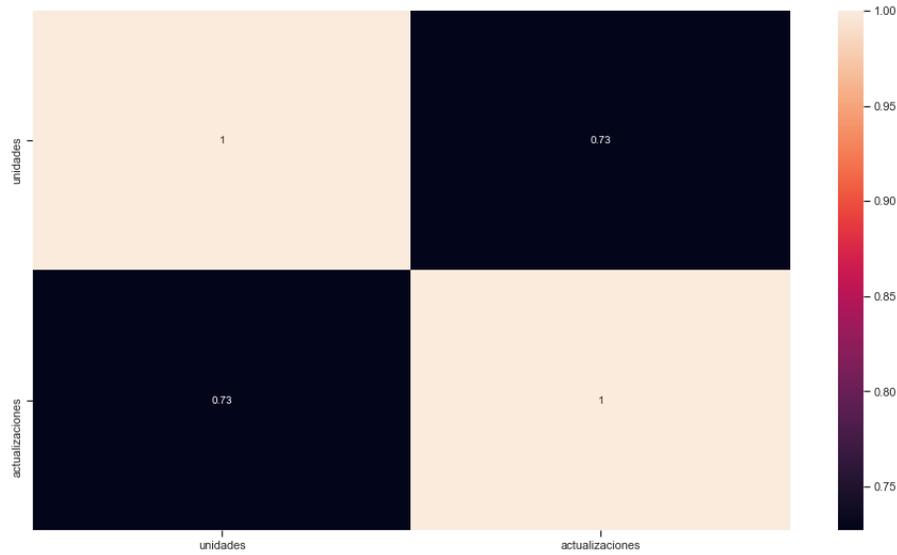


Ilustración 32. Correlación entre las variables "unidades" y "actualizaciones".

Como se puede observar, la correlación entre ambas variables es de 0.75, lo que indica que hay una relación positiva entre ambas y si una aumenta la otra también aumenta. Lo que significa que, históricamente, a mayor venta de unidades también hay un aumento de venta de actualizaciones.

Por tanto, "actualizaciones" es una variable de interés a incluir en el modelo de pronóstico de la demanda de unidades.

#### 5.4 Preparación de los datos

Los datos con los que se trabaja el modelo se encuentran en un archivo .csv que contiene una columna de "periodo", otra de "unidades" y una más de "actualizaciones" como se observa en la siguiente ilustración de los primeros cinco periodos visualizados en Jupyter.

	<b>unidades</b>	<b>actualizaciones</b>
<b>fecha</b>		
<b>2014-11-15</b>	20	0
<b>2014-11-30</b>	0	0
<b>2014-12-15</b>	0	0
<b>2014-12-31</b>	0	0
<b>2015-01-15</b>	1	0

Ilustración 33. Vista de los datos de la serie de tiempo

El modelo de pronóstico está basado en el modelo de Bagnato (2019), en donde desarrolla un ejemplo sobre un pronóstico de ventas diarias utilizando ML.

Siguiendo dicho ejemplo, uno de los primeros pasos, en la etapa de la preparación de los datos, es convertir la serie temporal en un problema de tipo supervisado, es decir, este proceso consiste en añadir más columnas a la serie de tiempo para pasar de tener una secuencia a tener patrones de entrada (X) y patrones de salida (Y) con el fin de que el algoritmo pueda predecir los patrones de salida a partir de los patrones de entrada.

1	0
2	1
3	2
4	3
5	4
6	5
7	6
8	7
9	8
10	9

1	X,	y
2	1,	2
3	2,	3
4	3,	4
5	4,	5
6	5,	6
7	6,	7
8	7,	8
9	8,	9

Ilustración 34. Ejemplo de serie de tiempo vs aprendizaje supervisado.  
Fuente: (Brownlee, Machine Learning Mastery, 2017).

En este caso, para convertir la serie de tiempo en un problema de tipo supervisado se utiliza la función *series\_to\_supervised()* (Brownlee, Machine Learning Mastery, 2017).

De esta manera se obtiene la serie de tiempo transformada en el siguiente formato en donde se visualizan algunos de los periodos. También se utiliza la función *MinMaxScaler* para transformar los valores escalándolos entre -1 y 1 para facilitar los cálculos.

	var1(t-40)	var1(t-39)	var1(t-38)	var1(t-37)	var1(t-36)	var1(t-35)	var1(t-34)	var1(t-33)	var1(t-32)	var1(t-31)	...	var1(t-9)	var1(t-8)	var1(t-7)	var1(t-6)
40	0.081081	-1.000000	-1.000000	-1.000000	-0.945946	-1.000000	-1.000000	-1.000000	-1.000000	-0.891892	...	-1.000000	-1.000000	-0.72973	-1.0
41	-1.000000	-1.000000	-1.000000	-0.945946	-1.000000	-1.000000	-1.000000	-1.000000	-0.891892	-1.000000	...	-1.000000	-0.72973	-1.000000	-1.0
42	-1.000000	-1.000000	-0.945946	-1.000000	-1.000000	-1.000000	-1.000000	-0.891892	-1.000000	-0.891892	...	-0.72973	-1.000000	-1.000000	-1.0
43	-1.000000	-0.945946	-1.000000	-1.000000	-1.000000	-1.000000	-0.891892	-1.000000	-0.891892	-1.000000	...	-1.000000	-1.000000	-1.000000	-1.0
44	-0.945946	-1.000000	-1.000000	-1.000000	-1.000000	-0.891892	-1.000000	-0.891892	-1.000000	-1.000000	...	-1.000000	-1.000000	-1.000000	-1.0

5 rows × 41 columns

Ilustración 35. Preparación de los datos: transformación de la serie de tiempo a un problema de aprendizaje supervisado para el modelo de una variable.

## Uso del pronóstico de la demanda para proponer un plan de ventas y operaciones en empresas de servicios.

fecha	var1(t-50)	var2(t-50)	var1(t-49)	var2(t-49)	var1(t-48)	var2(t-48)	var1(t-47)	var2(t-47)	var1(t-46)	var2(t-46)	...	var1(t-4)	var2(t-4)	var1(t-3)	var2(t-3)
2016-12-15	0.0	0.081081	0.0	-1.000000	0.0	-1.000000	0.0	-1.000000	0.0	-0.945946	...	0.0	-1.000000	0.0	-1.000000
2016-12-31	0.0	-1.000000	0.0	-1.000000	0.0	-1.000000	0.0	-0.945946	0.0	-1.000000	...	0.0	-1.000000	0.0	-0.945946
2017-01-15	0.0	-1.000000	0.0	-1.000000	0.0	-0.945946	0.0	-1.000000	0.0	-1.000000	...	0.0	-0.945946	0.0	-1.000000
2017-01-31	0.0	-1.000000	0.0	-0.945946	0.0	-1.000000	0.0	-1.000000	0.0	-1.000000	...	0.0	-1.000000	0.0	-1.000000
2017-02-15	0.0	-0.945946	0.0	-1.000000	0.0	-1.000000	0.0	-1.000000	0.0	-1.000000	...	0.0	-1.000000	0.0	-1.000000

5 rows × 102 columns

Ilustración 36. Preparación de los datos: transformación de la serie de tiempo a un problema de aprendizaje supervisado para el modelo de dos variables.

### 5.5 Modelado

Con base en el previo análisis del comportamiento de la demanda, se prosigue a seleccionar un método de pronóstico y la definición de sus características.

#### 5.5.1 Selección del modelo de pronóstico

En el subtema anterior se muestra el comportamiento de la demanda y de acuerdo con este y con la literatura revisada previamente en la sección 3.3.1, se selecciona el modelo de Multi Layer Perceptron MLP), basado en Redes Neuronales Artificiales para la previsión de demanda dado que en estudios anteriores mostró resultados superiores ante otros tipos de métodos.

A su vez, se desarrollan dos modelos MLP uno utilizando una variable: “unidades” y otro modelo multivariable utilizando “unidades” y “actualizaciones” con el fin de comparar su rendimiento y evaluar cuál es el más efectivo al aprovechar los datos con los que cuenta la empresa.

A manera de comparación, también se selecciona un método estadístico: el método de Croston corregido por Syntetos y Boylan, el cual estuvo presente en los casos de estudio analizados previamente y que además presentó un desempeño competitivo frente a modelos basados en ML o DL.

Para desarrollar el modelo MLP, como se mencionó anteriormente, se utiliza el entorno Python 3.6 y el ambiente Jupyter Notebooks que permite una adecuada visualización de los datos. De igual manera se hace uso de dos librerías Open Source: *Keras* y *TensorFlow*.

Keras es una biblioteca de código abierto de redes neuronales que ofrece una sintaxis sencilla para la creación de modelos de aprendizaje. Las redes neuronales son un tipo particular de gráfico de flujo de datos por lo que, para su representación, requiere de otro tipo de librerías que permita que se lleve a cabo su ejecución de manera rápida y eficiente. La librería de código abierto *TensorFlow* cumple con este último objetivo.

### 5.5.2 Desarrollo de modelos de predicción

#### Conjuntos de train y test

Como paso previo a la creación de la red neuronal, se subdivide el conjunto de datos en conjuntos de train y test, de acuerdo con la literatura (sección 3.2. Conjuntos de entrenamiento, validación y prueba.)

Para ello, se considera la regla general “80-20”, es decir, tomar el 80% de los datos para el conjunto de train y el 20% para test.

Cabe mencionar que, como se verá en el siguiente apartado, también deben seleccionarse el número de entradas, que reducen el número de datos disponibles para los conjuntos de train y test.

Para el modelo MLP de una variable se selecciona una entrada de 40, es decir, de 40 “columnas” que representan las ventas de los 40 periodos anteriores. Este valor se selecciona porque, como se observa en la Ilustración 30, la cantidad de ventas en los últimos periodos de la serie de tiempo es variable y el fin de seleccionar 40 entradas es que se tomen no solo los valores nulos, sino también los valores diferentes a cero para que el modelo se alimente de ellos. En la Ilustración 37 se visualiza el conjunto de entrada para el modelo MLP de una variable.

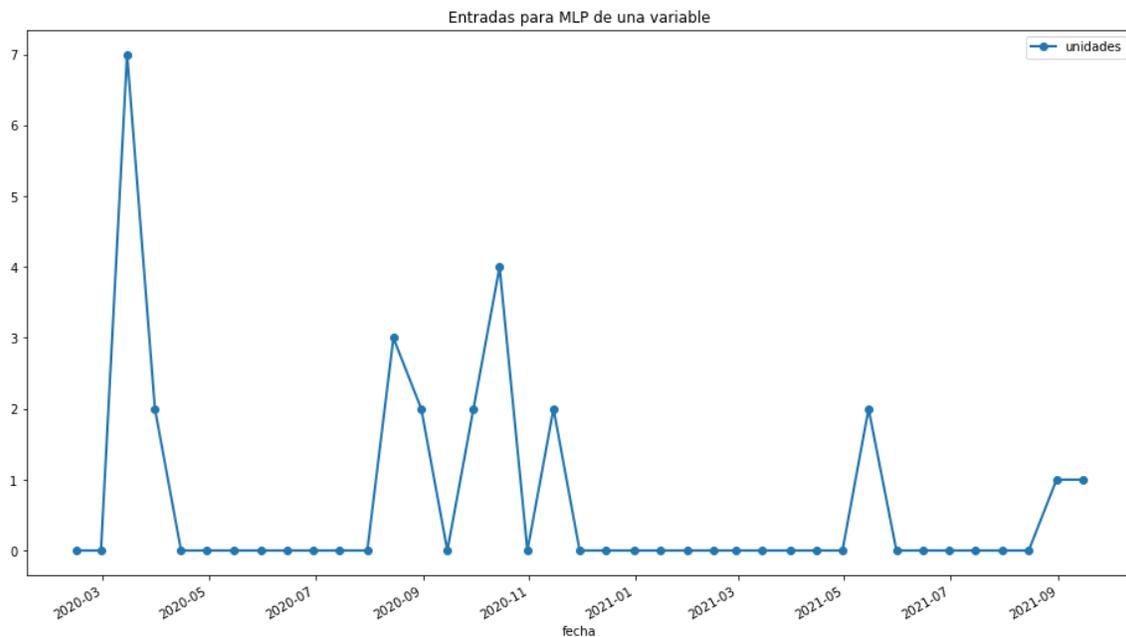


Ilustración 37. Visualización de los datos de entrada para el modelo MLP de una variable.

Al seleccionar las 40 entradas, se reduce el conjunto de datos disponible para entrenamiento y test, lo que deja un total de 125 datos disponibles, de los cuales 100 representan el 80% y 25 el 20%. Se selecciona un valor aproximado que vaya de acuerdo con la regla, en este caso son 93 datos de entrenamiento y el restante, 32 datos, para test.

En el caso del modelo de MLP multivariable, la selección del número de entradas es distinto dado que además de la variable de “unidades”, se toma también la variable “actualizaciones”. Esta última presenta una mayor variabilidad por lo que deben tomarse una cantidad mayor de entradas, pues como se observa en la Ilustración 38, los últimos periodos presentan una demanda nula y si se selecciona una baja cantidad de entradas, esos valores afectan al modelo.

Por tanto, se selecciona un valor de entrada de 50 que representa un conjunto de valores diferentes a cero. Así, la cantidad disponible de datos para los conjuntos de train y test son 115, de los cuales 80 son para train y 35 para test.

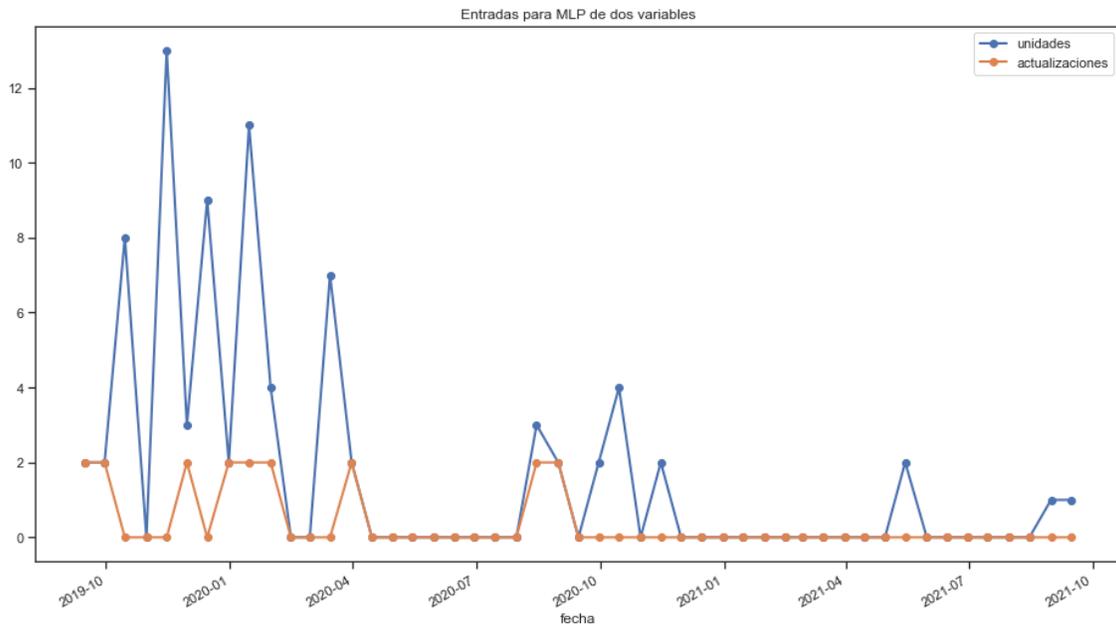


Ilustración 38. Visualización de los datos de entrada para el modelo MLP de dos variables.

#### Arquitectura de la red Neuronal MLP

Para el diseño de la arquitectura de la Red Neuronal, deben establecerse: el número de capas de entrada, el número de capas ocultas y el número de neuronas en cada una, la función de activación ( $\varphi$ ) y el número de capas de salida.

Como se muestra en la Ilustración 39, cada neurona recibe  $n$  número de entradas y calcula una salida, de acuerdo con la función de cada neurona.

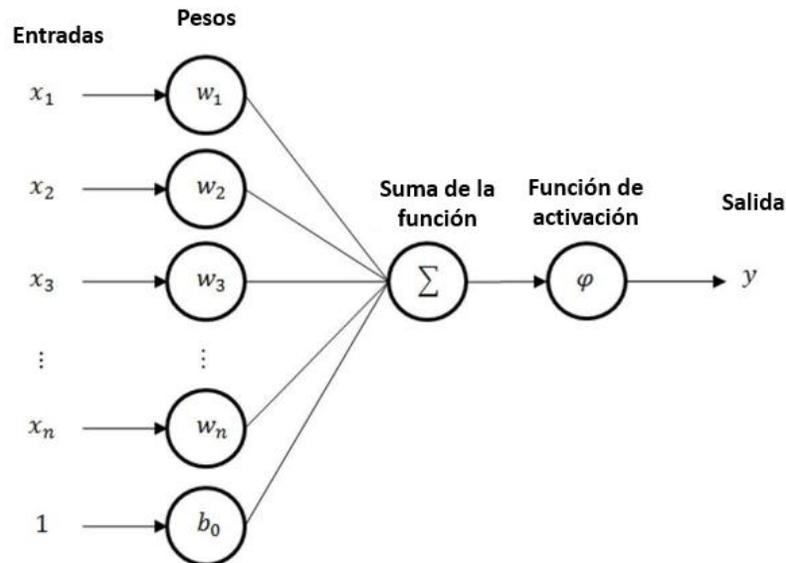


Ilustración 39. Ejemplo de una neurona artificial.  
Fuente: (Guérillot & Bruyelle, 2017)

Para el desarrollo de modelo de predicción, se sigue el siguiente modelo de Keras del ciclo de vida de un modelo de red neuronal (Brownlee, 5 Step Life-Cycle for Neural Network Models in Keras, 2020):

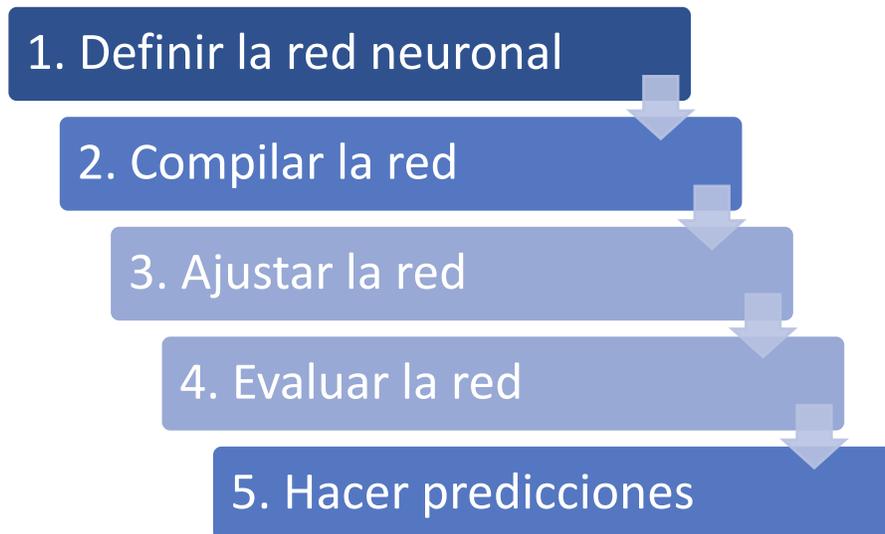


Ilustración 40. Keras Model Life-Cycle.  
Fuente: Elaboración propia con base en (Brownlee, 5 Step Life-Cycle for Neural Network Models in Keras, 2020).

### 1. Definir la red neuronal

El primer paso es definir la red neuronal. Para ello se seleccionan los siguientes parámetros:

- Entrada: como se mencionó anteriormente, para el modelo MLP de una variable se seleccionan 30 entradas y para el modelo multivariable 50 entradas.

- Capas ocultas: una capa oculta con 40 neuronas para el modelo de una variable y una capa oculta con 50\*2 neuronas para el modelo multivariable.
- Salida: la salida es de una neurona.
- Función de activación: al utilizar valores de entre -1 y 1, la función de activación utilizada es “tangente hiperbólica” además de que después de una iteración con las funciones de activación “sigmoid” y “relu”, está fue la que mejor rendimiento presentó.
- Optimizador: se utiliza el optimizador Adam y sirve para minimizar las pérdidas en cada una de las iteraciones.
- Métrica de pérdida (Loss): como métrica de pérdida en las iteraciones se utiliza el Mean Absolute Error.
- Métrica de evaluación (Accuracy): de igual manera, para analizar si el modelo mejora en cada iteración se selecciona el Mean Squared Error, el cual se espera que vaya reduciendo en cada una de ellas.

En Keras las redes neuronales se definen como una secuencia de capas y el contenedor para estas capas es la clase *Sequential*. Al crear el modelo utilizando *Sequential* se definen los parámetros antes mencionados (ver Anexo 3).

## 2. Compilar la red

La compilación de la red consta de la transformación de la secuencia de capas definidas en una serie de matrices y requiere de algunos parámetros a especificar como el algoritmo de optimización para entrenar la red, la función de pérdida y la métrica de rendimiento para el ajuste del modelo.

En este caso, estos parámetros son los que ya se establecieron previamente. Para esto se utiliza la función *compile* y puede consultarse en el Anexo 3.

## 3. Ajustar la red

Una vez que se compila la red se debe ajustar, de manera que se adapten los pesos del conjunto de datos y deben indicarse los datos en formación o la matriz de patrones de entrada y la matriz de patrones de salida. Para evaluar el ajuste se utiliza el algoritmo de optimización antes seleccionado y se especifica el número de *epochs* o épocas que se refiere al número de iteraciones de aprendizaje que conforma el ciclo por el cual el conjunto de datos es entrenado y en los que puede ir actualizando los parámetros del modelo.

*En el*

Anexo 4 se pueden observar algunas de las primeras iteraciones y resultados y como el rendimiento del entrenamiento del modelo va mejorando al reducir la variable *val\_mse* que mide la validación del modelo.

## 5.6 Evaluación del modelo

Siguiendo con la metodología propuesta para el caso de estudio (Ilustración 27), el siguiente paso es la evaluación del modelo.

### 4. Evaluar la red

Una vez entrenada la red, es decir que la red ajusta cada uno de los pesos de entrada para que las respuestas de la capa de salida sean lo más certeros posible, el siguiente paso es evaluarla. Para ello se utiliza el conjunto de datos de entrenamiento para evaluar el rendimiento de la red al predecir datos con los que no ha trabajado y así, tener una estimación de su comportamiento con nuevos datos no conocidos.

Para la evaluación del modelo se grafica la función Loss que es usada para mejorar el algoritmo de ML, de manera que permite comparar las predicciones realizadas por la red neuronal y los valores con los que no ha trabajado. La siguiente grafica muestra el comportamiento y se observa la disminución de Loss en el conjunto de train y en el de validación tanto para el modelo de una variable como el multivariable. Lo que quiere decir que conforme se realizan las iteraciones, mejora el modelo.

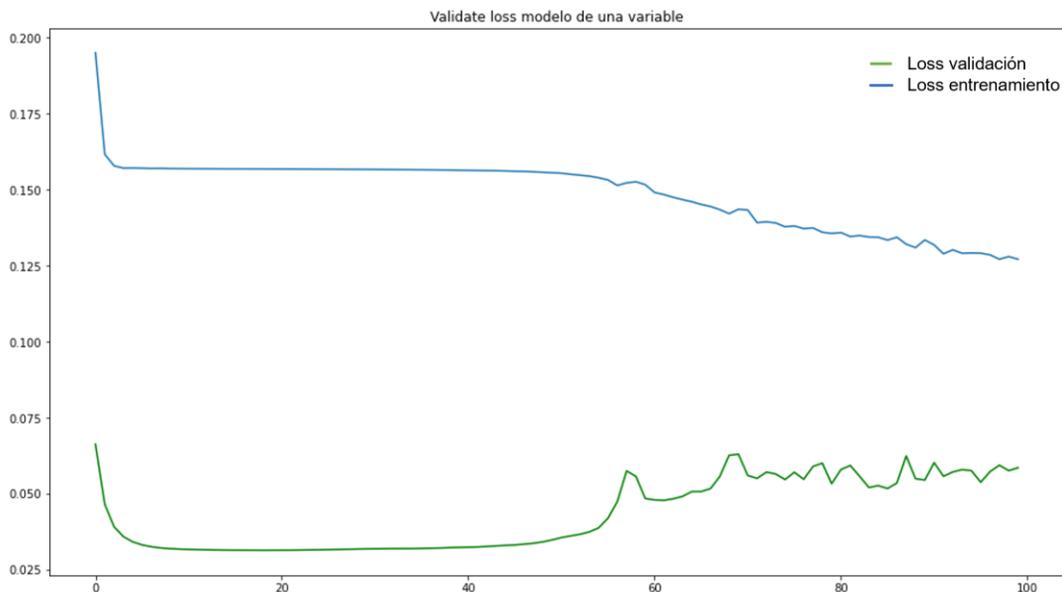


Ilustración 41. Validate loss del modelo de una variable en Jupyter

## Uso del pronóstico de la demanda para proponer un plan de ventas y operaciones en empresas de servicios.

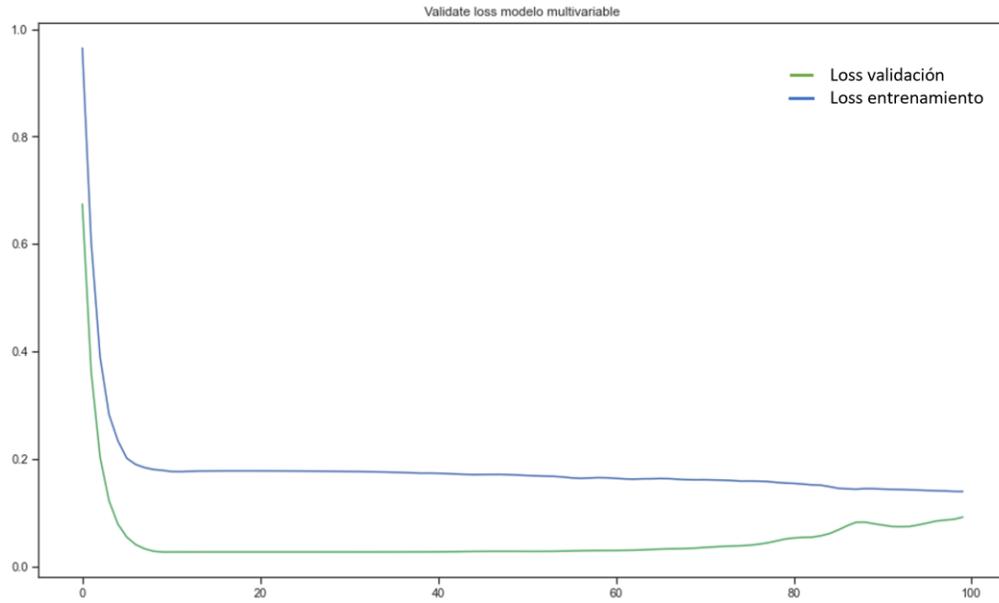


Ilustración 42. Validate loss del modelo multivariable en Jupyter

Al ser graficas diferentes y al no estar superpuestas, quiere decir que el modelo no presenta un sobre ajuste u overfitting, es decir, que el modelo no está sobre entrenado o está ajustándose a los datos ya conocidos para predecir, lo que genera una baja confiabilidad en los modelos.

De igual manera, la precisión del pronóstico (accuracy) va mejorando con cada iteración en ambos modelos.

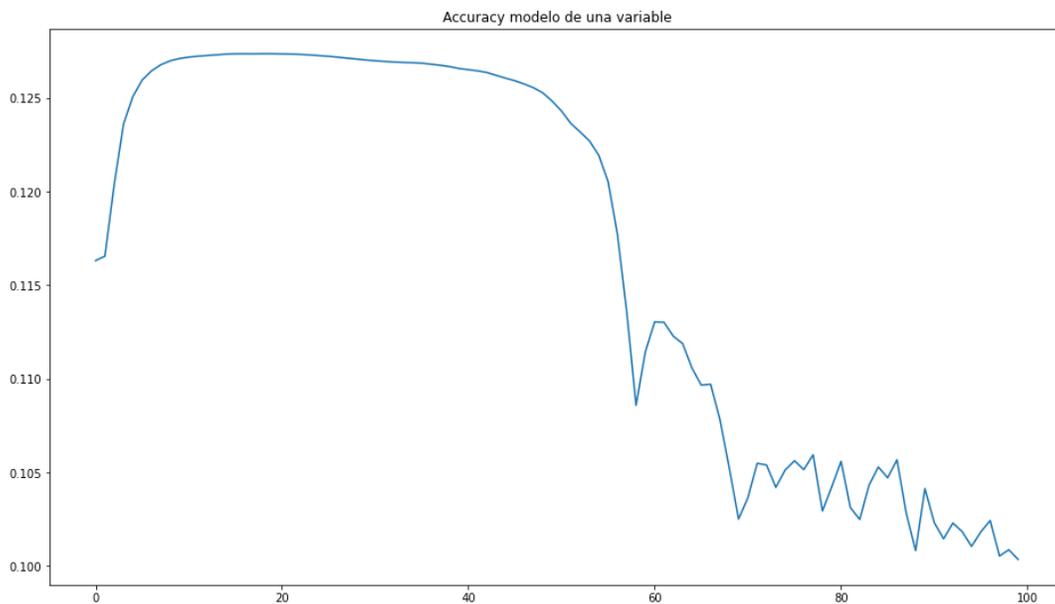


Ilustración 43. Precisión del modelo de una variable en Jupyter

## Uso del pronóstico de la demanda para proponer un plan de ventas y operaciones en empresas de servicios.

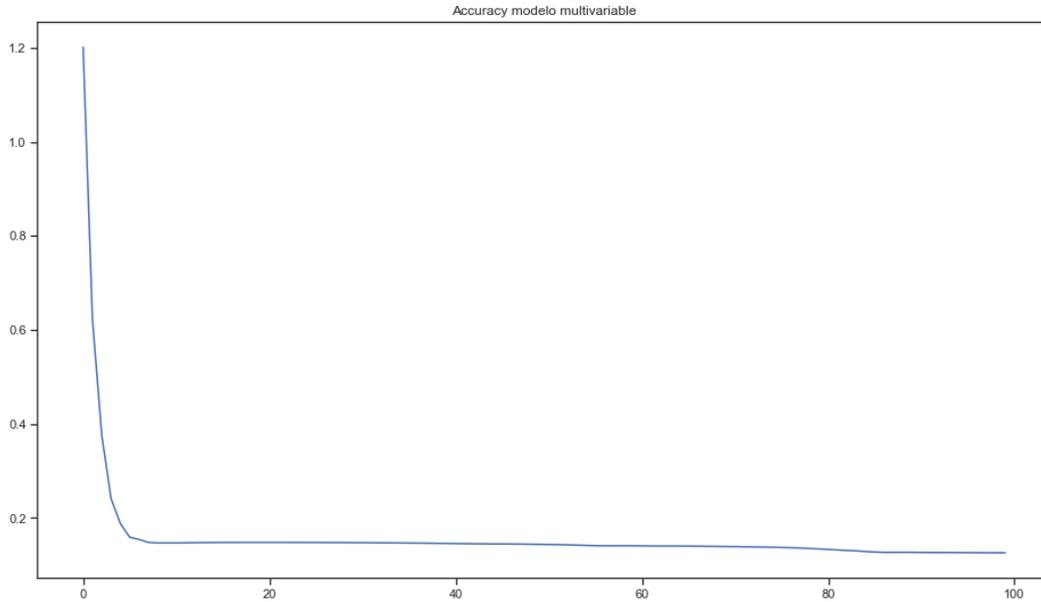


Ilustración 44. Precisión del modelo multivariable en Jupyter

En las siguientes gráficas se observa la comparación de la demanda real contra el pronóstico de ambos modelos y puede observarse que ambas previsiones presentan un comportamiento totalmente diferente.

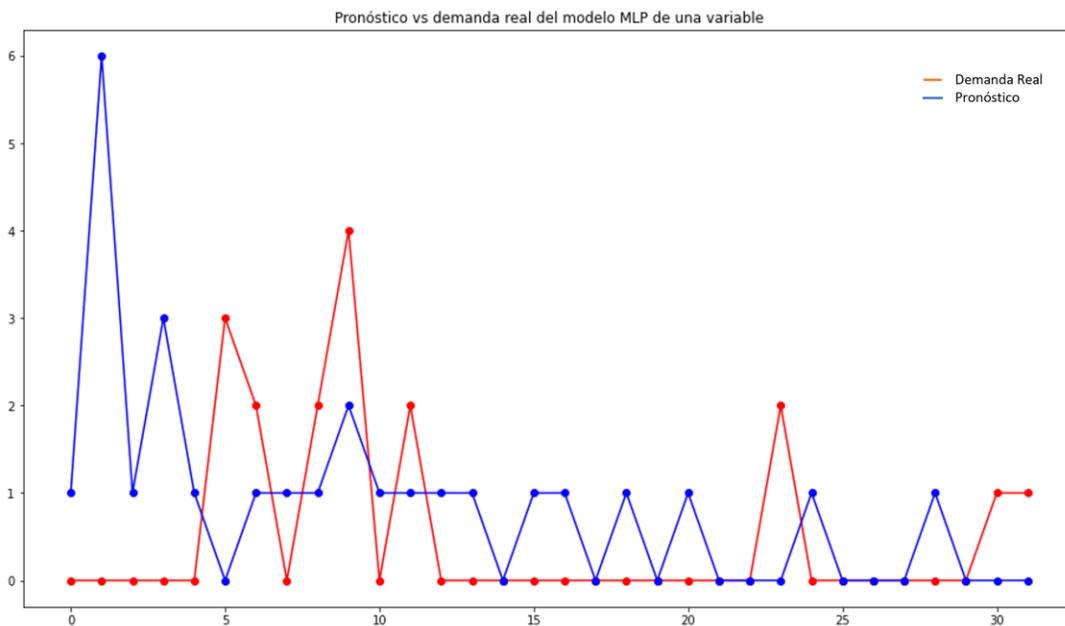


Ilustración 45. Pronóstico vs demanda real del modelo MLP de una variable en Jupyter

## Uso del pronóstico de la demanda para proponer un plan de ventas y operaciones en empresas de servicios.

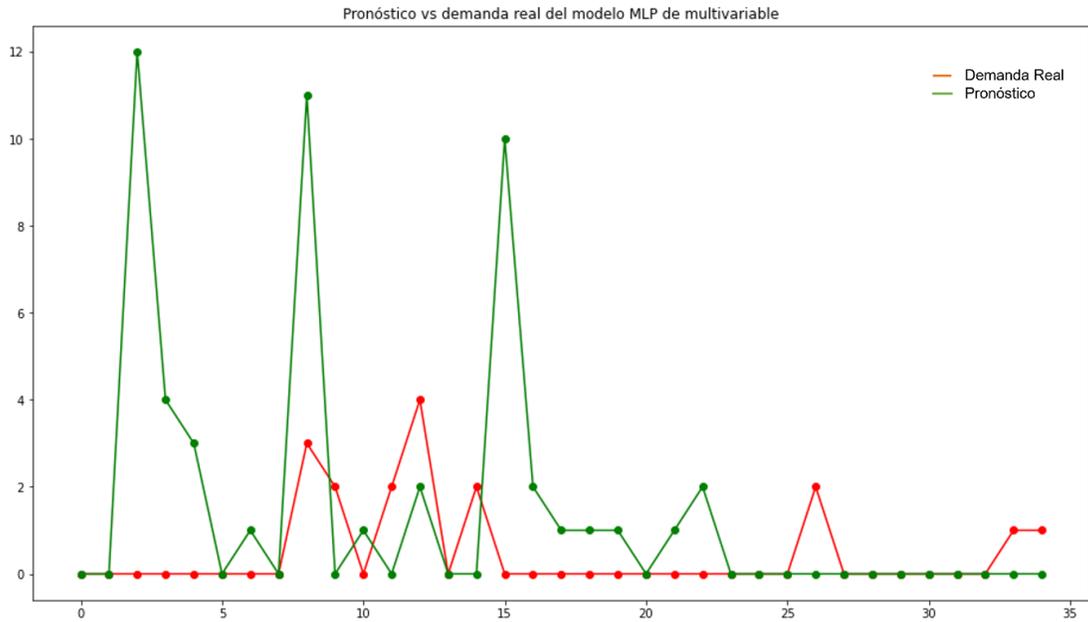


Ilustración 46. Pronóstico vs demanda real del modelo MLP multivariable en Jupyter

A modo de comparación se observa que, en el modelo de una variable, el pronóstico muestra un comportamiento donde al inicio predice uno de los picos, aunque en periodos adelantados al real y conforme van pasando los periodos los valores previstos se mueven por debajo de los valores de la demanda real predice los valores nulos. El modelo multivariable también predice valores nulos sobre todo en los periodos finales, pero predice picos que sobrepasan los de la demanda real. Por lo cual es necesario utilizar métricas de desempeño para evaluar la precisión de los modelos de pronóstico y así poder compararlos e identificar cuál es el más eficiente.

Se utilizaron SPEC, MSE y MAD (ver

Anexo 5).

Tabla 7. Métricas de desempeño de los modelos MLP.

Modelo	SPEC (%)	MSE (%)	MAD (%)
MLP de una variable	7.45	2.5	0.80
MLP multivariable	33.55	10.54	0.75

Para el cálculo de las métricas se utilizaron las librerías `spec_metric` y la función `spec` (Martin, Spitzer, & Kühn, 2020), `sklearn.metrics` y la función `mean_squared_error` y `pandas` y la función `mad`.

El uso de las métricas requiere de dos parámetros para comparar: la demanda real y la predicción. Además de estos, SPEC requiere de otros dos parámetros adicionales:

- a1: parámetro de ponderación de los costes de oportunidad.
- a2: parámetro de ponderación de los costes de mantenimiento de las existencias.

Haciendo una analogía de *Softing* con el caso de empresas manufacturas en la situación donde la empresa no cuenta con las unidades suficientes que son demandadas, los costes de oportunidad en este caso son representados por las ventas que no pueden ser concretadas por recursos no disponibles o escasos que no permiten que se completen las operaciones de manera eficiente para vender unidades demandadas, tales como la falta de capacidad de servidores, fallas en la página web para realizar compras, tardanza en lanzar a la venta nuevas actualizaciones, marketing ineficiente e insatisfacción de clientes tras la prueba demo del software ya sea debido al mismo software o al personal que realiza la prueba y no muestra la capacidad de explicar la funcionalidad y las ventajas que ofrece el software.

Los costos de mantenimiento de existencias, continuando con la analogía, se refieren a los costos que incurre la empresa por mantener una capacidad mayor a la que está siendo requerida, como la capacidad de servidores, desarrollo de nuevas actualizaciones que a su vez implica recursos tecnológicos y capacitaciones al personal.

Por tanto, los valores de los parámetros seleccionados son  $a1 = 0.9$  y  $a2 = 0.1$  los cuales fueron seleccionados para darle un mayor peso a los costos de oportunidad.

La métrica SPEC resultó ser mucho más baja en el modelo de una variable, al igual que MSE. Por otra parte, los resultados de la métrica MAD son cercanos e indica que el promedio de los errores de ambos modelos es similar siendo el modelo multivariable el que obtuvo un mejor rendimiento.

## 5. Hacer predicciones

## Uso del pronóstico de la demanda para proponer un plan de ventas y operaciones en empresas de servicios.

Una vez que se tiene la red neuronal y se evalúa su rendimiento con el set de test que pertenece a los datos históricos se procede realizar una nueva predicción para periodos futuros.

El horizonte de predicción es de 6 periodos (3 meses) para visualizar el comportamiento de la demanda a mediano plazo para realizar la planeación de ventas, de procesos y de servicios.

Para realizar la predicción se utiliza la función *predict* utilizando una serie de nuevos patrones de entrada que para ambos modelos serán los últimos 89 periodos, es decir, toma los datos de ventas desde el inicio del año 2018.

```
#últimos periodos de ventas
lastP = df['2018-01':'2021-09']
lastP
```

fecha	unidades
2018-01-15	4
2018-01-31	0
2018-02-15	6
2018-02-28	0
2018-03-15	0
...	...
2021-07-15	0
2021-07-31	0
2021-08-15	0
2021-08-31	1
2021-09-15	1

89 rows × 1 columns

```
#Ultimos periodos de ventas
lastP = df['2018-09':'2021-09']
lastP
```

fecha	unidades	actualizaciones
2018-09-15	4	0
2018-09-30	4	0
2018-10-15	0	0
2018-10-31	16	0
2018-11-15	4	2
...	...	...
2021-07-15	0	0
2021-07-31	0	0
2021-08-15	0	0
2021-08-31	1	0
2021-09-15	1	0

73 rows × 3 columns

Ilustración 47. Datos de entrada para el pronóstico de periodos futuros en Jupyter

Se realiza el mismo proceso que se realiza al crear la red, utilizando la función *series\_to\_supervised* y escalando los datos con la diferencia de que no hay una columna de salida porque ahora representa la columna con los nuevos valores del pronóstico de los periodos futuros.

## Uso del pronóstico de la demanda para proponer un plan de ventas y operaciones en empresas de servicios.

	var1(t-40)	var1(t-39)	var1(t-38)	var1(t-37)	var1(t-36)	var1(t-35)	var1(t-34)	var1(t-32)	var1(t-31)	var1(t-30)	...	var1(t-9)	var1(t-8)	var1(t-7)	var1(t-6)
40	-0.783784	-1.000000	-0.675676	-1.000000	-1.000000	-1.000000	-0.837838	-1.000000	-1.000000	-1.000000	...	-0.891892	-1.000000	-0.567568	-0.783784
41	-1.000000	-0.675676	-1.000000	-1.000000	-1.000000	-0.837838	-1.000000	-1.000000	-1.000000	-1.000000	...	-1.000000	-0.567568	-0.783784	-0.891892
42	-0.675676	-1.000000	-1.000000	-1.000000	-0.837838	-1.000000	-1.000000	-1.000000	-1.000000	-1.000000	...	-0.567568	-0.783784	-0.891892	-0.891892
43	-1.000000	-1.000000	-1.000000	-0.837838	-1.000000	-1.000000	-1.000000	-1.000000	-1.000000	-0.837838	...	-0.783784	-0.891892	-0.891892	-1.000000
44	-1.000000	-1.000000	-0.837838	-1.000000	-1.000000	-1.000000	-1.000000	-1.000000	-0.837838	-1.000000	...	-0.891892	-0.891892	-1.000000	-0.783784
45	-1.000000	-0.837838	-1.000000	-1.000000	-1.000000	-1.000000	-1.000000	-0.837838	-1.000000	-1.000000	...	-0.891892	-1.000000	-0.783784	-0.405405
46	-0.837838	-1.000000	-1.000000	-1.000000	-1.000000	-1.000000	-1.000000	-1.000000	-1.000000	-0.783784	...	-1.000000	-0.783784	-0.405405	-0.891892

7 rows × 40 columns

Ilustración 48. Datos de entrada para el pronóstico con una variable en Jupyter

	var1(t-50)	var2(t-50)	var1(t-49)	var2(t-49)	var1(t-48)	var2(t-48)	var1(t-47)	var2(t-47)	var1(t-46)	var2(t-46)	...	var1(t-5)	var2(t-5)	var1(t-4)
fecha														
2020-10-15	0.0	-0.783784	0.0	-0.783784	0.0	-1.000000	0.0	-0.135135	2.0	-0.783784	...	0.0	-1.000000	2.0
2020-10-31	0.0	-0.783784	0.0	-1.000000	0.0	-0.135135	2.0	-0.783784	0.0	-0.621622	...	2.0	-0.837838	2.0
2020-11-15	0.0	-1.000000	0.0	-0.135135	2.0	-0.783784	0.0	-0.621622	0.0	-1.000000	...	2.0	-0.891892	0.0
2020-11-30	0.0	-0.135135	2.0	-0.783784	0.0	-0.621622	0.0	-1.000000	0.0	-0.783784	...	0.0	-1.000000	0.0
2020-12-15	2.0	-0.783784	0.0	-0.621622	0.0	-1.000000	0.0	-0.783784	0.0	-0.783784	...	0.0	-0.891892	0.0
2020-12-31	0.0	-0.621622	0.0	-1.000000	0.0	-0.783784	0.0	-0.783784	1.0	-0.621622	...	0.0	-0.783784	0.0
2021-01-15	0.0	-1.000000	0.0	-0.783784	0.0	-0.783784	1.0	-0.621622	2.0	-0.891892	...	0.0	-1.000000	0.0

7 rows × 100 columns

Ilustración 49. Datos de entrada para el pronóstico con dos variables en Jupyter

También se crea una función para que en la predicción del periodo  $n$  tome la predicción ya realizada en el periodo  $n-1$ . Bagnato (2019) llama esta función *agregarNuevoValor* y consiste en ir “rellenando” el desplazamiento que se produce tras cada predicción. Después de esta función y de la re- transformación de los valores escalados entre -1 y 1 a la escala real de los datos, se obtiene el pronóstico (ver Anexo 6).

En las siguientes imágenes se visualiza la predicción para las ventas del AXML de las próximas seis quincenas, o tres meses, de los dos modelos diferentes.

## Uso del pronóstico de la demanda para proponer un plan de ventas y operaciones en empresas de servicios.

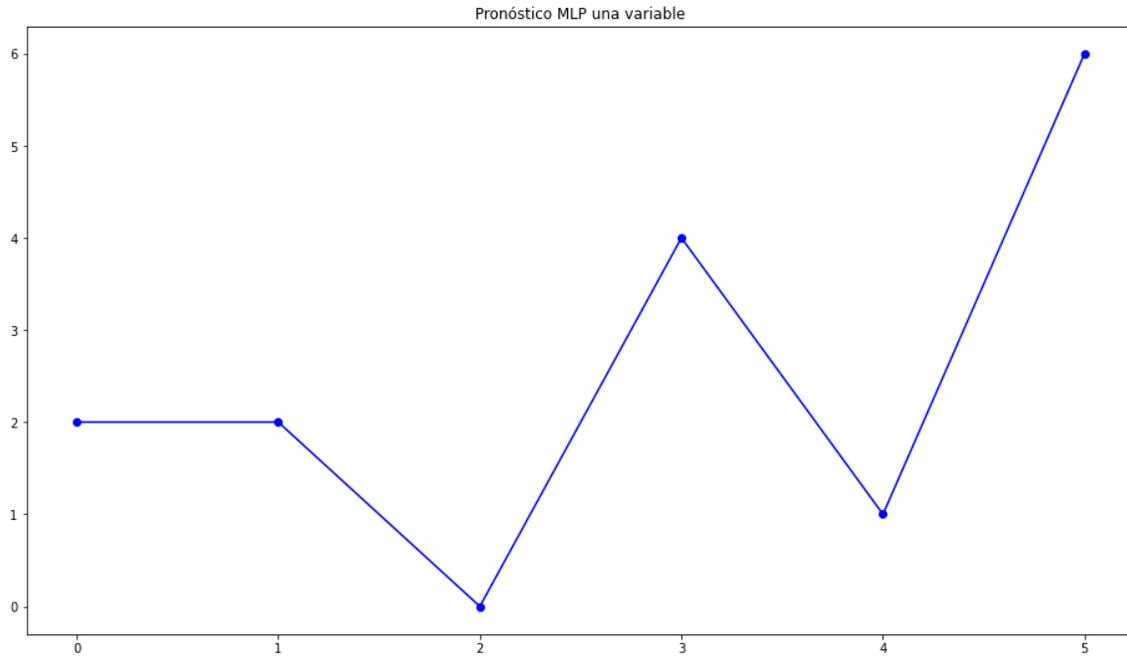


Ilustración 50. Pronóstico de periodos futuros con el modelo MLP de una variable en Jupyter

prediccion		prediccion	
Pronóstico modelo de una variable		Pronóstico modelo de una variable	
0	2.0	0	2.095713
1	2.0	1	1.875714
2	0.0	2	0.417038
3	4.0	3	3.791010
4	1.0	4	0.809747
5	6.0	5	5.521596

Ilustración 51. Valores del pronóstico de periodos futuros con el modelo MLP de una variable en Jupyter

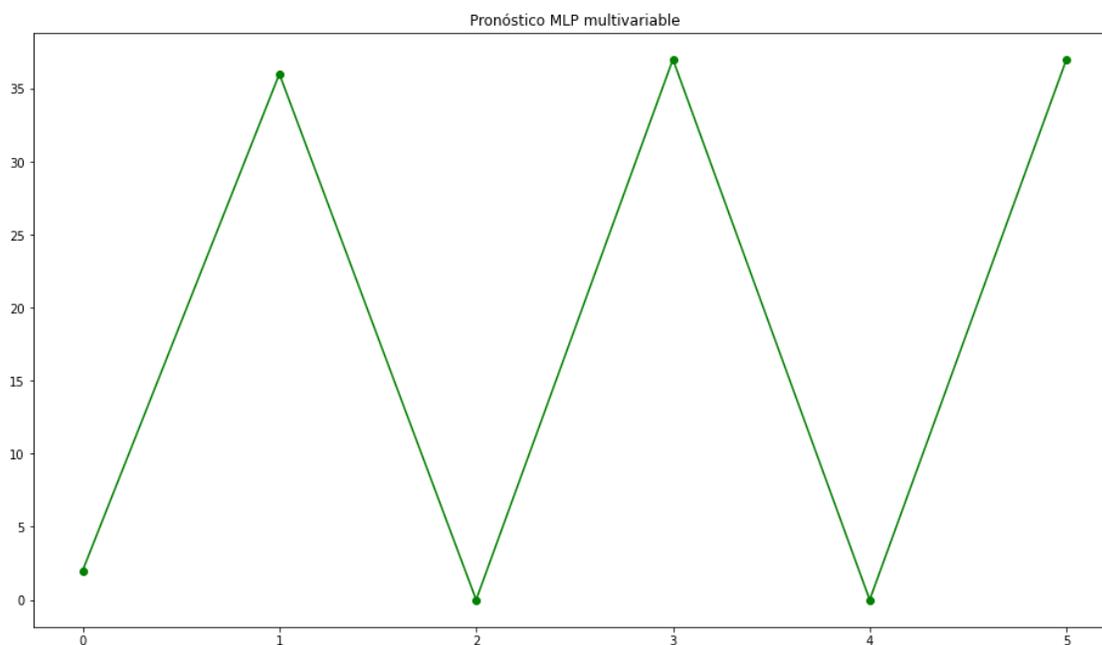


Ilustración 52. Pronóstico de periodos futuros con el modelo MLP multivariable en Jupyter

<code>prediccion.round()</code>		<code>prediccion</code>	
Pronostico modelo multivariable		Pronostico modelo multivariable	
0	2.0	0	1.633170
1	36.0	1	35.587839
2	0.0	2	0.216790
3	37.0	3	36.654625
4	0.0	4	0.451243
5	37.0	5	36.550552

Ilustración 53. Valores del pronóstico de periodos futuros con el modelo MLP multi variable en Jupyter

Como se menciona en la sección 5.5.1, se desarrolla de igual forma un modelo estadístico como comparación frente a un modelo de ML y se selecciona el modelo de Croston modificado por Syntetos y Boylan ya que, como se revisa en la sección 3.3.1 según la literatura, es el que presenta un mejor desempeño cuando la demanda es de tipo Lumpy.

*Modelo estadístico: Syntetos y Boylan*

Para el desarrollo del modelo estadístico de Syntetos y Boylan se utiliza Excel para realizar los cálculos del algoritmo de Croston (Ilustración 19), con la diferencia de que para el cálculo del pronóstico del periodo futuro se utiliza la corrección de Syntetos y Boylan.

Siguiendo el ejemplo de aplicación de (Vidal Holguín, 2010), se toma la serie de tiempo de ventas y se agregan dos columnas, una en la que se registran el número de periodos con demanda consecutiva y otra que corresponde a el número de periodos consecutivos con demanda mayor a cero.

Periodo (quincena)	Demanda	# periodos con demanda nula	# periodos demanda mayor a 0
1	20	1	
2	0	2	0
3	0	3	0
4	0	4	0
5	1	1	4
6	0	2	0
7	0	3	0
8	0	4	0
9	0	5	0
10	2	1	5
11	0	2	0
12	2	1	2
13	0	2	0
14	0	3	0
15	4	1	3
16	1	1	1

Ilustración 54. Formato de datos para el modelo de Syntetos y Boylan

Esta última columna se utiliza para obtener el primer valor de la previsión del intervalo de demanda ( $\hat{F}_t$ ) calculando el promedio de dicha columna y la columna de demanda que son los datos históricos se utiliza para calcular la previsión de la demanda no nula para el periodo presente ( $\hat{D}_t$ ).

Para estos cálculos se toman los primeros 84 periodos para comenzar a pronosticar a partir del periodo 85 y así, poder comparar el pronóstico de los periodos restantes con la demanda real y obtener el cálculo del error del modelo como se muestra en la Ilustración 55. El total de periodos a pronosticar es 81. Se toma como base el ejemplo de (Vidal Holguín, 2010) donde calcula el pronóstico utilizando el algoritmo de Croston.

Uso del pronóstico de la demanda para proponer un plan de ventas y operaciones en empresas de servicios.

Periodo (quincena)	Demanda	# periodos con demanda nula	# periodos demanda mayor a 0	$\hat{F}_t$	$\hat{D}_t$	k	Pronóstico	Error	Error abs	Error al cuadrado
83	3	1	4	3.57	4.63					
84	0	2	0	3.57	4.63					
85	0			3.57	4.63	1.00	1.01	-1.01	1.01	1.02
86	0			3.57	4.63	2.00	1.01	-1.01	1.01	1.02
87	0			3.57	4.63	3.00	1.01	-1.01	1.01	1.02
88	0			3.57	4.63	4.00	1.01	-1.01	1.01	1.02
89	0			3.57	4.63	5.00	1.01	-1.01	1.01	1.02
90	3			2.44	3.91	1.00	1.01	1.99	1.99	3.95
91	0			2.44	3.91	2.00	1.25	-1.25	1.25	1.57
92	0			2.44	3.91	3.00	1.25	-1.25	1.25	1.57
93	4			1.80	3.95	1.00	1.25	2.75	2.75	7.55
94	4			1.45	3.97	1.00	1.71	2.29	2.29	5.26
95	0			1.45	3.97	2.00	2.14	-2.14	2.14	4.56
96	16			1.25	9.26	1.00	2.14	13.86	13.86	192.22
97	4			1.14	6.95	1.00	5.77	-1.77	1.77	3.13
98	7			1.08	6.97	1.00	4.75	2.25	2.25	5.07
99	0			1.08	6.97	2.00	5.04	-5.04	5.04	25.39
100	4			1.04	5.66	1.00	5.04	-1.04	1.04	1.08
101	4			1.02	4.93	1.00	4.23	-0.23	0.23	0.05
102	7			1.01	5.84	1.00	3.75	3.25	3.25	10.54
103	2			1.01	4.15	1.00	4.49	-2.49	2.49	6.22
104	37			1.00	18.60	1.00	3.21	33.79	33.79	1141.56
105	5			1.00	12.62	1.00	14.45	-9.45	9.45	89.28
106	11			1.00	11.91	1.00	9.82	1.18	1.18	1.40
107	2			1.00	7.55	1.00	9.27	-7.27	7.27	52.92
108	2			1.00	5.11	1.00	5.88	-3.88	3.88	15.07
109	0			1.00	5.11	2.00	3.98	-3.98	3.98	15.85

Alpha	0.44
MAD	3.19
MSE	26.79
Pronóstico del periodo siguiente	1.12

Ilustración 55. Vista previa de la aplicación del algoritmo de Croston en Excel

El valor del parámetro  $\alpha$  fue seleccionado al utilizar la herramienta *Solver* con el propósito de obtener su valor óptimo con el cual se reduce el valor de MSE.

Las métricas de error de pronóstico utilizadas son MAD, MSE y SPEC. Los indicadores estadísticos fueron calculados en Excel y en Python, utilizando las mismas librerías que los modelos MLP, al igual que SPEC (ver Anexo 7).

Los resultados se muestran en la siguiente tabla:

Tabla 8. Errores de pronóstico del modelo estadístico SyB

Errores de pronóstico (SyB)		
SPEC (%)	MSE (%)	MAD (%)
36.29	26.79	3.12

Fuente: Elaboración propia

En la siguiente imagen se observa el comportamiento del pronóstico a lo largo de 80 periodos. Hay periodos en los que el pronóstico intenta alcanzar los picos de demanda, pero no alcanza ni sobre pasa alguno, también se podría decir que al inicio del horizonte se mueve alrededor de la media y en los últimos periodos se mantiene estable.

Por otro lado, el modelo no pronosticó demanda nula. Una explicación de ello es que, de acuerdo con el algoritmo de Croston (Ilustración 19), cuando la demanda en el periodo  $t$  no es positiva se toma  $\hat{D}_t = \hat{D}_{t-1}$ . Entonces siguiendo la ecuación  $m_{t+1} = \left(1 - \frac{\alpha}{2}\right) \frac{\hat{D}_t}{\hat{F}_t}$ , en los cálculos para la

demanda del periodo siguiente el valor será positivo en este caso donde no se presentan valores de  $\hat{D}_t$  iguales a 0.

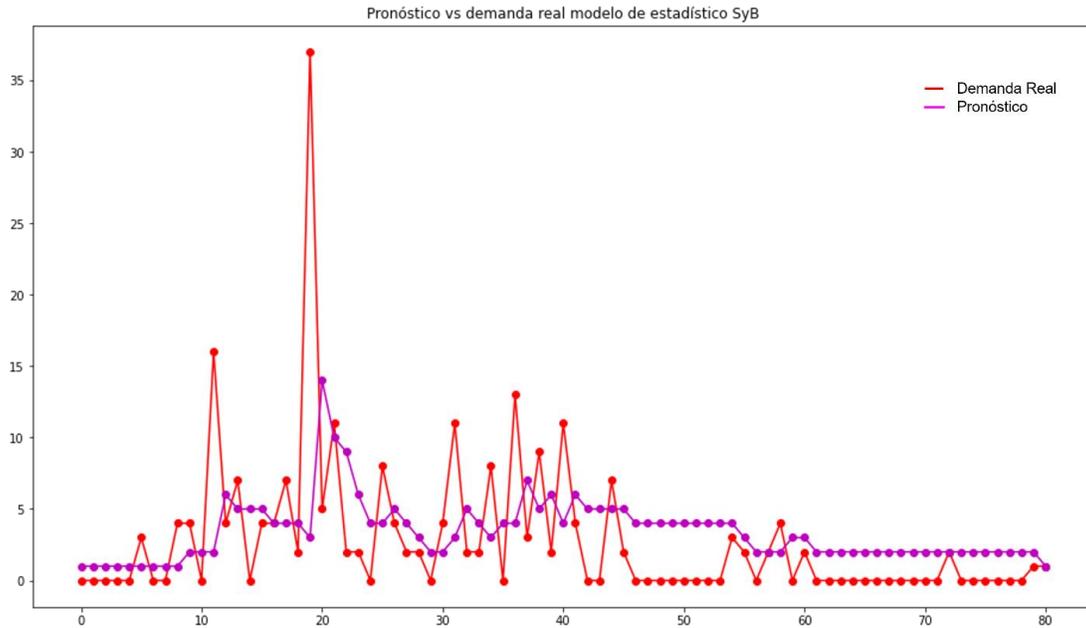


Ilustración 56. Pronóstico de la demanda vs demanda real usando el modelo SyB en Jupyter

La serie del pronóstico de periodos futuros se comporta constante al igual que el pronóstico de prueba en los últimos periodos, dando como resultado 1 unidad.

### 5.7 Análisis de resultados

Comenzando con el análisis de los resultados de los tres modelos de pronóstico se visualiza su comportamiento comparado con el de la demanda real.

## Uso del pronóstico de la demanda para proponer un plan de ventas y operaciones en empresas de servicios.

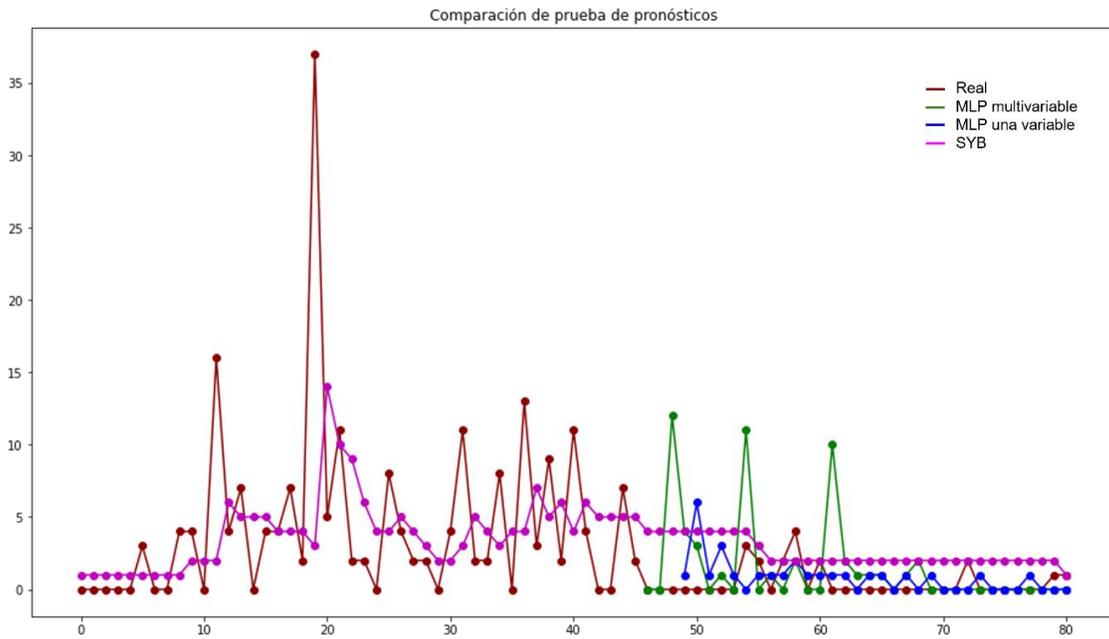


Ilustración 57. Comparación de los modelos de pronóstico vs la demanda real en Jupyter

El gráfico consta de los últimos 81 periodos de las ventas históricas siendo el modelo de pronóstico SyB el que toma estos periodos de prueba, el MLP multivariable toma 35 y el de una variable 32 periodos que son los que corresponden con los sets de test.

En general se observa que el pronóstico del método de SyB durante la primera mitad de los periodos se mueve dentro de la media de los valores reales sin alcanzar los picos de demanda real, aunque en la segunda mitad del pronóstico sí hay periodos en los que sobrepasa los datos reales y sin prever valores nulos.

Para tener una mejor visualización de la segunda mitad de los datos se tiene la Ilustración 58 en donde comienza el pronóstico de los modelos MLP.

El modelo MLP multivariable trata de imitar los picos de la demanda real de los periodos anteriores (del periodo 30 al 40) y repite este comportamiento por los 10 periodos siguientes a su inicio siendo el modelo que presenta los valores de demanda más altos en su pronóstico. Del periodo 66 en adelante muestra un suavizamiento sin mostrar picos tan altos y su comportamiento es más parecido al de la demanda real mostrando ceros, pero teniendo errores en calcular las pocas ventas de los últimos periodos.

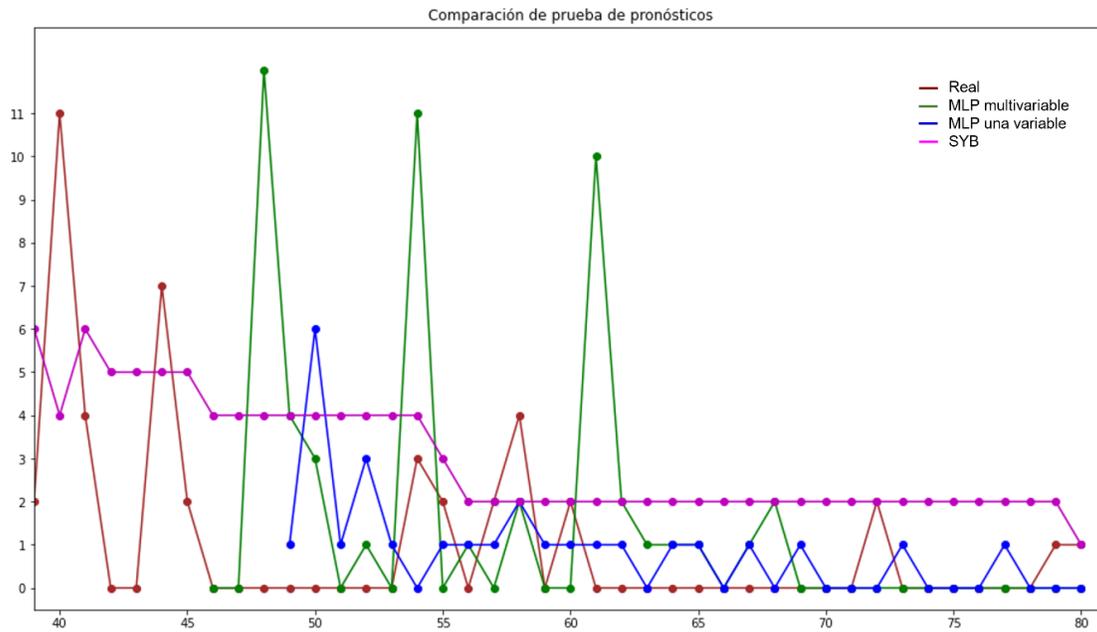


Ilustración 58. Comparación de modelos de pronóstico segunda mitad en Jupyter

El modelo MLP de una variable también inicia su pronóstico intentando replicar las altas demandas de periodos anteriores, pero conforme avanzan los periodos, la previsión va disminuyendo y su comportamiento a partir del periodo 60 se muestra intercalado entre valores nulos y unos.

En general, los tres modelos muestran comportamientos diferentes siendo el MLP multivariable el que prevé valores más altos alcanzando los picos de demanda reales en periodos diferentes, el modelo de una variable muestra un pronóstico que conforme aumentan los periodos calcula valores sin sobrepasar los picos presentes y sin coincidir en varios periodos con los valores nulos.

El modelo estadístico SyB prevé valores cercanos a la media de la demanda real en la primera mitad de los periodos y tras el periodo 43, presenta una caída de ventas y por el resto de los periodos se mueve por debajo de 10 unidades sin presentar picos significantes y a partir del periodo 56 permanece constante. Se observa que este modelo no llega a los valores más bajos de la demanda real en esta prueba y una de sus desventajas que no prevé la demanda que es igual a cero.

La comparación de los indicadores de error de pronóstico se muestra en la

**Tabla 9.**

Tabla 9. Comparación de error de pronóstico de los tres modelos

<b>Modelo</b>	<b>SPEC (%)</b>	<b>MSE (%)</b>	<b>MAD (%)</b>
<b>MLP de una variable</b>	7.49	2.49	0.80
<b>MLP multivariable</b>	33.55	10.54	0.75
<b>SyB</b>	36.29	26.79	3.12

Fuente: Elaboración propia

El modelo que mejor rendimiento obtuvo tanto en las métricas SPEC y MSE y que además quedó muy cerca del modelo que obtuvo menor MAD, es el modelo MLP de una variable.

Para una explicación con mayor detalle, se clasifica el análisis de resultados de acuerdo con las tres métricas.

#### 5.7.1 Análisis de resultados de acuerdo con la métrica MAD

Las métricas estadísticas informan la diferencia promedio del pronóstico y la demanda real, siendo MAD la que indica dicho promedio tomando valores positivos. Lo que quiere decir que el pronóstico obtenido con el modelo MLP multivariable obtuvo resultados que en promedio varían 0.75 unidades, con el modelo MLP de una variable los resultados varían 0.8 unidades y con SyB varían 3.12 unidades siendo este último el que obtuvo mayor variación.

#### 5.7.2 Análisis de resultados de acuerdo con la métrica MSE

La métrica MSE mide el error cuadrado promedio de las predicciones y, aunque el modelo MLP multivariable mostró una menor variación de acuerdo con MAD, obtuvo un MSE más alto dado que esta métrica castiga los errores más altos y esto se debe a los picos erróneos que obtuvo en el pronóstico.

En cuanto al modelo MLP de una variable, obtuvo un MSE más bajo dado que los valores previstos no resultaron tan altos con los reales a pesar de que tuvo una mayor variación que el modelo multivariable.

Por otra parte, el modelo SyB obtuvo MSE más altas dado que el promedio de las variaciones es aún mayor que en los otros dos modelos y se destaca que el no pronosticar valores nulos tuvo un peso importante en ello.

#### 5.7.3 Análisis de resultados de acuerdo con la métrica SPEC

En cuanto a la métrica SPEC el modelo MLP de una variable obtuvo el mejor rendimiento, seguido por MLP multivariable y SyB al final. SPEC castiga el error de pronóstico utilizando dos parámetros:

el costo de oportunidad y el costo de mantenimiento. Por ello, este análisis se divide en estas dos subsecciones.

*Análisis de penalización de SPEC por costos de mantenimiento:*

El modelo MLP multivariable obtiene un mayor valor en SPEC pues es el que pronóstica los valores más altos, es decir, SPEC castiga al modelo debido a que pronostica 3 picos de los cuales las diferencias con la demanda real son 12, 8 y 10 unidades lo que significa que el error pronostica costes de mantenimiento para esas unidades extra.

Lo sucedido con el modelo SyB es un caso parecido al anterior. La diferencia más grande de pronóstico que calcula es de 34, 14 y 8 unidades, entonces SPEC penaliza al modelo por el costo de mantenimiento de dichas unidades.

El modelo menos penalizado es el MLP de una variable donde el valor máximo pronosticado es de 6 unidades.

*Análisis de penalización de SPEC por costos de oportunidad:*

Lo mismo sucede con los valores que los modelos prevén por debajo de los valores reales: SPEC penaliza esas diferencias porque representa los costos de oportunidad y es el parámetro al que se eligió dar un mayor peso pues para el caso de estudio representaría un costo mayor al costo de mantenimiento.

Los modelos MLP presentan un mejor rendimiento en cuanto a la predicción de valores de por debajo de la demanda real. El modelo de una variable obtuvo como valores máximos 3, 2 y 1 unidades de diferencia por debajo de la demanda real que representan las ventas que pudieron hacerse pero que no se lograron por la falta de estos productos. El modelo multivariable obtuvo como máximo el pronóstico de 2 unidades.

El modelo SyB obtuvo valores de diferencia más elevados: 9, 7, 4, 3, 2 y 1 unidades.

Debido a que el horizonte de pronóstico para el modelo SyB es mayor a los otros dos modelos, las métricas se ven afectadas por lo cual se toman 124 periodos de la serie de tiempo para realizar la prueba del modelo SyB a 40 periodos para comparar su comportamiento frente al modelo anterior donde se pronosticaron 81 periodos como prueba.

Uso del pronóstico de la demanda para proponer un plan de ventas y operaciones en empresas de servicios.

Periodo (quincena)	Demanda	# periodos con demanda nula	# periodos demanda mayor a 0	$\hat{F}_t$	$\hat{D}_t$	k	Pronóstico	Error	Error abs	Error al cuadrado
123	9	1	1	2.44	5.71					
124	2			1.81	8.04	1.00	1.82	9.18	9.18	84.20
125	11			1.45	6.26	1.00	3.47	0.53	0.53	0.28
126	4			1.45	6.26	2.00	3.36	-3.36	3.36	11.31
127	0			1.45	6.26	3.00	3.36	-3.36	3.36	11.31
128	0			1.25	6.59	1.00	3.36	3.64	3.64	13.22
129	7			1.14	4.57	1.00	4.10	-2.10	2.10	4.41
130	2			1.14	4.57	2.00	3.12	-3.12	3.12	9.74
131	0			1.14	4.57	3.00	3.12	-3.12	3.12	9.74
132	0			1.14	4.57	4.00	3.12	-3.12	3.12	9.74
133	0			1.14	4.57	5.00	3.12	-3.12	3.12	9.74
134	0			1.14	4.57	6.00	3.12	-3.12	3.12	9.74
135	0			1.14	4.57	7.00	3.12	-3.12	3.12	9.74
136	0			1.14	4.57	8.00	3.12	-3.12	3.12	9.74
137	0			1.14	4.57	9.00	3.12	-3.12	3.12	9.74
138	0			1.08	3.88	1.00	3.12	-0.12	0.12	0.01
139	3			1.04	3.05	1.00	2.80	-0.80	0.80	0.64
140	2			1.04	3.05	2.00	2.28	-2.28	2.28	5.19
141	0			1.02	2.59	1.00	2.28	-0.28	0.28	0.08
142	2			1.01	3.21	1.00	1.97	2.03	2.03	4.12
143	4			1.01	3.21	2.00	2.47	-2.47	2.47	6.10
144	0			1.01	2.68	1.00	2.47	-0.47	0.47	0.22
145	2			1.01	2.68	2.00	2.07	-2.07	2.07	4.29
146	0			1.01	2.68	3.00	2.07	-2.07	2.07	4.29
147	0			1.01	2.68	4.00	2.07	-2.07	2.07	4.29
148	0			1.01	2.68	5.00	2.07	-2.07	2.07	4.29
149	0			1.01	2.68	6.00	2.07	-2.07	2.07	4.29
150	0			1.01	2.68	7.00	2.07	-2.07	2.07	4.29
151	0			1.01	2.68	8.00	2.07	-2.07	2.07	4.29
152	0			1.01	2.68	9.00	2.07	-2.07	2.07	4.29
153	0			1.01	2.68	10.00	2.07	-2.07	2.07	4.29
154	0			1.01	2.68	11.00	2.07	-2.07	2.07	4.29
155	0			1.01	2.68	12.00	2.07	-2.07	2.07	4.29
156	0			1.00	2.38	1.00	2.07	-0.07	0.07	0.01
157	2			1.00	2.38	2.00	1.85	-1.85	1.85	3.41
158	0			1.00	2.38	3.00	1.85	-1.85	1.85	3.41
159	0			1.00	2.38	4.00	1.85	-1.85	1.85	3.41
160	0			1.00	2.38	5.00	1.85	-1.85	1.85	3.41
161	0			1.00	2.38	6.00	1.85	-1.85	1.85	3.41
162	0			1.00	2.38	7.00	1.85	-1.85	1.85	3.41
163	0			1.00	1.77	1.00	1.85	-0.85	0.85	0.72
164	1			1.00	1.43	1.00	1.38	-0.38	0.38	0.14
165	1						1.12			

Alpha	0.44
MAD	2.21
MSE	7.02
Pronóstico del periodo siguiente	1.12

Ilustración 59. Modelo SyB con 40 periodos de prueba.

Al realizar 40 periodos de prueba con el modelo de SyB las métricas de error redujeron siendo MAD = 2.21, MSE = 7.02 y SPEC = 26.11 (ver Anexo 7). El valor de pronóstico resultó ser igual que el modelo anterior con 81 periodos y su comportamiento también fue parecido durante los últimos periodos.

## Uso del pronóstico de la demanda para proponer un plan de ventas y operaciones en empresas de servicios.

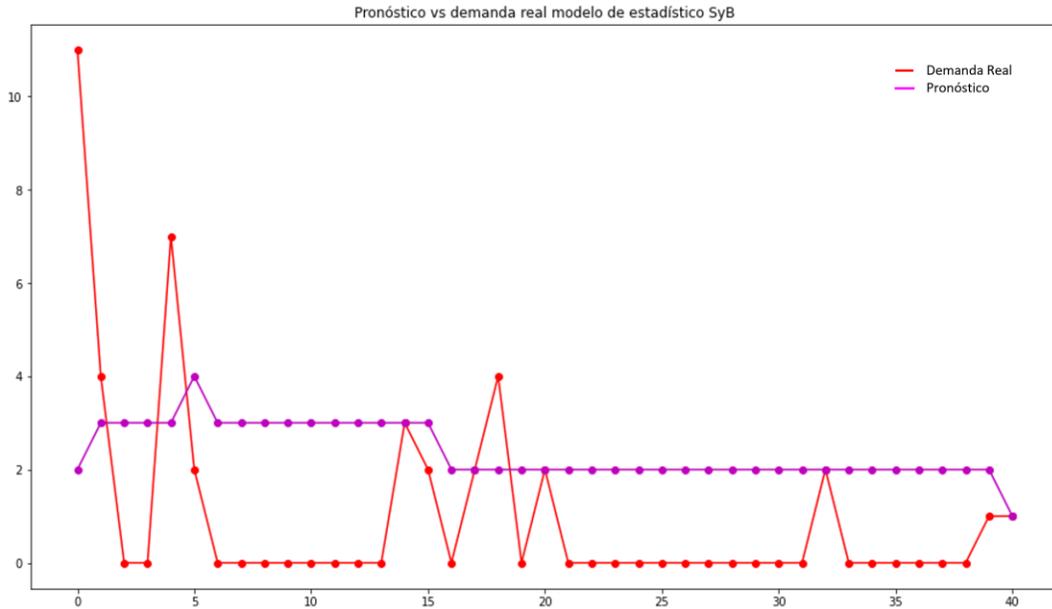


Ilustración 60. Pronóstico de la demanda vs pronóstico real utilizando SyB durante 40 periodos

Ahora revisando el pronóstico futuro se observa que el modelo MLP multivariable pronóstica altos picos de demanda al igual que en el conjunto de prueba donde los primeros periodos de pronóstico intentaban repetir los picos anteriores. Sin embargo, los últimos 20 periodos no presentaron ventas tan altas, sino que variaron entre 0 y 2 unidades.

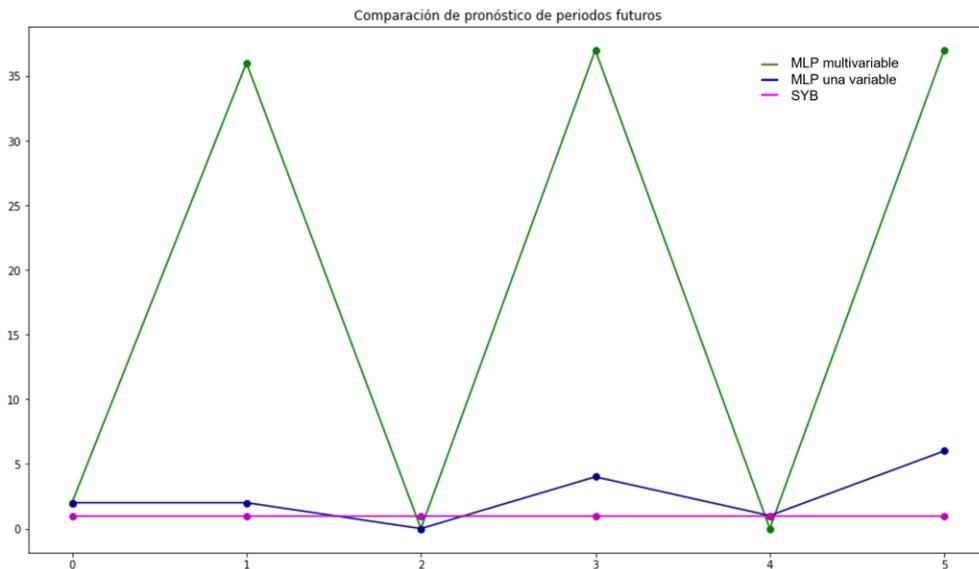


Ilustración 61. Comparación de los pronósticos de periodos futuros de los tres modelos.

El comportamiento del pronóstico de la demanda del modelo MLP de una variable es parecido al comportamiento que mostró durante los últimos periodos de prueba, variando entre 0 y 2 unidades

y posteriormente pronostica más valores de demanda llegando a 6 unidades en el sexto periodo futuro.

El pronóstico del modelo estadístico SyB toma el valor del último periodo del pronóstico de prueba que es de una unidad y se mantiene constante por los seis periodos futuros.

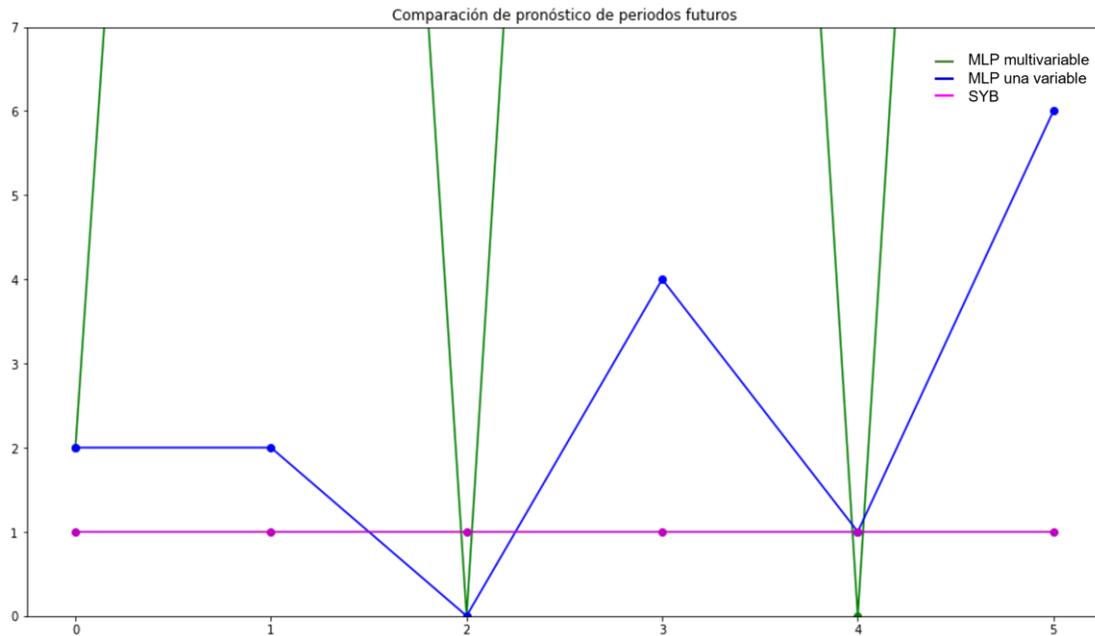


Ilustración 62. Comparación de los pronósticos de periodos futuros de los tres modelos.

Esta comparación del modelo SyB de 81 periodos contra 40 periodos a pronosticar refleja que no hay una variación considerable en los resultados, es decir, en este caso el horizonte de pronóstico y el número de entradas del modelo no influyen en el resultado. Esto se debe a que, con esta serie de datos, el algoritmo calcula valores constantes y no muestra grandes variaciones a no ser que los valores de los parámetros que utiliza cambien en gran medida lo cual no ocurre, pero sí van aumentando de manera constante puesto que los valores de estos parámetros se van acumulando o toman el valor anterior si se incrementa el intervalo de periodo donde hubo demanda.

Como resultado final tras el análisis del rendimiento del pronóstico de prueba de los tres modelos al compararlo con la demanda real y el pronóstico futuro, se selecciona el modelo MLP de una variable para tomar el pronóstico como base para la planeación de ventas y operaciones.

Esto debido a que en el pronóstico de prueba obtuvo el mejor rendimiento según SPEC y MSE, tal como se analizó previamente. Y en el pronóstico futuro muestra valores más cercanos a los últimos periodos, calcula un periodo nulo y no se comporta constante entre un rango de valores pues presenta aumentos en el pronóstico y se muestra variable comparado con los dos modelos restantes donde el MLP multivariable presenta picos muy altos y los valores no crecen ni presentan movimiento dentro del rango de pronóstico de 0 a 37 unidades y el SyB se mantiene constante a lo largo de los periodos.

Así, el pronóstico de demanda para los periodos siguientes es:

Tabla 10. Pronóstico para los periodos futuros

<b>Periodo</b>	<b>Pronóstico</b>
<b>1</b>	<b>2</b>
<b>2</b>	<b>2</b>
<b>3</b>	<b>0</b>
<b>4</b>	<b>4</b>
<b>5</b>	<b>1</b>
<b>6</b>	<b>6</b>

**Fuente:** Elaboración propia

### 5.8 Propuesta del plan de ventas y operaciones S&OP

La predicción de la demanda es una de las variables de entrada para el proceso S&OP, por lo que su cálculo fue el primer paso para el desarrollo del plan.

El propósito del proceso S&OP es desarrollar y acordar un plan operativo para lograr los objetivos de la empresa, principalmente posicionarse en el mercado con el AXML e incrementar sus ventas, además de garantizar que las áreas de la empresa estén alineadas en cuando a las metas, decisiones y procesos a seguir.

El plan de ventas y operaciones es un entregable que debe ser aprobado y liderado por la alta dirección. Para llevarlo a cabo se recomienda que se nombre a un líder de proceso, se elabore un calendario de reuniones periódicas entre ventas, operaciones, finanzas y la dirección y crear actas normalizadas de reunión.

Tomando como referencia la Ilustración 7, se propone que en la empresa se realice el siguiente proceso de S&OP el cual es modificado de acuerdo con la literatura sobre la planeación de la demanda en el sector servicios revisada en la sección 2.1.1 Planeación de la demanda en el sector servicios, incluyendo el paso de planeación de la oferta. Cabe señalar que para el desarrollo de este proceso se realizan solamente los planes para el producto de estudio (software AXML) y que estos son adaptables para incorporar los demás productos de la empresa mediante una planeación agregada.

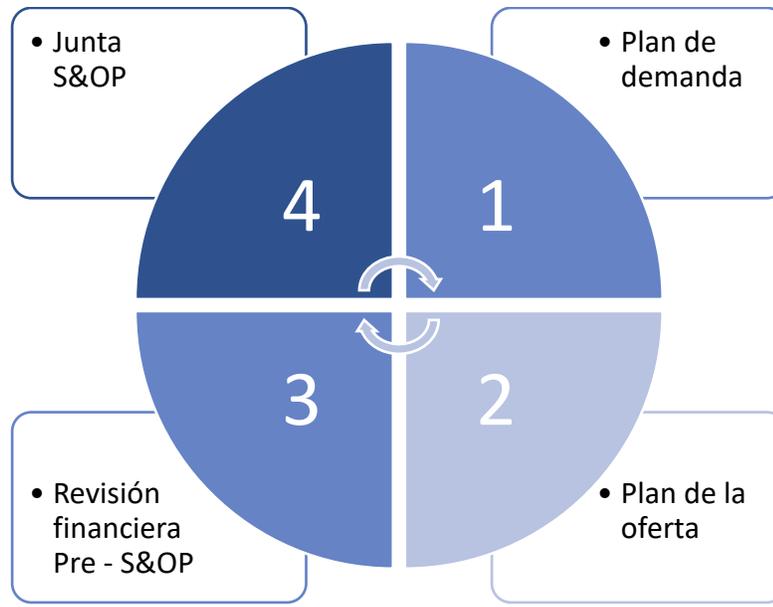


Ilustración 63. Propuesta del proceso de S&OP en el caso de estudio.  
Fuente: Elaboración propia con base en (Sintec, 2016).

Para comenzar con el desarrollo de S&OP, es importante realizar una revisión interna y externa de *Softing* por lo que se aplican los modelos de las 5 fuerzas de Porter y el Balanced Scorecard (BSC) para un mejor entendimiento de la empresa y así guiar los esfuerzos hacia el cumplimiento de su visión. Se recomienda que en la primera reunión se revise este análisis.

#### Modelo de las 5 fuerzas de Porter

Para analizar el entorno de *Softing* se desarrolla el análisis de las 5 fuerzas de Porter para comparar su propuesta de valor con la de su competidor principal al cual será referido como la empresa "X".

#### 1. La rivalidad entre los competidores existentes.

La empresa "X" desarrolla software y aplicaciones web a la medida de las necesidades de los clientes dirigidos a los procesos administrativos, fiscales y contables. Al igual que *Softing*, es una microempresa, por ello, y debido al giro en el que se desarrolla se considera su principal competidor.

En el mercado mexicano existen otras empresas que ofrecen el mismo tipo de productos, pero la empresa "X" utiliza las mismas tecnologías que *Softing*.

Esta empresa fue pionera en el desarrollo de software para facturación por lo que tiene mayor tiempo y experiencia en el mercado.

Ambas empresas cuentan con diferentes modalidades de venta, la empresa "X" renta las licencias de sus software, además de que estos están divididos por módulos y se rentan por separado, también tienen diferentes precios según el plan que va de acuerdo con el tamaño de empresa del cliente. Por su parte, *Softing* vende la licencia del AXML sin necesidad de pagar una renta mensual, solo se compran las actualizaciones e incluye los módulos completos. *Softing* identifica esta

situación como un área de oportunidad porque hay clientes que prefieren la renta en lugar de la compra y la separación de las funciones por módulos porque los clientes también prefieren comprar solo lo que necesitan además de que se podrían agregar nuevas funciones.

La empresa "X" cuenta con una página web dinámica en donde los precios de sus productos son transparentes y cuenta con video tutoriales donde explican el uso de sus productos desde los primeros pasos para su uso hasta la demostración de diferentes funciones que incluye. En la actualidad Softing trabaja en su página web donde integra la venta en línea y herramientas digitales para la capacitación de sus clientes.

En cuanto a la diferenciación con su competidor, *Softing* ofrece como valor agregado la cantidad de descarga de CFDI's en una sola consulta que es posible gracias a la constante capacitación de los colaboradores para ofrecer tecnologías de vanguardia, la actualización de software según los nuevos requerimientos del SAT y la capacidad de predicción de nuevas tendencias y sus precios competitivos.

## **2. La entrada de nuevos competidores**

La entrada de nuevos competidores en el mercado puede ser fácil dado que aún no existen muchas empresas en este giro que sean reconocidas, sin embargo, el proceso de integración exitoso al negocio puede verse complicado si no cuenta con la experiencia tanto del área a los que van dirigidos los productos y de las tecnologías para su desarrollo. Estos son aspectos a considerar, además de los precios competitivos y de una estrategia de marketing que es donde podría encontrarse un diferenciador pues tanto la empresa "X" como *Softing* no cuentan con esta estrategia o no es de gran alcance.

## **3. La amenaza de sustitutos**

La competencia entre empresas que ofrecen este tipo de productos se hace más fuerte mientras continúan con la búsqueda de consolidarse y ser reconocidas en el mercado siguiendo la relación entre precio y funcionalidad. Por esta parte es fácil que se encuentren sustitutos y empresas que desarrollan otro tipo de software decidan entrar a este negocio incluyendo grandes corporaciones que bien podrían identificar esta área de oportunidad en el mercado mexicano.

## **4. El poder de negociación con los compradores**

Los clientes tienen un alto poder de negociación y se vuelven más exigentes conforme se les ofrece nuevas soluciones por lo que es necesario que *Softing* innove en sus productos y que al mismo tiempo ofrezca precios competitivos.

Durante y después de los tiempos de pandemia los clientes se han comportado cautelosos en cuanto a inversiones se refiere porque han tenido que economizar, aunque también han tenido que renovar sus modelos de negocio por la necesidad de digitalizar sus operaciones por esta situación y por los cambios fiscales que imponen la adaptación a la facturación electrónica. En este contraste, *Softing* también debe seguir una estrategia donde los clientes comprendan las ventajas que brinda el

software. Además, se ve una tendencia en los clientes donde presentan mayor interés en capacitarse por medios digitales en lugar de tener un contacto humano, por lo que también es necesario diseñar plataformas digitales para su capacitación.

### **5. El poder de negociación con proveedores**

El poder de negociación con los proveedores es bajo pues los principales colaboradores de Softing son los servidores virtuales, instaladores y proveedores de luz e internet.

Por el momento, la empresa cuenta con un servidor propio que es suficiente para las operaciones y no tiene la necesidad de contratar un servidor virtual, sin embargo, como el objetivo es que las ventas se incrementen será necesario tener en cuenta la contratación del servicio. Entre otras razones para ello es evitar costos de mantenimiento del equipo y evitar problemas como problemas con la energía eléctrica y el internet.

#### Balanced Scorecard

Con base en el análisis anterior se propone una estrategia conformada por los siguientes elementos para implementar la visión de *Softing*:

- Atracción y retención del talento
- Ofrecer servicio de calidad
- Ofrecer software a la vanguardia tecnológica y alineado con las necesidades del cliente
- Aumentar la fuerza de ventas y marketing
- Satisfacción del cliente

Para alcanzar esta estrategia se hace uso del BSC en donde se muestran los objetivos estratégicos a seguir y se clasifican en los cuatro conjuntos que corresponden a las cuatro perspectivas del BSC, añadiendo la perspectiva de Ventas/Marketing pues se identificó como un área de oportunidad para la empresa.

Dicho análisis se plasma en el siguiente mapa estratégico en donde se incluye la relación causa-efecto entre cada objetivo estratégico de manera que se puede observar que, desde la parte inferior, los objetivos impulsan el éxito de los que se encuentran en la parte superior.

**MAPA ESTRATÉGICO**

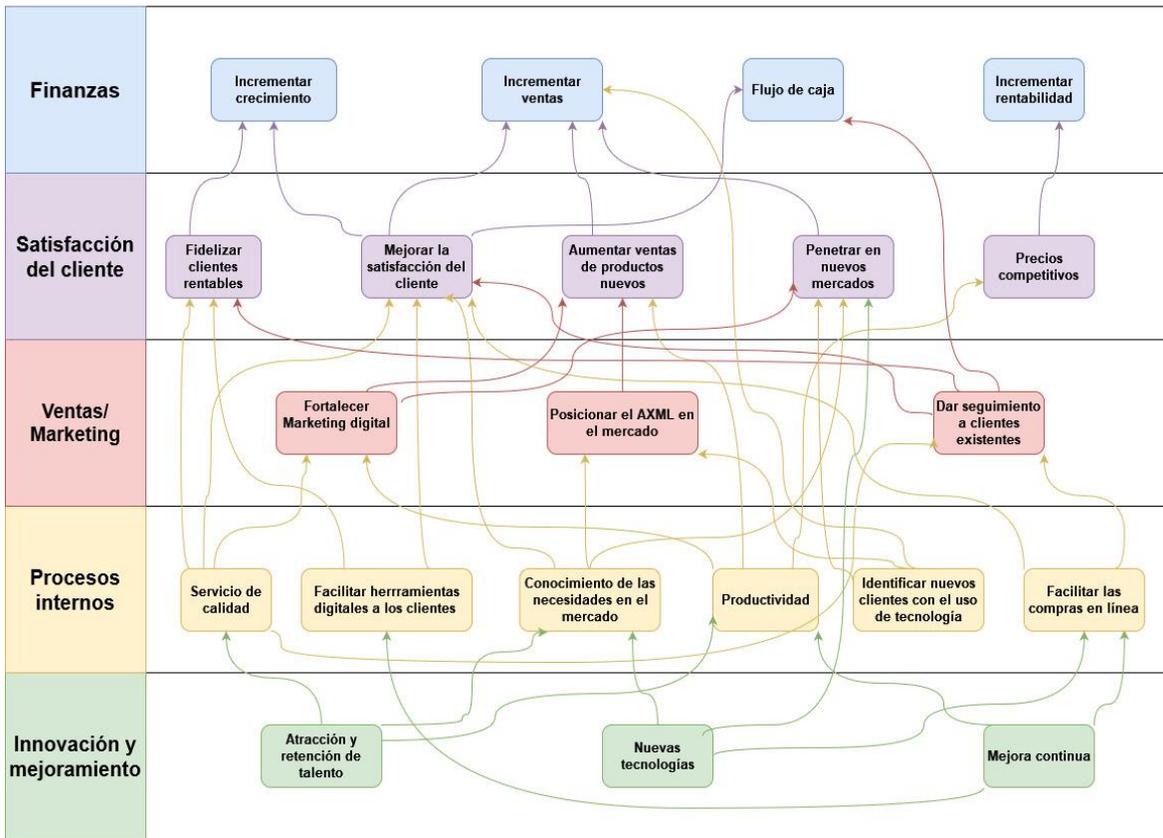


Ilustración 64. Mapa estratégico de Softing  
Fuente: Elaboración propia.

Estos son los objetivos que se toman como sustento para la planeación de demanda y suministro y la toma de decisiones en las reuniones S&OP pues los esfuerzos de las áreas de la empresa deben alinearse y dirigirse para cumplirlos.

En la sección 0 se muestran los indicadores de desempeño propuestos para el proceso del S&OP y además de ellos, se proponen los indicadores para el seguimiento del BSC que también deben ser revisados en las reuniones S&OP.

En Softing es el inicio de la integración del proceso además del inicio de una planeación formal de demanda y de suministro, por lo que se tomará como horizonte de planeación tres meses, los cuales corresponden a los periodos de predicción, y se propone realizar revisiones mensuales.

5.8.1 Plan de demanda

De acuerdo con Sintec (2016) el plan de demanda consta de los siguientes pasos:

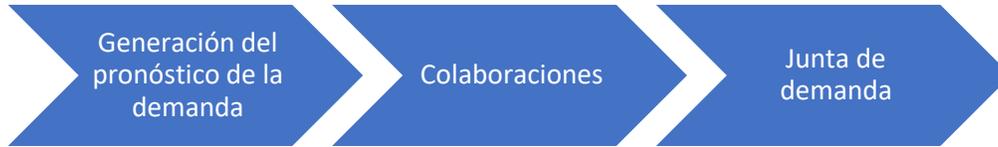


Ilustración 65. Proceso de plan de demanda.  
Fuente: Elaboración propia con base en (Sintec, 2016).

### **1. Generación del pronóstico de la demanda**

El primer paso es la generación del pronóstico de la demanda. En este trabajo este paso puede ser revisado a detalle a partir de la sección 5.2. Cabe mencionar que, aunque la demanda pronosticada corresponde al periodo del último trimestre del año 2021, se plantea la presente propuesta considerando la situación actual de la empresa dado que el procedimiento es adaptable con la serie de tiempo de ventas actual.

### **2. Colaboraciones**

El siguiente paso es la colaboración. En esta fase se revisa el valor del pronóstico y, en caso de ser necesario, es ajustado por el área de ventas porque es el área que tiene el conocimiento y experiencia en el comportamiento de la demanda. El pronóstico antes calculado se toma como una herramienta de apoyo para la toma de decisiones. En este caso esta modificación no es realizada y se considera el pronóstico mostrado en la Tabla 10.

El proceso de la venta de una licencia del AXML se describe en el siguiente árbol estructural de servicio, el cual comprende las actividades que se realizan durante la preventa y postventa del software, así como las actividades de desarrollo. Estas últimas no son tomadas en cuenta para la programación de colaboradores porque son actividades que se realizan indirectamente para efectuar una venta y su tiempo de duración no afecta en esta planeación dado que el desarrollo de actualizaciones del software y el mantenimiento de la página web de la empresa deben estar listas para el momento de realizar una venta, pero se muestran a manera de ilustración de continuación del proceso, además de que el costo unitario de una licencia del AXML contempla estas tareas.

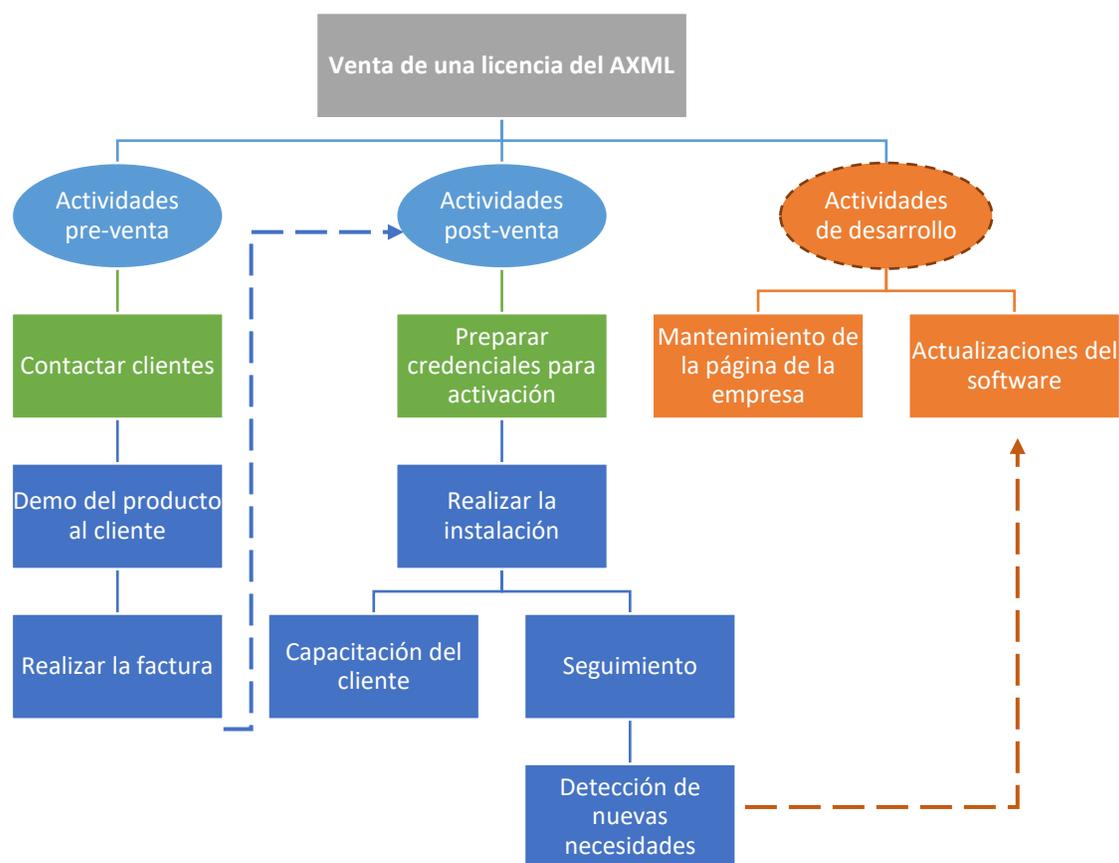


Ilustración 66. Árbol estructural de servicio para la venta de una licencia del AXML.  
Fuente: Elaboración propia.

Para la venta de una licencia primero se realiza el contacto con el cliente, ya sea que este sea buscado por parte de la empresa o el cliente llegue por su cuenta o por recomendación de un tercero. Después se realiza un demo o demostración del software mostrando su funcionalidad, sus módulos y las ventajas que ofrece. Si el cliente está interesado en adquirir la licencia se le realiza una factura para terminar la venta.

Una vez que esta se efectúa la venta, se preparan las credenciales con las que el cliente puede activar su licencia para lo que se requiere recopilar la información del usuario tal como RFC de la empresa, razón social, nombre del usuario, correo, número de contacto y posición en la empresa. Posteriormente se acompaña al usuario con la instalación del software y con la activación de su licencia, se le brinda capacitación al usuario, si es que así lo requiere, y después de esto se le da seguimiento, puede ser que el cliente sea el primero en acercarse para resolución de sus dudas o que *Softing* lo contacte. Como parte de este seguimiento también se va realizando la detección de nuevas necesidades.

## Uso del pronóstico de la demanda para proponer un plan de ventas y operaciones en empresas de servicios.

---

Las actividades de desarrollo, que son aquellas que son indirectas a las ventas, se encuentran el mantenimiento de la página de la empresa para ofrecer a los clientes un medio de contacto con la empresa y el desarrollo de las actualizaciones del software. Estas actividades son importantes porque persiguen el objetivo de retención y atracción de nuevos clientes.

Estas tareas se enlistan en la siguiente tabla en donde también se muestra el tiempo de duración promedio de cada tarea al mes y cuántos colaboradores son necesarios para ejecutarlas.

El costo unitario por la venta de una licencia (incluyendo el salario de colaboradores, pagos a proveedores y de servicios y gastos en general) es de \$1,500.

Tabla 11. Lista estructurada de servicios para la venta de una licencia del AXML

<b>Actividades</b>	<b>Tiempo de duración promedio (minutos)</b>	<b>Número de colaboradores necesarios</b>
Contactar clientes	60	1
Demo del producto	40	1
Realizar la factura	10	1
Realizar la instalación	15	1
Capacitación al cliente	30	1
Seguimiento	30	1
Detección de nuevas necesidades	30	1
Desarrollo de la página de la empresa	1500	2
Actualizaciones del software	600	2

**Fuente:** Elaboración propia.

La duración promedio de las actividades que se realizan en la preventa y en la postventa suelen ser constantes, mientras que la duración de las actividades de mantenimiento suele variar por diferentes factores.

Uso del pronóstico de la demanda para proponer un plan de ventas y operaciones en empresas de servicios.

---

En el caso de la actividad “desarrollo de la página de la empresa”, la duración actual es mayor a otros meses porque la empresa se encuentra trabajando en la actualización de su página web incluyendo módulos de venta mediante la misma. Cuando se encuentre lista el tiempo de duración de esta actividad disminuirá y este valor tendrá que ser cambiado para realizar los planes a futuro.

La duración de las actualizaciones del software depende de los cambios del SAT y de la detección de nuevas necesidades, por lo que puede variar de un mes a otro.

Para ejecutar las actividades que se realizan en la pre y postventa del software se requiere de un colaborador que comúnmente suele ser la misma persona desde el inicio (contactar con el cliente) hasta el final del servicio (detección de nuevas necesidades). Y la realización de las actividades de desarrollo requieren de dos colaboradores cada una.

Actualmente en la empresa hay tres colaboradores que se dedican a estas tareas, las tres personas se dedican a las actividades de pre y posventa y dos de ellas se encargan del desarrollo. La empresa espera que en un futuro pueda contratarse por lo menos a una persona que se dedique exclusivamente a las actividades de preventa y que cumpla con un perfil de ventas, además del conocimiento del software para cerrar ventas de manera más rápida y eficiente.

En la siguiente tabla se muestra la programación de los colaboradores y los costos requeridos para satisfacer la demanda de acuerdo al pronóstico.

Tabla 12. Programación de colaboradores y costos para satisfacer la demanda.

Periodo futuro (mes)	Pronóstico	Colaboradores necesarios por licencia	Colabores necesarios promedios	Tiempo requerido (minutos)	Tiempo requerido (minutos)	Costo	Costo regular
1	4	4	4	860	860	\$6,000.00	\$6,000.00
2	4	4	4	860	860	\$6,000.00	\$6,000.00
3	7	7	4	1505	860	\$10,500.00	\$6,000.00
<b>Total</b>	<b>15</b>	<b>15</b>		<b>3225</b>	<b>2580</b>	<b>\$22,500.00</b>	<b>\$18,000.00</b>

**Fuente:** Elaboración propia.

En la tabla anterior también se muestra el número de colaboradores que son necesarios para satisfacer la demanda promedio (5 licencias), el tiempo promedio para satisfacer la demanda y el costo de demanda promedio que indican la programación de una demanda constante en los siguientes periodos. Puede interpretarse que es necesario contar por lo menos con 4 colaboradores para satisfacer la demanda en los siguientes periodos y que esto conlleva un tiempo de 860 minutos (14.33 horas) y un costo de \$6,000 al mes.

Estos valores pueden servir como base para la planeación de los periodos futuros, sobre todo considerando que la demanda es tipo lumpy y puede presentar una mayor variación, sin embargo, este planteamiento debe ser tratado en la reunión de demanda.

Para el periodo futuro inmediato se requieren 4 colaboradores para realizar las tareas de venta de 4 licencias, para lo que necesitan 860 minutos y el costo es de \$6,000. Se puede contemplar como un aproximado que para los siguientes tres meses se necesitará de 3225 minutos (53.75 horas) del tiempo de los colaboradores y \$22,500 para satisfacer la demanda, sin embargo, la programación puede cambiar el siguiente mes al reiniciar el proceso y contando con nueva información.

Las modificaciones al programa y su aprobación son realizadas en la junta de demanda.

### **3. Junta de demanda**

La junta de demanda tiene como objetivo buscar el consenso de las áreas responsables de demanda para la aprobación del plan de demanda.

Para este caso, es un proceso donde una vez que se plantea el plan de demanda, se realizan modificaciones de acuerdo con la experiencia de los encargados y se toman decisiones. El entregable de esta junta es el plan de demanda aprobado por el área de ventas y operaciones para ser presentado en la junta S&OP.

#### **5.8.2 Plan de oferta**

En la industria manufacturera el plan de suministro comprende los planes de capacidad de abastecimiento, capacidad de producción y capacidad de almacenaje y transporte y tiene como objetivo definir qué comprar y de qué fuentes, así como definir si las expectativas son realistas. Este proceso se realiza por las áreas operativas y sirve para comparar la capacidad con el plan de demanda.

Este proceso puede ser adaptado para la industria de servicios y consiste en analizar e identificar posibles dificultades para llevar a cabo el plan de demanda. Si la capacidad no se ajusta a los planes de demanda previstos, se pueden modificar las operaciones para encontrar soluciones que permitan generar lo que está previsto vender.

Para este caso, el elemento de capacidad con mayor importancia son los colaboradores pues el producto no necesita de otro tipo de capacidad para ser ofertado más que el espacio de almacenamiento para las credenciales de los usuarios en el servidor de la empresa.

en el plan de demanda (Tabla 12) se requieren de 4 colaboradores para satisfacer la demanda de 4 licencias en el siguiente mes. Se pueden organizar los horarios de los 3 colaboradores que están disponibles y repartir las tareas para satisfacer la demanda tomando en cuenta las demás actividades que llevan a cabo dentro de la empresa. Y lo mismo sucede cuando la demanda supere las 3 licencias como en el caso de los siguientes periodos.

Esta organización es posible en medida que la demanda sea menor a 40 licencias, pues como se muestra en la siguiente tabla, los colaboradores no pueden dedicar más del 30% de su jornada laboral mensual en realizar solamente estas actividades.

Tabla 13. Capacidad máxima del elemento colaboradores.

Pronóstico	Colaboradores necesarios por licencia	Tiempo requerido (minutos)	Tiempo requerido (horas)	Tiempo por colaborador (minutos)	Tiempo por colaborador (horas)	Minutos laborales al mes	Horas laborales al mes	Costo
40	40	8600	107.5	2866.66	47.77	9600	160	\$60,000.00
		% tiempo dedicado al mes		30%	30%			

Fuente: Elaboración propia.

Por otro lado, la contratación de más personal es una opción que la empresa contempla y así, podría superar su capacidad de servicio. Sin embargo, por el momento no es necesario porque la demanda no rebasa este límite, aunque es un objetivo que se persigue. De igual manera, el que la demanda aumente vuelve más viable la operación y sostener los costos pues estos representan aproximadamente el 20% del precio del software.

Realizando el análisis sobre el escenario que resulta de la combinación entre la capacidad y la demanda en que se encuentra Softing de acuerdo con la literatura (sección 2.1.1) se puede concluir que actualmente la empresa cuenta con capacidad en exceso, es decir, la demanda está por debajo de su capacidad, lo que provoca la ineficiencia de los recursos y baja productividad.

De las estrategias a seguir para intervenir en este problema que se proponen en la literatura se muestran en la Ilustración 12 y para este caso se selecciona la estrategia de *oferta en precios y segmentación de la demanda* para el plan de demanda, mientras que la estrategia que se ya se aplica en el plan de oferta es *empleados multifuncionales, participación del cliente y compartir la capacidad*.

#### *Estrategias para el plan de demanda*

Las estrategias que se proponen seguir en el plan de demanda son:

- Oferta de precios.

La estrategia puede ser aplicada mediante un sistema de precios que dependen del número de licencias que adquieren los clientes en donde a partir de la compra de un número de licencias se ofrece un descuento. De igual manera, se puede ofrecer el producto más económico en momentos en los que la demanda sea menor o en los periodos estimados con venta nula.

- Segmentación de la demanda:

La segmentación de la demanda consiste en segmentar el software por módulos, de manera que la venta incluye solo las funciones que el cliente necesita en lugar del software global. Esto implica una reducción del precio, pero también reduce la duración de la prestación del servicio.

La división en estos módulos debe ser revisada por el equipo de desarrolladores y por los colaboradores de ventas de acuerdo con las necesidades de los clientes.

Para llevar a cabo estas estrategias de equilibrio de demanda con la oferta, se propone que vayan acompañadas de una estrategia de marketing para lograr con este cometido y con los objetivos de mayor alcance a clientes y penetración de nuevos mercados.

Una empresa puede colaborar con el área de marketing en este punto, planteando los objetivos a seguir. Las ventajas de aplicar una estrategia de marketing no solo incluyen el alcance de nuevos clientes, sino también pueden ayudar con la fidelización de los clientes. Para esto último la empresa puede comenzar un blog en donde hablen de temas de interés para los clientes como nuevas reglamentaciones del SAT y también videos tutoriales donde se expliquen las ventajas del AXML y su funcionamiento.

En el Anexo 8 se muestra una estrategia Inbound y Outbound Marketing (ver sección 2.1).

#### *Estrategias para el plan de oferta*

En este caso las estrategias de *empleados multifuncionales* y *participación del cliente* son utilizados porque los colaboradores se dedican a otras tareas y no solo a las relacionadas con el AXML y existe la participación del cliente de manera indirecta cuando se le ofrece el seguimiento pues es cuando los colaboradores pueden identificar sus nuevas necesidades.

*Compartir la capacidad* es una estrategia que se relaciona con *empleados multifuncionales* de manera que la capacidad de mano de obra es compartida, pero también la capacidad de almacenamiento es compartida, pues el servidor también es utilizado para otros productos de la empresa al igual que los servicios como luz, internet y el mantenimiento de los equipos.

La conclusión de este apartado, donde se alinean los planes de demanda y de oferta, es que es posible satisfacer la demanda de los próximos tres meses con la capacidad de operaciones que tiene la empresa mediante la programación de los colaboradores para la realización de las actividades pertinentes. Sin embargo, se expone que la capacidad operativa supera a la demanda lo que indica que los recursos no son aprovechados eficientemente. Para ello se proponen estrategias para balancear la demanda con la oferta y estas al igual que los costos que involucra el plan de demanda, deben ser estudiados durante la revisión financiera Pre-S&OP.

#### 5.8.3 Revisión financiera Pre - S&OP

En esta junta se reúnen los responsables de finanzas, operaciones, cadena de suministro, marketing y todas aquellas áreas involucradas en el proceso de S&OP con el propósito de validar todos los datos analizados en las fases anteriores e incluirlos dentro del cuadro general de seguimiento. Al final, se presentan estos datos al comité ejecutivo, que les dará validez.

En el caso de Softing, al ser una microempresa, esta reunión es realizada por el área de finanzas y por el equipo de ventas que anteriormente planteó y alineó los planes de demanda con los de producción. En esta reunión se aprueban o no los planes anteriores tras el análisis de costos asociados y se toman decisiones para modificarlos o implementar estrategias para llevarlos a cabo tomando en cuenta los beneficios futuros.

Para ello se analizan los planes de ventas y se comparan con los objetivos del negocio incluyendo las ventas, utilidades y activos invertidos. También se realiza la generación de estados financieros proyectados como el Estado de Resultados y el Balance General, además de los requerimientos adicionales de capital por cambios que no son esperados y/o gastos operativos.

En el Anexo 9 se presentan las plantillas que se proponen como entregables de esta reunión en las que se incluyen los análisis financieros de recursos humanos, inversiones, costos fijos, costos variables, balance general y estado de resultados.

#### 5.8.4 Junta S&OP

La base para realizar la junta S&OP son los planes anteriores y para llevarla con éxito también es necesario que se definan y asignen las responsabilidades pre-S&OP, las cuales, al igual que la reunión en sí, deben ser agendadas.

Se propone que el responsable de llevar y coordinar el proceso S&OP sea una persona que pertenezca al área administrativa y en la siguiente tabla se presenta el área responsable de llevar a cabo cada tarea del proceso.

Tabla 14. Asignación de tareas del proceso S&OP por área.

<b>Tarea</b>	<b>Área responsable</b>
Recolección de datos	Operaciones
Pronóstico de la demanda	Operaciones
Colaboración para el ajuste de pronóstico	Ventas y operaciones
Plan de demanda	Ventas y operaciones
Plan de oferta	Administración
Revisión financiera	Finanzas

**Fuente:** Elaboración propia

En cuanto a la agenda de las reuniones y de la elaboración de cada tarea, se propone seguir el siguiente calendario mensual el cual comienza el primer lunes del mes con la recolección de datos de ventas del mes anterior, se toman los siguientes dos días para generar el pronóstico, luego se lleva a cabo la colaboración entre operaciones y ventas para revisar y ajustar el pronóstico y los dos días siguientes se realiza el plan de demanda.

El siguiente día se comparte el plan de demanda con el área administrativa para poder comparar con el plan de oferta el cual puede ser diseñado antes, pero debe estar listo el segundo viernes del

Uso del pronóstico de la demanda para proponer un plan de ventas y operaciones en empresas de servicios.

mes para que el tercer lunes se realice el análisis de estrategia de equilibrio entre demanda y oferta. Posteriormente se hace la revisión financiera y el cuarto lunes del mes el encargado del proceso verifica que no falten pendientes por terminar para que el último viernes del mes se realice la reunión S&OP.

MON 27	TUE 28	WED 29	THU 30	FRI Oct 1
4	5	6	7	8
Recolección de datos de ventas del m	Generación del pronóstico	Generación del pronóstico	Colaboraciones; Revisión del pronósti	Colab: Plan de demanda
11	12	13	14	15
Colab: Plan de demanda	Colab: compartir plan de demanda Day of Race	Plan de oferta	Plan de oferta	
18	19	20	21	22
Colab: Estrategias de demanda y ofert	Colab: compartir planes	Revisión financiera	Revisión financiera	
25	26	27	28	29
Revisión de cumplimiento			Reunión S&OP	
Nov 1	2	3	4	5
	Day of the Dead			

Ilustración 67. Calendario de actividades del proceso S&OP.

**Fuente:** Elaboración propia

Una vez que se tiene la información y los planes están listos se realiza la junta S&OP.

En esta reunión se analizan las mejores alternativas con base en los planes propuestos considerando los riesgos que pueden presentarse y la nueva información con la que cuentan las diferentes áreas y que pueden tener impacto en las acciones futuras, tales como nuevos proyectos o prospectos de clientes.

Las propuestas se analizan y se debaten entre los encargados de cada área para llegar a acuerdos sobre decisiones en las operaciones y en las estrategias a seguir para lo que se hace una revisión de escenarios críticos.

Los entregables de esta reunión son los planes de demanda, de oferta y de finanzas acordados entre los responsables de todas las áreas y estos son comunicados a la organización.

También se entrega un acta de la reunión en donde se plasman los acuerdos, los pendientes a revisar, los nuevos asuntos, los anuncios para las futuras reuniones y la firma de aprobación y comentarios o conclusiones del director general. La plantilla de esta acta se presenta en el Anexo 10.

Por último, como parte de la revisión del S&OP y como seguimiento a los objetivos estratégicos mostrados en la Ilustración 64 se propone implementar indicadores de desempeño como apoyo a las decisiones con base en información cuantitativa de los logros de la empresa.

#### Indicadores de desempeño

Para cada objetivo estratégico se propone una métrica para medir su avance o identificar áreas de oportunidad, los cuales se muestran en el siguiente diagrama:

Tabla 15. Indicadores de desempeño para el BSC.

	Objetivos	Indicadores
<b>Finanzas</b>	<ol style="list-style-type: none"> <li>Incrementar ventas</li> <li>Incrementar crecimiento</li> <li>Flujo de caja</li> <li>Incrementar rentabilidad</li> </ol>	<ul style="list-style-type: none"> <li>Índice de crecimiento de venta</li> <li>EBITDA</li> <li>Flujo de caja</li> <li>Rentabilidad de la empresa</li> </ul>
<b>Satisfacción del cliente</b>	<ol style="list-style-type: none"> <li>Fidelizar clientes</li> <li>Mejorar la satisfacción del cliente</li> <li>Penetrar en nuevos mercados</li> <li>Aumentar ventas de nuevos productos</li> <li>Precios competitivos</li> </ol>	<ul style="list-style-type: none"> <li>Promedio de compras por cliente</li> <li>% Resolución de quejas</li> <li>Penetración de mercado</li> <li>Ventas de productos nuevos</li> <li>ROI</li> </ul>
<b>Marketing</b>	<ol style="list-style-type: none"> <li>Fortalecer marketing digital</li> <li>Posicionar el AXML en el mercado</li> <li>Dar seguimiento a clientes existentes</li> </ol>	<ul style="list-style-type: none"> <li>Índice de ventas logradas por marketing</li> <li>Índice de clientes nuevos</li> <li>Índice de tráfico en la páginas web</li> </ul>
<b>Procesos internos</b>	<ol style="list-style-type: none"> <li>Servicio de calidad</li> <li>Facilitar herramientas digitales a los clientes.</li> <li>Conocimiento de las necesidades en el mercado.</li> <li>Identificar nuevos clientes con el uso de la tecnología.</li> <li>Facilitar las compras en línea.</li> <li>Productividad</li> </ol>	<ul style="list-style-type: none"> <li>Índice de comentarios negativos</li> <li>Índice de tráfico en el blog de la empresa</li> <li>Índice de nuevos prospectos identificados con análisis de datos</li> <li>Tasa de compras en línea</li> <li>Índice de productividad</li> </ul>
<b>Innovación y mejoramiento</b>	<ol style="list-style-type: none"> <li>Atracción y retención del talento</li> <li>Nuevas tecnologías</li> <li>Mejora continua</li> </ol>	<ul style="list-style-type: none"> <li>Índice de rotación de personal</li> <li>Tasa de retención de talento</li> <li>Tasa de proyectos de innovación realizados</li> <li>Efectividad de implementación de nuevas tecnologías</li> <li>Índice de mejora continua</li> </ul>

Fuente: Elaboración propia.

Es importante el seguimiento de cada uno para verificar el logro de cada objetivo, sin embargo, el nivel de madurez de la empresa se encuentra en el nivel 1 (ver Ilustración 10) el cual corresponde a un proceso S&OP inexistente en donde no existen reuniones, colaboración, indicadores y un plan formal, lo que implicaría un problema para la empresa por la cantidad de información a procesar, además de la dedicación a implementar esta nueva cultura de organización.

Por tanto, se propone que conforme aumente la madurez de desarrollo e implementación del S&OP en la empresa se incorporen otras métricas y que los indicadores básicos sean los siguientes:

Tabla 16. Indicadores de desempeño para el nivel de madurez 1 del proceso S&OP.

Indicador	Descripción	Ecuación
Error del pronóstico	Costo del Error de Predicción orientados al Mantenimiento de Existencias  (SPEC)	Ecuación 6 en página 32
	Error cuadrado medio  (MSE)	Ecuación 4 en página 30
	Deriviación media absoluta  (MAD)	Ecuación 3 en página 30
Índice de variaciones sobre el plan de demanda <sup>3</sup>	Muestra el índice de variaciones realizadas sobre el plan de demanda al ser comparado contra los planes de oferta y de finanzas.	$IVP = \frac{\text{Número veces que se modificó el plan}}{\text{Número periodos del proceso S\&OP}} \times 100$
Índice de crecimiento de ventas	Muestra el porcentaje en el que han crecido o disminuido las ventas.	$\frac{\text{Índice de crecimiento de ventas}}{= \frac{\text{Ventas del periodo actual} - \text{Ventas del periodo anterior}}{\text{Ventas del periodo anterior}} * 100}$

<sup>3</sup> Este indicador se considera básico para conocer qué tan acertados son los planes de demanda, sin embargo, será útil en periodos futuros cuando se hayan realizado modificaciones sobre dicho plan y puedan ser contados.

Uso del pronóstico de la demanda para proponer un plan de ventas y operaciones en empresas de servicios.

<b>Rentabilidad</b>	Permite evaluar si la empresa tiene la capacidad de generar los recursos económicos que permitan cubrir los costos.	$\text{Rentabilidad} = \frac{\text{Beneficio bruto}}{\text{Activo total neto}}$
<b>Nivel de servicio</b>	Muestra el porcentaje de resolución de problemas del cliente.	$\% \text{ Resolución de problemas} = \frac{\text{Número de problemas solucionados}}{\text{Número de problemas totales}} \times 100\%$
<b>Índice de tráfico en la página web</b>	Muestra la variación de mes a mes de la actividad de clientes y clientes potenciales que visitan la página de la empresa.	$\% \text{ Tráfico en la página web} = \frac{\text{tráfico en el periodo actual} - \text{tráfico en el mes anterior}}{\text{tráfico en el periodo anterior}} \times 100\%$
<b>Utilización de la capacidad de producción o productividad</b>	Muestra qué tan eficiente es la gestión de recursos utilizados.	$\text{Índice de productividad} = \frac{\text{Total de productos fabricados}}{\text{Recursos empleados (personal + materiales + capital + otros)}} \times 100$

Fuente: Elaboración propia

Se proponen estos indicadores porque dan seguimiento al proceso S&OP y a cada categoría del BSC, vigilando el aspecto financiero, de clientes, marketing y procesos internos y permite que la empresa tenga un punto de partida para la medición de su crecimiento.

El análisis previo hace notar las áreas de oportunidad de la empresa al ser comparada con sus competidores y decidir cuáles son las estrategias por seguir para crear valor para los clientes y para ser competitiva en el mercado. Para esto, también resulta fundamental tener conocimiento de la demanda porque es la base para realizar los pasos posteriores de planeación en la empresa y para la alineación de la demanda con la capacidad, pues al ser una mayor a la otra puede resultar en pérdidas para la empresa.

## Conclusiones y recomendaciones

A pesar de las diferencias entre las empresas de servicios y las empresas de manufactura, ambas comparten características que, de manera general, explican la interacción de su cadena de suministro con su entorno, con los participantes que se involucran en ella y con sus principales objetivos.

Una de estas características es la incertidumbre bajo la que operan, siendo el pronóstico de la demanda una tarea esencial no solo en empresas de producción, que es el área en el que más ha sido estudiado, sino también en empresas de servicios pues, aunque resulte complicado la cuantificación de su producto, también requiere de herramientas de apoyo para la toma de decisiones frente a situaciones que no pueden ser controladas.

El cálculo del pronóstico de demanda es un procedimiento que requiere de tiempo, recursos y un análisis profundo para ser lo más certero posible. En él, debe considerarse que existen muchas técnicas a utilizar, pero la elección de estas depende del comportamiento de la demanda.

La demanda lumpy es un tipo de demanda poco común y que en la literatura se estudia principalmente en empresas de manufactura, sin embargo, teniendo presentes las similitudes entre los dos tipos de empresas se demuestra que esta teoría puede ser aplicada para empresas de servicios.

Además de las técnicas estadísticas para el cálculo de la demanda de tipo lumpy se han estudiado otro tipo de técnicas que utilizan Inteligencia Artificial y de acuerdo con estos estudios, los que presentan mejor rendimiento son los modelos de ML, destacando el algoritmo Multi-layer Perceptron que, comparado con el modelo estadístico, se comprobó la superioridad con los datos utilizados en este trabajo. Una desventaja que se destaca de dichos datos es que son de pocos periodos comparados con la gran capacidad de procesamiento de este tipo de herramientas, por lo que se debe tomar en cuenta para futuros trabajos siendo que una base de datos más robusta presentaría mejores resultados.

El pronóstico de la demanda requiere de todo un análisis, pero es apenas el primer paso para la planeación en una empresa. Este paso resultó ser fundamental porque de no realizarse no se tendría la información para programar los tiempos de los empleados, la capacidad de operaciones y los costos. De igual manera el análisis de los planes de demanda y de oferta es sobresaliente porque destaca la problemática de los escenarios en donde la demanda supera la oferta o viceversa y en los tres casos en donde no hay un equilibrio entre estas, existen pérdidas para la empresa.

Por otro lado, el análisis de las 5 fuerzas de Porter contribuye haciendo notar las acciones que hace la competencia y la empresa no y, por tanto, permite que con base en la comparación se fijen objetivos a alcanzar. Estos objetivos pueden clasificarse en las categorías que el BSC sugiere y se concluye que esta herramienta es de ayuda porque permite tener un panorama completo de la empresa y las estrategias a seguir sin perder de vista sus objetivos gracias al monitoreo de los logros mediante el seguimiento de las métricas de desempeño.

Esta herramienta en conjunto con el proceso S&OP permite un mayor control de las actividades dentro de la empresa, el cual sirve también para asegurarse de que la comunicación entre las áreas de la empresa sea transparente y eficiente y evita que cada una realice planes por separado que al final supondrían una desorganización que costaría dinero, tiempo y recursos a la empresa. Más que ser un proceso, el S&OP debe convertirse en parte de la cultura organizacional de la empresa al tener como objetivo la transmisión de la información de planes y acuerdos en toda las áreas incluidos los objetivos de la organización.

Finalmente, las nuevas tendencias tecnológicas han obligado a las empresas a adaptarse. En la era digital en la que las empresas coexisten en la actualidad, se ha presentado el reto del manejo de un gran volumen de datos que puede ser aprovechado para prever la demanda para lo que resulta ineficiente utilizar un modelo estadístico. Por ello, una de las recomendaciones para trabajos futuros que pueden derivarse de la presente investigación, utilizar herramientas de Big Data las cuales proporcionen el comportamiento, hábitos, búsquedas del segmento de clientes al que va dirigido el producto y cruzar la información con las ventas históricas para predecir cuándo se presentará un poco de demanda o cuales son las fechas en las que es más conveniente generar ofertas.

## Referencias

- Abirami, S., & Chitra, P. (2020). *Advances in Computers*. Madurai, India.
- Assaghir, Z., Makki, S., & Zeineddine, H. (2017). *Machine Learning For Intermittent Demand Forecasting*. Lebanese University.
- Baca, G. (2001). *Evaluación de Proyectos*. México: Mc Graw Hill Interamericana Editores.
- Bagnato, J. I. (febrero de 2019). *Aprende machine learning*. Obtenido de Pronóstico de Series Temporales con Redes Neuronales en Python: <https://www.aprendemachinlearning.com/pronostico-de-series-temporales-con-redes-neuronales-en-python/>
- Ballou, R. H. (2004). *Logística Administración de la cadena de suministro*. Pearson Educación.
- Brand Ortiz , J. (s.f.). *Plan de Ventas y Operaciones (PVO): estrategia para maximizar la rentabilidad de las Pymes del sector textil colombiano*. Institución Universitaria Esumer.
- Brandt, J. R. (s.f.). *PLANEACIÓN DE DEMANDA: Optimizar las operaciones a través de la cadena de suministros*. Obtenido de Axentit: [http://axentit.com.mx/Descargables/Manufactura/Planeacion\\_de\\_la\\_demanda.pdf](http://axentit.com.mx/Descargables/Manufactura/Planeacion_de_la_demanda.pdf)
- Brownlee, J. (Marzo de 2017). *Machine Learning Mastery*. Obtenido de How to Convert a Time Series to a Supervised Learning Problem in Python: <https://machinelearningmastery.com/convert-time-series-supervised-learning-problem-python/>
- Brownlee, J. (2020). *5 Step Life-Cycle for Neural Network Models in Keras*. Obtenido de Machine Learning Mastery: <https://machinelearningmastery.com/5-step-life-cycle-neural-network-models-keras/>
- Carbonneau, R., Vahidov, R., & Laframboise, K. (2016). *Machine Learning-Based Demand forecasting in supply chains*. International Journal of Intelligent Information Technologies.
- Carreras, E., Miguel, G., Pulido, J., Rodríguez, S., & Salazar, T. (2018). *Inbound Marketing*. Estudio de Comunicación Online.
- Centeno Franco, A. (2019). *Deep Learning*. Sevilla: Universidad de Sevilla.
- Croston, J. D. (1972). *Forecasting and Stock Control for Intermittent Demands*. Operational Research Quarterly.
- Del Moral, M. (2020). *Cadena de Suministro Global*. Ciudad de México: Posgrado, Facultad de Ingeniería, UNAM.
- Deloitte , & SoyLogístico. (2017). *Eficiencia en la Cadena de Suministro. Estudio comparativo de prácticas y tendencias en México*. Ciudad de México.
- Deloitte. (2019). *Tendencias de industrias*.
- Eldridge, S., & Hung Goh, S. (2015). New product introduction and supplier integration in sales and operations planning: Evidence from the Asia Pacific region. *International Journal of Physical Distribution & Logistics Management* .
- Freppe. (s.f.). *Demand classification: why forecastability matters*. Obtenido de <https://freppe.com/blog/demand-classification/>
- Fuentes, A. (1995). *El enfoque de Sistemas en la Solución de Problemas la elaboración del modelo conceptual*. México: Facultad de Ingeniería, UNAM.

- Gonfalonieri, A. (Julio de 2020). *Introduction to Causality in Machine Learning*. Obtenido de Towards data science.
- Grimson, J. a. (2007). *Sales and Operations Planning: An Exploratory Study and Framework*. International Journal of Logistics Management.
- Guérillot, & Bruyelle, J. (2017). Uncertainty Assessment in Production Forecast with an Optimal Artificial Neural Network. *Society of Petroleum Engineers*.
- IBISWorld. (2021). *Manufacturing sector*.
- IBM. (s.f.). *Conceptos básicos de ayuda de CRISP-DM*.
- Inbound Logistics México. (2007). Al menos 7 de cada 10 empresas en México registran errores de pronósticos. *Inbound Logistics México*.
- INEGI. (2018). *Industria manufacturera*.
- INEGI. (2020). *Producto Interno Bruto*.
- Instituto Nacional de Estadística y Geografía. (s.f.). *Clasificación para Actividades Económicas*.
- Jiménez Sánchez , J. E., & Hernández García, S. (2002). *Marco conceptual de la cadena de suministro: un nuevo enfoque logístico*. Sanfandila, Queretáro.: Secretaría de Comunicaciones y Transporte. Instituto Mexicano del Transporte.
- Joseph, M. (7 de octubre de 2020). *Forecast Error Measures: Intermittent Demand*. Obtenido de Deep & Shallow.
- Kiefer, Daniel, Bauer, Markus, Grimm, Florian, & van Dinther, Clemens. (2021). *Demand Forecasting Intermittent and Lumpy Time Series: Comparing Statistical, Machine Learning and Deep Learning Methods*. Hawaii International Conference on System Sciences.
- Kim, S., & Kim, H. (2016). A new metric of absolute percentage error for intermittent demand forecasts. *International Journal of Forecasting*.
- Krajewski, L., Ritzman, L., & Malhotra, M. (2008). *Administración de Operaciones. Procesos y cadenas de valor*. . México: PEARSON EDUCACION.
- KRAJEWSKI, L., RITZMAN, L., & MALHOTRA, M. (2010). *Operations Management. Processes & supply chains*. México: Pearson.
- Lagunas, E. (2020). Así es la importancia del PIB durante la pandemia. *FORBES*.
- Lapide, L. (2007). Sales And Operations Planning (S&Op). *Mindsets. The Journal Of Business Forecasting*.
- López, J. F. (1 de marzo de 2018). *Variable endógena*. Obtenido de Economipedia: <https://economipedia.com/definiciones/variable-endogena.html>
- Lucas, J. (2017). *Apuntes complementarios de Planeación y Control de la Producción*. Ciudad de México: Facultad de ingeniería.
- Martín Peña, M., & Díaz Garrido, E. (2016). *Fundamentos de dirección de operaciones en empresas de servicios*. Madrid: ESIC.
- Martin, D., Spitzer, P., & Kühn, N. (2020). *New Metric for Lumpy and Intermittent Demand Forecasts: Stock-keeping-oriented Prediction Error Costs*. In Proceedings of the 53rd Annual Hawaii International Conference on System Sciences (HICSS-53).

- Martin, M. E. (2017). *Planificación de la cadena de suministros: desde el S&OP hasta el IBP*. Obtenido de <https://www.esan.edu.pe/conexion/actualidad/2017/10/20/la-planificacion-de-la-cadena-de-suministros/>
- Medina García, L. (2013). *Logística de los sistemas de armas del ministerio de defensa: modelos de previsión de demanda y análisis de coste - riesgo*. Gobierno de España. Ministerio de defensa.
- Meindl, P., & Chopra, S. (2008). *Administración de la cadena de suministro. Estrategia, planeación y operación*. México: PEARSON EDUCACIÓN.
- Menzies, T., Kocagüneli, E., Minku, L., Peters, F., & Turhan, B. (2015). *Data Science for Software Engineering: Sharing Data and Models*.
- Merino Nambo, V. M. (2013). *Planeación de la demanda en la logística contemporánea. Packaging.enfasis*.
- Muñoz, L., Galarza, O., Rodríguez, K., & Aboultaif, M. (2021). *Método Croston (Ejemplo para demanda errática)*. Universidad ICESI.
- Naciones Unidas. (2009). *Clasificación Industrial Internacional Uniforme de todas las actividades económicas (CIIU)*. Nueva York.
- Observatorio laboral. (2020). *Ocupación por sectores económicos. Tercer trimestre 2020*.
- Palacios Morales, G. (2019). *Machine Learning en el pronóstico del índice de precios y cotizaciones de la Bolsa Mexicana de Valores*. Facultad de Ingeniería.
- Pasquali, M. (2020). *Contribución al producto interno bruto (PIB) trimestral de las diferentes actividades económicas en México en el segundo trimestre de 2020*. Statista.
- Peña Andrés, C. (2015). *Planificación de ventas y operaciones. S&OP en 14 claves*. Marge Books.
- Peña, J. A. (2021). *Multi-step forecast with Machine Learning algorithms. Comparative study*.
- Pérez, A. (Agosto de 2017). *Planificación de la demanda e inteligencia artificial*. Obtenido de Business School : <https://www.obsbusiness.school/blog/planificacion-de-la-demanda-e-inteligencia-artificial>
- Pinedo Chapa, J. M. (2018). *Propuesta de un modelo de pronósticos de*. Lima, Perú: Universidad Peruana de Ciencias Aplicadas (UPC).
- Porter, M. (1986). *Ventaja Competitiva*. México: Editorial C.E.C.S.A.
- Richter, F. (2020). *These are the top 10 manufacturing countries in the world*. World Economic Forum.
- Rodríguez, E., & Cerecedo, J. (2021). *Modelos predictivos con Machine Learning*. Obtenido de edX - Universidad Anáhuac: <https://courses.edx.org/courses/course-v1:AnahuacX+UVA-CP1-1x+3T2020/course/>
- Romero, O., & Romero, S. (s.f.). *Pronóstico de la Demanda*. Diplomado en Planeación y Dirección de Operaciones. ITAM.
- Rosengren, W., & Gersuny, C. (s.f.). *Los servicios de la división del trabajo de las sociedades modernas. Revista de Estudios Políticos*.
- Ruiz Reina, J. L. (2017). *Evaluación de modelos. Razonamiento asistido por computador*.

- Sahin, M., Kızılaslan, R., & Demirel, Ö. (2013). Forecasting Aviation Spare Parts Demand Using Croston Based Methods and Artificial Neural Networks. *Journal of Economic and Social Research*, 1-21.
- Salazar, A., & Cabrera, M. (2007). *Pronóstico de demanda por medio de redes neuronales artificiales*.
- Santa Cruz, R., & Correa, C. (2017). Intermittent demand forecasting with time series methods and artificial neural networks: A case of study. *Universidad Nacional de Colombia*.
- Schroeder, R., Meyer, S., & Rungtusanatham, J. (2011). *Administración de operaciones*. McGraw-Hill.
- Sintec. (2016). *La guía para la implementación del proceso de S&OP*.
- Sipper, D., & Bulfin, R. (1998). *Planeación y Control de la Producción*. México: McGraw-Hill.
- Syntetos, A. B. (2005). *On the categorization of demand patterns*. Journal of the Operational Research Society.
- uniphyton. (s.f.). *Cómo desarrollar modelos de Deep Learning con Keras*.
- Universidad de Valencia. (s.f.). Obtenido de <https://www.uv.es/frasquem/dci/DirCom1TEMA6.pdf>
- Usuga Cadavid, J., Lamouri, S., & Grabot, B. (2018). Trends in Machine Learning Applied to Demand & Sales: A Review. *Conference on Information Systems, Logistics and Supply Chain*. Lyon, France.
- Vidal Holguín, C. J. (2010). *Fundamentos de control y gestión de inventarios*. Cali, Colombia: Universidad del Valle.
- Zaki, M. J., & Meira, W. J. (2014). *Data Mining and Machine Learning: Fundamental Concepts and Algorithms*. Cambridge University Press.

## Anexos

Anexo 1. Análisis estadístico de la serie de tiempo de ventas del AXML en Jupyter (Código)

	<b>unidades</b>	<b>actualizaciones</b>
<b>count</b>	165.000000	165.000000
<b>mean</b>	2.024242	0.393939
<b>std</b>	4.917554	1.319169
<b>min</b>	0.000000	0.000000
<b>25%</b>	0.000000	0.000000
<b>50%</b>	0.000000	0.000000
<b>75%</b>	2.000000	0.000000
<b>max</b>	37.000000	10.000000

## Anexo 2. Preparación de los datos: transformación de serie de tiempo a problema de aprendizaje supervisado (Código)

Código de la transformación de serie de tiempo a problema de aprendizaje supervisado para el modelo de una variable y multivariable.

Preparación de datos para modelo MLP de una variable:

```
from keras.models import Sequential
from keras.layers import Dense,Activation,Flatten
from sklearn.preprocessing import MinMaxScaler

PASOS= 40

# convert series to supervised learning
def series_to_supervised(data, n_in=1, n_out=1, dropnan=True):
    n_vars = 1 if type(data) is list else data.shape[1]
    df = pd.DataFrame(data)
    cols, names = list(), list()
    # input sequence (t-n, ... t-1)
    for i in range(n_in, 0, -1):
        cols.append(df.shift(i))
        names += [('var%d(t-%d)' % (j+1, i)) for j in range(n_vars)]
    # forecast sequence (t, t+1, ... t+n)
    for i in range(0, n_out):
        cols.append(df.shift(-i))
        if i == 0:
            names += [('var%d(t)' % (j+1)) for j in range(n_vars)]
        else:
            names += [('var%d(t+%d)' % (j+1, i)) for j in range(n_vars)]
    # put it all together
    agg = pd.concat(cols, axis=1)
    agg.columns = names
    # drop rows with NaN values
    if dropnan:
        agg.dropna(inplace=True)
    return agg
```

## Uso del pronóstico de la demanda para proponer un plan de ventas y operaciones en empresas de servicios.

```
# load dataset
values = df.values

#ensure all data is float
values = values.astype('float32')

# normalize features
scaler = MinMaxScaler(feature_range=(-1, 1))
values=values.reshape(-1, 1) # esto lo hacemos porque tenemos 1 sola dimension
scaled = scaler.fit_transform(values)

#datos['scaled'] = scaled
#scaledMerge=datos.drop('unidades',axis=1)

# frame as supervised learning
reframed = series_to_supervised(scaled, PASOS, 1)
reframed.head()
#values
```

	var1(t-40)	var1(t-39)	var1(t-38)	var1(t-37)	var1(t-36)	var1(t-35)	var1(t-34)	var1(t-33)	var1(t-32)	var1(t-31)	...	var1(t-9)	var1(t-8)	var1(t-7)	var1(t-6)
40	0.081081	-1.000000	-1.000000	-1.000000	-0.945946	-1.000000	-1.000000	-1.000000	-1.000000	-0.891892	...	-1.000000	-1.000000	-0.72973	-1.0
41	-1.000000	-1.000000	-1.000000	-0.945946	-1.000000	-1.000000	-1.000000	-1.000000	-0.891892	-1.000000	...	-1.000000	-0.72973	-1.000000	-1.0
42	-1.000000	-1.000000	-0.945946	-1.000000	-1.000000	-1.000000	-1.000000	-0.891892	-1.000000	-0.891892	...	-0.72973	-1.000000	-1.000000	-1.0
43	-1.000000	-0.945946	-1.000000	-1.000000	-1.000000	-1.000000	-0.891892	-1.000000	-0.891892	-1.000000	...	-1.000000	-1.000000	-1.000000	-1.0
44	-0.945946	-1.000000	-1.000000	-1.000000	-1.000000	-0.891892	-1.000000	-0.891892	-1.000000	-1.000000	...	-1.000000	-1.000000	-1.000000	-1.0

5 rows x 41 columns

### Preparación de datos para modelo MLP multivariable:

```
from keras.models import Sequential
from keras.layers import Dense,Activation,Flatten
from sklearn.preprocessing import MinMaxScaler

PASOS= 50

# convert series to supervised learning
def series_to_supervised(data, n_in=1, n_out=1, droppan=True):
    n_vars = 1 if type(data) is list else data.shape[1]
    df = pd.DataFrame(data)
    cols, names = list(), list()
    # input sequence (t-n, ... t-1)
    for i in range(n_in, 0, -1):
        cols.append(df.shift(i))
        names += [('var%d(t-%d)' % (j+1, i)) for j in range(n_vars)]
    # forecast sequence (t, t+1, ... t+n)
    for i in range(0, n_out):
        cols.append(df.shift(-i))
        if i == 0:
            names += [('var%d(t)' % (j+1)) for j in range(n_vars)]
        else:
            names += [('var%d(t+%d)' % (j+1, i)) for j in range(n_vars)]
    # put it all together
    agg = pd.concat(cols, axis=1)
    agg.columns = names
    # drop rows with NaN values
    if droppan:
        agg.dropna(inplace=True)
    return agg
```

## Uso del pronóstico de la demanda para proponer un plan de ventas y operaciones en empresas de servicios.

```
# Load dataset
values = df['unidades'].values

# ensure all data is float
values = values.astype('float32')
# normalize features
scaler = MinMaxScaler(feature_range=(-1, 1))
values=values.reshape(-1, 1)
scaled = scaler.fit_transform(values)

df['scaled'] = scaled
scaledMerge=df.drop('unidades',axis=1)
#print(scaledMerge.values)

# frame as supervised learning
reframed = series_to_supervised(scaledMerge, PASOS, 1)
reframed.head()
```

	var1(t-50)	var2(t-50)	var1(t-49)	var2(t-49)	var1(t-48)	var2(t-48)	var1(t-47)	var2(t-47)	var1(t-46)	var2(t-46)	...	var1(t-4)	var2(t-4)	var1(t-3)
fecha														
2016-12-15	0.0	0.081081	0.0	-1.000000	0.0	-1.000000	0.0	-1.000000	0.0	-0.945946	...	0.0	-1.000000	0.0
2016-12-31	0.0	-1.000000	0.0	-1.000000	0.0	-1.000000	0.0	-0.945946	0.0	-1.000000	...	0.0	-1.000000	0.0
2017-01-15	0.0	-1.000000	0.0	-1.000000	0.0	-0.945946	0.0	-1.000000	0.0	-1.000000	...	0.0	-0.945946	0.0
2017-01-31	0.0	-1.000000	0.0	-0.945946	0.0	-1.000000	0.0	-1.000000	0.0	-1.000000	...	0.0	-1.000000	0.0
2017-02-15	0.0	-0.945946	0.0	-1.000000	0.0	-1.000000	0.0	-1.000000	0.0	-1.000000	...	0.0	-1.000000	0.0

5 rows × 102 columns

### Anexo 3. Creación y compilación de la red neuronal para los modelos MLP de una variable y multivariable (Código)

Para una variable:

```
#Creación del modelo

def crear_modeloFF():
    model = Sequential()
    model.add(Dense(PASOS, input_shape=(1,PASOS),activation='tanh'))
    model.add(Flatten())

    model.add(Dense(1, activation='tanh'))

    model.compile(loss='mean_absolute_error',optimizer='Adam',metrics=["mse"])
    model.summary()
    return model
```

Multivariable:

```
def crear_modeloFF():
    model = Sequential()
    model.add(Dense(PASOS, input_shape=(1,PASOS*2),activation='tanh'))
    model.add(Flatten())
    model.add(Dense(1, activation='tanh'))
    model.compile(loss='mean_absolute_error',optimizer='Adam',metrics=["mse"])
    model.summary()
    return model
```

#### Anexo 4. Ajuste de la red neuronal (Código y resultados)

##### Una variable:

```
#Ver resultado del entrenamiento en 100 épocas
EPOCHS=100

model = crear_modeloFF()

history=model.fit(x_train,y_train,epochs=EPOCHS,validation_data=(x_val,y_val),batch_size=PASOS)
```

---

```
Epoch 1/100
3/3 [=====] - 1s 85ms/step - loss: 0.1950 - mse: 0.1163 - val_loss: 0.0662 - val_mse: 0.0057
Epoch 2/100
3/3 [=====] - 0s 8ms/step - loss: 0.1616 - mse: 0.1165 - val_loss: 0.0464 - val_mse: 0.0033
Epoch 3/100
3/3 [=====] - 0s 8ms/step - loss: 0.1578 - mse: 0.1204 - val_loss: 0.0391 - val_mse: 0.0032
Epoch 4/100
3/3 [=====] - 0s 16ms/step - loss: 0.1571 - mse: 0.1236 - val_loss: 0.0358 - val_mse: 0.0034
Epoch 5/100
3/3 [=====] - 0s 8ms/step - loss: 0.1571 - mse: 0.1251 - val_loss: 0.0341 - val_mse: 0.0035
Epoch 6/100
3/3 [=====] - 0s 16ms/step - loss: 0.1570 - mse: 0.1259 - val_loss: 0.0331 - val_mse: 0.0035
Epoch 7/100
3/3 [=====] - 0s 16ms/step - loss: 0.1570 - mse: 0.1264 - val_loss: 0.0325 - val_mse: 0.0036
Epoch 8/100
3/3 [=====] - 0s 11ms/step - loss: 0.1570 - mse: 0.1268 - val_loss: 0.0321 - val_mse: 0.0036
Epoch 9/100
3/3 [=====] - 0s 16ms/step - loss: 0.1569 - mse: 0.1270 - val_loss: 0.0318 - val_mse: 0.0036
```

##### Multivariable:

```
#Ver resultado del entrenamiento en 100 épocas
EPOCHS=100

model = crear_modeloFF()

history=model.fit(x_train,y_train,epochs=EPOCHS,validation_data=(x_val,y_val),batch_size=PASOS)
```

---

```
Epoch 1/100
2/2 [=====] - 1s 185ms/step - loss: 0.9648 - mse: 1.2013 - val_loss: 0.6742 - val_mse: 0.7153
Epoch 2/100
2/2 [=====] - 0s 31ms/step - loss: 0.6036 - mse: 0.6229 - val_loss: 0.3616 - val_mse: 0.3198
Epoch 3/100
2/2 [=====] - 0s 31ms/step - loss: 0.3895 - mse: 0.3762 - val_loss: 0.2028 - val_mse: 0.1528
Epoch 4/100
2/2 [=====] - 0s 22ms/step - loss: 0.2826 - mse: 0.2408 - val_loss: 0.1220 - val_mse: 0.0673
Epoch 5/100
2/2 [=====] - 0s 31ms/step - loss: 0.2337 - mse: 0.1880 - val_loss: 0.0785 - val_mse: 0.0262
Epoch 6/100
2/2 [=====] - 0s 31ms/step - loss: 0.2010 - mse: 0.1590 - val_loss: 0.0542 - val_mse: 0.0106
Epoch 7/100
2/2 [=====] - 0s 31ms/step - loss: 0.1894 - mse: 0.1544 - val_loss: 0.0402 - val_mse: 0.0051
Epoch 8/100
2/2 [=====] - 0s 31ms/step - loss: 0.1836 - mse: 0.1481 - val_loss: 0.0325 - val_mse: 0.0034
Epoch 9/100
2/2 [=====] - 0s 38ms/step - loss: 0.1800 - mse: 0.1468 - val_loss: 0.0278 - val_mse: 0.0029
```

## Anexo 5. Error de pronóstico de los modelos MLP (Código y resultados)

Código de error de pronóstico de los modelos MLP:

```
from spec_metric import spec

compara = pd.DataFrame(np.array([y_val, [x[0] for x in results]])).transpose()
compara.columns = ['real', 'prediccion']

inverted = scaler.inverse_transform(compara.values)

compara2 = pd.DataFrame(inverted)
compara2.columns = ['real', 'prediccion']
compara2['diferencia'] = compara2['real'] - compara2['prediccion']
MSE = mean_squared_error(compara2['real'], compara2['prediccion'])
MAD = compara2.mad()
SPEC = spec(compara2['real'], compara2['prediccion'])
compara2
```

Visualización de los datos de pronóstico con una variable contra ventas reales:

	Real	MLP una variable	Diferencia
0	0	1	1
1	0	6	6
2	0	1	1
3	0	3	3
4	0	1	1
5	3	0	-3
6	2	1	-1
7	0	1	1
8	2	1	-1
9	4	2	-2
10	0	1	1
11	2	1	-1
12	0	1	1
13	0	1	1
14	0	0	0
15	0	1	1
16	0	1	1
17	0	0	0
18	0	1	1
19	0	0	0
20	0	1	1
21	0	0	0
22	0	0	0
23	2	0	-2
24	0	1	1
25	0	0	0
26	0	0	0
27	0	0	0
28	0	1	1
29	0	0	0
30	1	0	-1
31	1	0	-1

Código del cálculo de error de pronóstico de una variable y resultados:

```
#UNA VARIABLE
MSEu = mean_squared_error(dfu ['Real'], dfu['MLP una variable'])
MADu = dfu .mad()
SPECu = spec(dfu['Real'], dfu['MLP una variable'], a1=0.9, a2=0.1)
```

```
print('SPEC MLP una variable = ', SPECu.round(2))
print('MSE MLP una variable = ', MSEu.round(2))
print('MAD MLP una variable = ', MADu. round(2))
```

```
SPEC MLP una variable = 7.49
MSE MLP una variable = 2.5
MAD MLP una variable = Real 0.80
```

Uso del pronóstico de la demanda para proponer un plan de ventas y operaciones en empresas de servicios.

---

Visualización de los datos de pronóstico multivariable contra ventas reales:

	Real	MLP multivariable	Diferencia
0	0	0	0
1	0	0	0
2	0	12	12
3	0	4	4
4	0	3	3
5	0	0	0
6	0	1	1
7	0	0	0
8	3	11	8
9	2	0	-2
10	0	1	1
11	2	0	-2
12	4	2	-2
13	0	0	0
14	2	0	-2
15	0	10	10
16	0	2	2
17	0	1	1
18	0	1	1
19	0	1	1
20	0	0	0
21	0	1	1
22	0	2	2
23	0	0	0
24	0	0	0
25	0	0	0
26	2	0	-2
27	0	0	0
28	0	0	0
29	0	0	0
30	0	0	0
31	0	0	0
32	0	0	0
33	1	0	-1
34	1	0	-1

Código del cálculo de error de pronóstico multivariable y resultados:

```
#MULTIVARIABLE
from sklearn.metrics import mean_squared_error
from spec_metric import spec

MSEm = mean_squared_error(dfm ['Real'], dfm ['MLP multivariable'])
MADm = dfm .mad()
SPECm = spec(dfm['Real'], dfm['MLP multivariable'], a1=0.9, a2=0.1)

print('SPEC Multivariable = ', SPECm.round(2))
print('MSE Multivariable = ', MSEm.round(2))
print('MAD Multivariable = ', MADm. round(2))

SPEC Multivariable = 33.55
MSE Multivariable = 10.54
MAD Multivariable = Real 0.75
```

#### Anexo 6. Pronóstico de demanda de períodos futuros (Código)

Se muestra el código para el pronóstico tras realizar la preparación de los datos de entrada, tal como se realizó en el Anexo 2.

Pronóstico utilizando el modelo MLP de una variable:

```
def agregarNuevoValor(x_test,nuevoValor):
    for i in range(x_test.shape[2]-1):
        x_test[0][0][i] = x_test[0][0][i+1]
    x_test[0][0][x_test.shape[2]-1]=nuevoValor
    return x_test

results=[]
for i in range(6):
    parcial=model.predict(x_test)
    results.append(parcial[0])
    print(x_test)
    x_test=agregarNuevoValor(x_test,parcial[0])

adimen = [x for x in results]
print(adimen)
inverted = scaler.inverse_transform(adimen)
inverted
```

Pronóstico utilizando el modelo MLP multivariable:

```
def agregarNuevoValor(x_test,nuevoValor):
    for i in range(x_test.shape[2]-1):
        x_test[0][0][i] = x_test[0][0][i+1]
    x_test[0][0][x_test.shape[2]-1]=nuevoValor
    return x_test
```

```
results=[]
for i in range(6):
    parcial=model.predict(x_test)
    results.append(parcial[0])
    print(x_test)
    x_test=agregarNuevoValor(x_test,parcial[0])
```

```
adimen = [x for x in results]
print(adimen)
inverted = scaler.inverse_transform(adimen)
inverted
```

Anexo 7. Error de pronóstico del modelo de SyB (Código y resultados)

Error de pronóstico del modelo de SyB:

```
from spec_metric import spec
SPEC = spec(df['real'], df ['pronostico SyB'], a1=0.9, a2=0.1)

print('SPEC S&B = ', SPEC.round(2))

SPEC S&B = 26.11
```

Error de pronóstico del modelo de SyB con 40 periodos de prueba:

```
SPEC = spec(df['Real'], df ['Pronostico SyB40'], a1=0.9, a2=0.1)
print('SPEC SyB40 = ', SPEC.round(2))

SPEC SyB40 = 26.11
```

Anexo 8. Estrategia de marketing

Tabla 17. Estrategias de Marketing

Estrategias de Marketing	
Método	Descripción
Video Marketing	<p>Realizar un video explicación del AXML y comprar una campaña de Facebook para que sea promocionado en las redes de las personas cuyos intereses contengan: facturación, SAT y sus características coincidan con un perfil de contador o administrativo.</p> <p>Esto es posible gracias a que Facebook permite elegir estas características y colocar el anuncio a las personas que es más probable que estén interesadas.</p>
Google Ads	<p>Realizar una campaña en Google para posicionar la página de la empresa en los primeros lugares de las páginas que muestra el buscador. Para esto es importante elegir las palabras adecuadas para garantizar que los usuarios hallen la página, además de economizar en esta tarea.</p> <p>Las palabras clave las cuales pueden ser: software, facturación, la combinación de estas y la combinación de software con SAT y XML.</p>
Blog	<p>Crear un blog en la página de Softing el cual sea informativo y llame la atención de los clientes. Para esto pueden tocarse temas sobre facturación, noticias sobre actualizaciones en el SAT, información sobre nuevas tecnologías que son utilizadas en esta área, el funcionamiento y ventajas de los productos de Softing y muestre nuevas soluciones. Con esto se puede crear una comunidad y con el paso del tiempo, colabore con la fidelización de clientes.</p>

**Fuente:** Elaboración propia

Uso del pronóstico de la demanda para proponer un plan de ventas y operaciones en empresas de servicios.

Anexo 9. Plantillas de entregables de la reunión Financiera

Plantilla para revisión financiera de RH e Inversiones:

Recursos Humanos				Inversiones				
	Sueldos Mensual	Número de colaboradores			Inversiones	1	2	3
Departamento	Sueldo por persona	1	2	3				
Operaciones	\$ -				Investigación y desarrollo	\$ -	\$ -	\$ -
Ventas	\$ -				Propiedad industrial / intelectual	\$ -	\$ -	\$ -
Administrativos	\$ -				Licencias para desarrollo de programación	\$ -	\$ -	\$ -
Otros	\$ -				Equipo	\$ -	\$ -	\$ -
	Incremento salarial		(%)	(%)	<b>TOTAL</b>	\$ -	\$ -	\$ -
Gasto salarios y seguros sociales								
Departamento	1	2	3					
Operaciones	\$ -	\$ -	\$ -					
Ventas	\$ -	\$ -	\$ -					
Administrativos	\$ -	\$ -	\$ -					
Otros	\$ -	\$ -	\$ -					
<b>TOTAL</b>	\$ -	\$ -	\$ -					

Plantilla para revisión financiera de Costos fijos y variables:

Costos fijos				Costos variables			
Concepto	1	2	3	Concepto	1	2	3
Electricidad	\$ -	\$ -	\$ -	Gastos comerciales variables (marketing)	\$ -	\$ -	\$ -
Internet	\$ -	\$ -	\$ -	Comisiones por ventas	\$ -	\$ -	\$ -
Salarios	\$ -	\$ -	\$ -	Materiales, reparaciones de equipos	\$ -	\$ -	\$ -
Seguros	\$ -	\$ -	\$ -	<b>TOTAL</b>	\$ -	\$ -	\$ -
Página web	\$ -	\$ -	\$ -				
Traslados/gasolina	\$ -	\$ -	\$ -				
Papelería	\$ -	\$ -	\$ -				
Marketing*	\$ -	\$ -	\$ -				
Mantenimiento	\$ -	\$ -	\$ -				
<b>TOTAL</b>	\$ -	\$ -	\$ -				

Uso del pronóstico de la demanda para proponer un plan de ventas y operaciones en empresas de servicios.

Plantilla para revisión financiera del Balance General:

<b>BALANCE GENERAL</b>			
Softing			
Al 31 de septiembre de 2019			
ACTIVO		PASIVO	
<b>Activo corriente</b>		<b>Pasivo corriente</b>	
Efectivo	\$ -	Cuentas por pagar	\$ -
Cuentas por cobrar	\$ -	Prestamos	\$ -
Pagos anticipados	\$ -	Salarios	\$ -
Inversiones	\$ -	<b>TOTAL PASIVO CORRIENTE</b>	\$ -
<b>TOTAL DE ACTIVO CORRIENTE</b>	\$ -		
<b>Activo no corriente</b>		<b>Pasivo no corriente</b>	
Bonos de empresas	\$ -	Obligaciones comerciales	\$ -
Mobiliario	\$ -	Obligaciones a largo plazo	\$ -
Equipo	\$ -	<b>TOTAL PASIVO NO CORRIENTE</b>	\$ -
<b>TOTAL DE ACTIVO NO CORRIENTE</b>	\$ -		
		<b>PATRIMONIO</b>	\$ -
		Capital social	\$ -
		Utilidades retenidas	\$ -
		<b>TOTAL PATRIMONIO</b>	\$ -
			\$ -
<b>TOTAL ACTIVO</b>	\$ -	<b>TOTAL PASIVO Y PATRIMONIO</b>	\$ -

Plantilla para revisión financiera del Estado de Resultados:

<b>Estado de resultados</b>			
Softing			
Al 31 de diciembre de 2019			
	oct-19	nov-19	dic-19
<b>Ingresos operacionales</b>			
Ventas y servicios			
Devoluciones en ventas			
<b>Total ingresos operacionales</b>			
<b>Costo de ventas</b>			
Costo de servicios			
Costo de productos			
<b>Total Costo de Ventas</b>			
<b>UTILIDAD BRUTA</b>			
<b>Gastos operacionales</b>			
Gastos administrativos			
Gastos de venta			
Provisiones			
Total de Gastos Operacionales			
<b>UTILIDAD OPERACIONAL</b>			
<b>Ingresos no Operacionales</b>			
Financieros			
Otros ingresos			
<b>TOTAL INGRESOS NO OPERACIONALES</b>			

Anexo 10. Acta de reunión S&OP

## Acta de reunión

### Llamada al orden

Se ha celebrado una reunión de **Softing** en **[Ubicación]** el **[fecha]**.

### Asistentes

Asistentes incluidos:

Área	Responsable	Firma

### Aprobación de las actas y conclusiones

\*Comentarios o conclusiones de la reunión.

**Aprobación de actas por:** \_\_\_\_\_

### Asuntos pendientes

- Nuevo asunto
- Nuevo asunto

### Nuevos asuntos

- Nuevo asunto
- Nuevo asunto

### Anuncios

Cambios o anuncios para considerar en las siguientes juntas.

\_\_\_\_\_  
Director general

\_\_\_\_\_  
Fecha de aprobación