



Universidad de
San Andrés

Escuela de Negocios

Licenciatura en Administración de Empresas

Inteligencia Artificial aplicada a los negocios:
modelado predictivo de ventas y necesidad de
insumos productivos en la empresa TN&Platex

Alumno: José Francisco Lopez

Mentor: Roberto Bunge

30 de diciembre de 2022

ABSTRACT	4
CAPÍTULO 1: INTRODUCCIÓN	5
1.1 Introducción y justificación	5
1.1.1 Descripción de la empresa TN & Platex	5
1.1.2 Descripción del proceso productivo de hilado	7
1.1.3 Áreas de la empresa donde se puede aplicar Inteligencia Artificial	9
1.1.4 Ranking de factibilidad e impacto de cada proyecto	11
1.1.5 Problema seleccionado a resolver	12
1.1.5 Proceso de ingreso de pedidos	15
1.2 Problemática	16
1.3 Preguntas de investigación	19
1.4 Objetivos	20
1.5 Metodología	20
CAPÍTULO 2 - MARCO TEÓRICO	22
2.1 Impacto de la Inteligencia Artificial aplicada en las empresas	22
2.2 Administración de inventarios	22
2.3 Analytics en el mundo empresarial: ML como arma de vanguardia	24
CAPÍTULO 3 - MODELADO PREDICTIVO	29
3.1 Estrategia de modelado	29
3.2 Visualización y análisis de datos	31
3.3 Obtención, curado y transformación de datos	38
3.3.1 Recolección y curado de los datos	38
3.3.1.1 Datos internos	38
3.3.1.2 Datos externos	39
3.3.2 Procesamiento de los datos	40
3.3.3 Dataset final	44
3.4 Modelado autorregresivo: ARIMA	45
3.5 Modelado con deep learning: modelo de red neuronal MLP	53
3.6 Modelado con deep learning: modelo de red neuronal LSTM	61
3.7 Estimación de la proporción de cada hilado del total	65
3.8 Fórmulas de insumos productivos por artículo	68
CAPÍTULO 4 - ANÁLISIS Y RESULTADOS FINALES	72
4.1 Análisis de resultados obtenidos en los modelos de predicción	72
4.2 Predicción de necesidad de insumos para Noviembre 2022	73
4.3 Resultado final	76
CAPÍTULO 5 - CONCLUSIONES Y TRABAJO A FUTURO	79
5.1 Repaso de impacto de implementar ML	79
5.2 Resultados obtenidos y mejoras	80
5.3 Impacto del trabajo en la empresa	81



Universidad de
San Andrés

ABSTRACT

La inteligencia artificial hace años introdujo en el contexto empresarial una oportunidad de adopción de distintas herramientas que pueden ayudar a hacer los procesos más eficientes, mediante la toma de decisiones basadas en datos. En este contexto, la empresa TN & Platex se sumerge en un cambio de mentalidad empresarial para poder crear valor en sus procesos y adaptarse rápidamente a las necesidades del mercado.

En el presente trabajo, se plantea una problemática actual de la empresa que consiste en predecir la necesidad futura de insumos productivos. Para resolver este problema, se define una estrategia para atacar el problema en dos partes. Por un lado, se trabaja en el modelado predictivo utilizando distintos algoritmos para predecir el total de pedidos que ingresarán en el futuro. Luego, se estima una proporción del total que corresponde a cada artículo seleccionado. De esta manera, se puede obtener la necesidad de insumos productivos futuros y llevar a cabo acciones que optimicen el stock físico, el planeamiento de la producción y una mejor manera de destinar la capacidad financiera de la empresa.

A lo largo del estudio, se entrenan modelos predictivos clásicos como ser el modelo ARIMA, y también modelos de *deep learning* como lo son las redes neuronales MLP y LSTM. Luego de entrenar los modelos diseñados, se comparan los errores que tienen los modelos de predicción, y se concluye en que utilizar un modelo LSTM presenta un 3% de error esperado mensual. Se demuestra que utilizar este modelo, puede generar un ahorro de más de \$15 millones de pesos en la compra de insumos productivos.

TN & Platex detecta problemáticas que pueden ser solucionadas con las herramientas que brinda la Inteligencia Artificial, y se propone avanzar en este camino innovador para destinar sus recursos, tanto humanos como económicos, de manera más eficiente.

Palabras clave: negocios, industria textil, inventarios, datos, transformación digital, inteligencia artificial, machine learning.

CAPÍTULO 1: INTRODUCCIÓN

1.1 Introducción y justificación

1.1.1 Descripción de la empresa TN & Platex

Este trabajo surge como la búsqueda de una solución a una de las problemáticas que atraviesa la empresa TN & Platex en su etapa de crecimiento y desarrollo, en la cual busca crear valor en sus procesos, tanto productivos como de negocios, a partir del análisis y la ciencia de datos.

TN & Platex es una empresa textil nacida en 1979 con poca capacidad productiva en la ciudad de Monte Caseros, provincia de Corrientes. En sus inicios, la empresa sólo podía producir 150.000 kilos de hilado por mes, La empresa actualmente produce artículos de hilados y tejidos, y se convirtió en una empresa líder en la industria del país y de Sudamérica. La empresa cuenta con 11 fábricas en 6 provincias de Argentina, y más de 1200 trabajadores según su propia página web (<https://tnplatex.com/>). Las 11 fábricas están compuestas por 6 hilanderías, 3 tejedurías, 1 fábrica de medias y prendas, y 1 fábrica de barbijos sanitarios. TN & Platex tiene plantas ubicadas 1 en Monte Caseros, 1 en Catamarca, 2 en La Rioja y 2 en Tucumán.

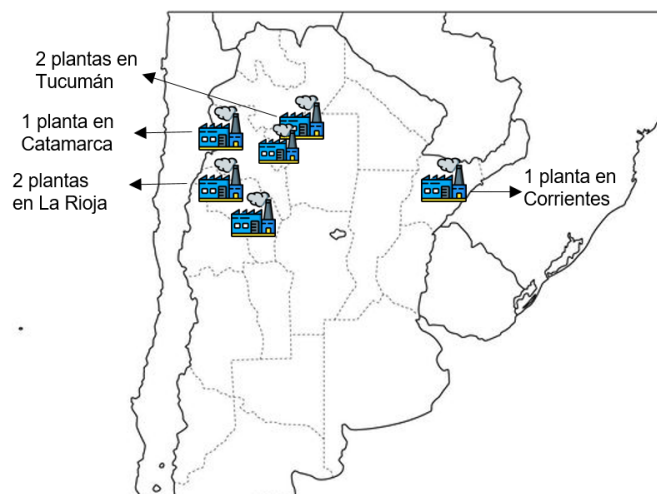


Figura 1: Representación de las plantas en mapa de Argentina. Fuente de elaboración propia.

Si bien al principio solo producía hilados, la empresa buscó diversificar sus unidades de negocio. En este sentido, TN & Platex decide en 2015 comprar la reconocida marca de medias “Ciudadela”, nacida en 1949. De esta manera, TN & Platex se aseguraba estar en todo el proceso productivo de Ciudadela, dado que la fabricación de medias y prendas se harían con los hilados de TN & Platex.

Además, en 2016 TN & Platex comienza con la producción de tejidos, con el deseo de ganar participación en este mercado mediante la inversión en máquinas de última generación. En esta unidad de negocio, la empresa busca comercializar productos tejidos clásicos y productos diferenciados ligados a la necesidad de las últimas tendencias en moda.

Por último, a causa de la pandemia que inició en 2020, se decide crear la unidad de negocios de barbijo, para satisfacer las necesidades sanitarias del país en ese momento. Si bien cumplió con su objetivo durante la pandemia, actualmente continúa activa esta unidad en camino hacia aumentar la oferta y consolidarse en este rubro.

La empresa ofrece distintas variedades de artículos que luego terminan en la creación de todo tipo de productos, como por ejemplo vestimenta (pantalones, buzos, remeras, medias), guantes, neumáticos, colchones, ropa de cama, velas, gasas, trapos de piso, rejillas de cocina, etc.

Las variedades del hilado que comercializa TN & Platex dependen del grosor, la materia prima, la tecnología empleada en la producción, y las distintas mezclas utilizadas. Mientras que en los tejidos, se diferencian principalmente en la materia prima utilizada en su producción.

En relación al contexto de la empresa en el mercado, en la industria textil es muy importante el capital productivo para poder competir, y el capital financiero para invertir constantemente en capacidad productiva. Según menciona Denis

B., jefe del área de inteligencia aplicada de TN & Platex, actualmente del mercado de hilandería la empresa aproximadamente participa en un 30%, mientras que en el mercado de los tejidos lo hace con un 25%. El mercado textil es un mercado muy concentrado, dado que las empresas necesitan millones de dólares para invertir en hilandería, y en los recursos que se necesitan.

De esta manera, se entiende que TN & Platex tiene un papel muy importante en la confección de muchos artículos que una persona consume o utiliza en el día a día, como así también en el consumo directo de las personas (medias y prendas). Por lo tanto, se puede mencionar que la empresa para llegar a su producto final cuenta con distintos procesos que deben ser cumplidos de la mejor manera para lograr su objetivo comercial. Estos procesos pueden describirse como productivos, administrativos, comerciales, de negocios, etc.

1.1.2 Descripción del proceso productivo de hilado

El proceso de hilado dentro de la empresa, depende de la tecnología que se utilice en el hilado a producir.

La materia prima principal en la producción de hilado es el algodón. Las fibras de algodón son procesadas en distintas máquinas para obtener el hilado como se conoce. Además, la empresa utiliza otras materias primas como por ejemplo: poliéster, lycra, viscosa, acrílico, lino.

TN & Platex cuenta con 3 tecnologías de hilados posibles: Hilado Open End, Hilado Cardado e Hilado Peinado.

El hilado open end se obtiene a través del proceso open end, el cual convierte cintas de algodón en hilado. Este hilado es el más rústico, simple, y tiene alto nivel de producción.

El hilado cardado es un poco más procesado que el hilado open end, dado que al principio de su proceso la fibra de algodón es introducida en un tipo de máquina que elimina las fibras cortas y además, alinea todas las fibras para unificar el algodón en cuanto a grosor.

El hilado peinado es el más sofisticado de los 3, dado que elimina todo tipo de fibras cortas, medianas e impurezas para obtener un producto de mayor calidad, más resistente y de mayor suavidad.

En cada proceso productivo, pueden incluirse las siguientes máquinas:

- Cardas: en estas máquinas se limpia el algodón y se empieza a dar forma.
- Manuar: en esta máquina se vuelve a limpiar el algodón y se lo convierte en citas.
- Reunidora de cinta: esta máquina unifica las cintas generadas.
- Mechera: en esta máquina se convierte las cintas en un cuasi hilado.
- Open End: en esta máquina se ingresa cintas y sale hilado.
- Continuas: en esta máquina se utiliza el cuasi hilado que sale de la máquina mecheras y lo convierte en hilado.
- Peinadoras: con las cintas que salen de la máquina reunidora de cintas, realiza un proceso de limpieza y unificación de las cintas.
- Enconadora: el hilado se enrolla en un cono.
- Bobina: el hilado se enrolla en un tubo.

Cada tecnología, cuenta con distintas máquinas en el proceso productivo:

- Hilado open end: las fibras de algodón ingresan la máquina de cardas, luego por la máquina manuar, al salir de ahí ingresan a la máquina open end y por último a la bobina.

- Hilado cardado: las fibras de algodón ingresan la máquina de cardas, luego por la máquina manual, en este caso vuelva a pasar por una segunda máquina de manual, en siguiente lugar pasa por la máquina mechera, al salir ingresa a la máquina de continuas y por último pasa por la máquina de encolado.
- Hilado peinado: las fibras de algodón ingresan la máquina de cardas, luego por la máquina manual, en este punto pasan por la máquina reunidora de cintas, luego por peinadora, en siguiente lugar pasa por la máquina mechera, luego continuas y termina en enconado.

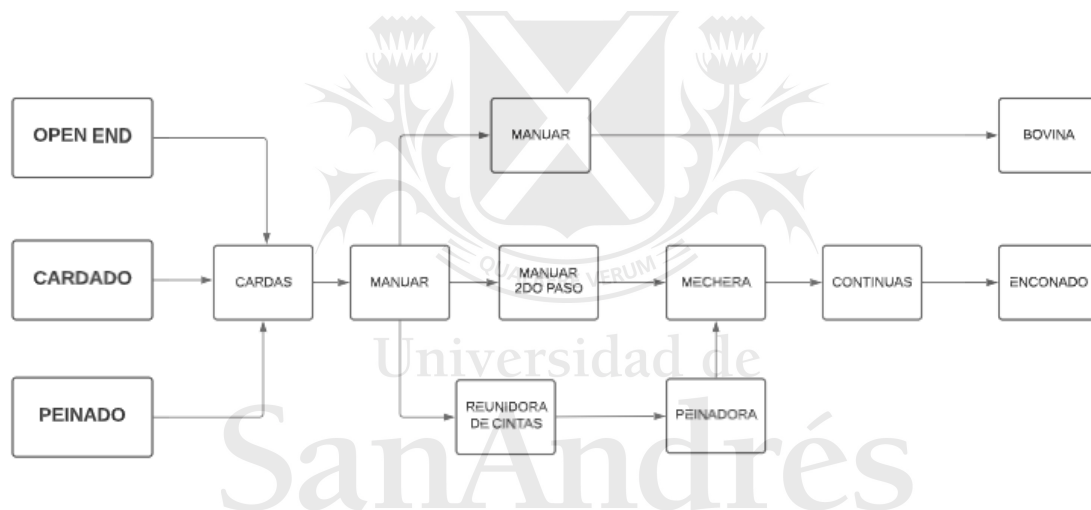


Figura 2. Proceso productivo de hilado en TN & Platex. Fuente de elaboración propia a partir de entrevistas informales en la empresa.

1.1.3 Áreas de la empresa donde se puede aplicar Inteligencia Artificial

La empresa actualmente está en un proceso de convertirse en una “Data Company Industrial”, tal como mencionan en su sitio web (<https://tnplatex.com/>). Para este objetivo, TN & Platex cuenta con datos

históricos pero además, está implementando nuevas tecnologías para obtener datos de las máquinas de producción, de atributos del clima dentro de la planta, datos de clientes, entre otras.

Por lo tanto, existen muchas áreas de la empresa donde se podría aplicar IA actualmente:

- Segmentación de clientes: se podría utilizar machine learning para clusterizar los clientes y de esta manera ofrecer un trato distinto a cada segmento, y accionar comercialmente.
- Predicción de abandono: en base a la historia de los clientes que dejaron de comprar y los que siguen vigentes, se puede diseñar un modelo de clasificación para predecir la probabilidad de que un cliente abandone la empresa en base a distintas variables.
- Recomendación de producto: teniendo en cuenta distintas variables de los clientes, como artículos comprados, tamaño del cliente, ubicación, etc., en base a la similitud de los clientes se puede utilizar un algoritmo de recomendación para aumentar las ventas.
- Detección de fallas en los artículos: al final del proceso de producción, una persona analiza cada producto terminado para revisar que no tenga manchas, cortes, o algún otro defecto que se puede generar en la producción. Se puede utilizar visión computacional para detectar qué productos tienen fallas y de esta manera automatizar esta tarea.
- Predicción de necesidades de repuestos de máquinas: usando datos productivos de las máquinas y datos de inventario de los repuestos utilizados en maquinaria, se puede buscar predecir la necesidad de repuestos en determinado momento del tiempo.
- Predicción de necesidades de insumos productivos: se puede intentar predecir con algoritmos de machine learning, que cantidad de insumos

productivos se necesitan en determinado momento del tiempo para cumplir con la demanda de pedidos de artículos de hilado.

1.1.4 Ranking de factibilidad e impacto de cada proyecto

A continuación, se ordenarán los proyectos mencionados en el ítem anterior, en base a la posibilidad de cumplirlo y el impacto que generará dentro de la empresa.

1. Predicción de necesidades de insumos productivos: este proyecto es muy factible de concretarse, dado que se cuentan con datos históricos de ventas de artículos que utilizan estos insumos productivos de 2005, y además se cuenta con la base de datos de compras de 2014 en adelante. En relación al impacto que puede generar, se considera que es importante la posibilidad de liberar recursos económicos si se realiza una compra de insumos productivos óptima en base a las necesidades, como así también para la liberación de recurso humano abocado a esta tarea actualmente.
2. Predicción de abandono: este proyecto tiene posibilidades de concretarse dado que se cuentan con datos de ventas, pedidos, pero no existen actualmente otros datos que representen al cliente, como por ejemplo: tamaño del cliente, rubro del cliente, ubicación, etc. En cuanto al impacto que puede generar, sería útil para poder accionar con los clientes que tienen probabilidad de abandonar la compra y de esta manera reducir la tasa de abandono.
3. Predicción de necesidades de repuestos de máquinas: este proyecto generaría mucho impacto dentro de TN & Platex, dado que se podría predecir en qué momento una máquina puede tener una falla. Actualmente, se cuentan con datos de inventarios y de compras de repuestos, pero no son lo suficientemente confiables en todo el historial. Además, actualmente se están tomando datos en tiempo real de las máquinas en cuanto a kg producidos, eficiencia, paros de la máquina, y

otras variables que son importantes para este punto. Por lo tanto, en un futuro será posible encarar este proyecto.

4. Segmentación de clientes: este proyecto podría ocasionar un impacto en el trato hacia los clientes, lo cual sería importante para destinar de manera más eficiente los recursos de la empresa. Sin embargo, a pesar de contar con datos de ventas históricos por cliente, no se cuenta con variables representativas del cliente que serían útiles.
5. Recomendación de producto: al igual que los proyectos de Predicción de abandono y Segmentación de clientes, no se cuenta con los datos suficientes para diseñar un modelo de predicción. En relación al impacto que tendría, sería de ayuda para que los vendedores de TN & Platex puedan armar carteras de productos para cada cliente.
6. Detección de fallas en los artículos: aplicar IA en este problema sería el proyecto que mayor impacto generaría en la empresa. Sin embargo, actualmente existe una computadora que genera estos datos a través de una cámara pero no se están almacenando en una base de datos. Por lo tanto, una vez que se empiece a guardar estos datos se podrá comenzar a desarrollar este proyecto.

1.1.5 Problema seleccionado a resolver

En este caso en particular, nos enfocaremos en estudiar la manera de hacer más eficiente los procesos de compras de insumos productivos, como así también su posterior gestión de inventarios, mediante algoritmos de *machine learning*, una rama de Inteligencia Artificial que se explicara en los siguientes capítulos. Estos productos en los cuales nos centraremos son los siguientes: insumos productivos (tubos, cajas, y demás insumos de empaque). En una entrevista informal realizada en la empresa, Ricardo C., gerente de planificación, explica que “un tubo es el insumo en donde se enrolla el hilo para

su posterior empaque, luego en una caja se colocan N cantidad de tubos para luego despachar desde las plantas de producción a los depósitos de donde salen los pedidos hacia los clientes”. En la siguiente imagen, se muestra lo que es un tubo (rosa) y como es enrollado el hilado en el mismo.



Figura 3. El tubo es un insumo productivo importante para la cadena de producción, dado que es donde se enrolla el hilado para luego poder distribuirlo. Fuente: Sitio Web TN & Platex.

<https://tnplatex.com/es/articulos-y-usos/>

Actualmente, dentro de la empresa se generan momentos complicados relacionados a la toma de decisiones, debido a la falta de stock de ciertos insumos productos a la hora de producir sus productos (hilados).

Además, otro factor importante a tener en cuenta es la capacidad financiera con la que cuenta la empresa en el necesario momento de reponer stock de insumos productivos. Denis B., jefe del área de inteligencia aplicada de TN&Platex, argumenta que el tema financiero es determinante en este punto porque el dinero que se utiliza para realizar las compras de insumos productivos podría ser destinado a otras cuestiones si esta compra se realiza de manera óptima, por lo tanto, es vital para la empresa basarse en los datos para la toma de decisiones y realizar una compra más eficiente en el momento determinado y poder asignar sus recursos de la mejor forma.

Dada las situaciones expuestas, la necesidad por parte de la empresa y la clara justificación de este trabajo es poder modelar problemas reales importantes para la organización, y resolverlos utilizando las herramientas que ofrece la ciencia de datos para poder obtener un respaldo a las decisiones que toman las personas, las cuales estarán basadas en los datos generados en el pasado. En tiempos de constante evolución a nivel de tecnología, poder automatizar procesos es importante para hacer más eficiente las tareas de toda la empresa y liberar recursos que pueden ser destinados a otras tareas no menos importantes.

En el presente trabajo, se buscará explotar los datos internos de la empresa TN & Platex, como así también datos externos, para poder darle una solución a los problemas descritos. La manera de explotar dichos datos, será a través de la implementación de modelos predictivos y algoritmos de optimización y simulación, lo cual es razón también de este trabajo, que pretende presentar la importancia en el momento actual en las empresas de tomar decisiones apoyadas en datos. Los datos tanto internos como externos que rodean a TN & Platex puestos en contexto proporcionan información valiosa sobre el comportamiento de los clientes, los patrones de consumo, los desafíos y

oportunidades del mercado, y mucho más. Al utilizar esta información, la empresa puede tomar decisiones acertadas y estratégicas que le permitan adaptarse rápidamente a conseguir los objetivos planteados.

En la actualidad del mundo de los negocios, las empresas deben tomar decisiones precisas y rápidas constantemente dado el alto nivel de competitividad y dinamismo que existe para poder aprovechar las oportunidades del mercado y mantenerse a la altura de las necesidades. Una manera de lograr este constante cambio, es convertirse en empresas data drivers, es decir, organizaciones que toman decisiones basadas en el análisis de datos como complemento a la intuición de las personas o la experiencia que se posee en el negocio. Utilizar los datos para tomar decisiones no significa desplazar al expertise del recurso humano que posee una empresa, sino más bien complementar y brindar un sostén a estas decisiones, para lograr mayor efectividad en la resolución de los problemas que se pueden generar en la dirección de una empresa.

1.1.5 Proceso de ingreso de pedidos

Los datos de pedidos de artículos de hilado que comercializa TN & Platex se generan de la siguiente manera:

1. Un cliente se contacta con un vendedor de la empresa, para realizar un pedido de N artículos y X cantidad de kilos de cada artículo.
2. El vendedor analiza la disponibilidad de cada artículo en el stock actual y posible futuro dado el programa de producción.
3. El vendedor y el cliente negocian las X cantidades y precios, y se define una fecha de entrega que propone el cliente. En este punto, interactúan el área comercial, el área de ventas y el sector de producción.
4. Luego, el vendedor carga en la base de datos las características del pedido.

1.2 Problemática

Por una parte, los insumos productivos afectan de manera directa en la cadena de producción. Para que este proceso sea eficiente, tienen que interactuar 3 áreas conjuntamente: producción en planta y el programador de la producción, almacén en planta, y el sector de compras. Si el sector de almacén en planta no solicita los insumos productivos de los cuales no hay demasiado stock porque esos determinados artículos hilados que utilizan estos insumos productivos no están en producción actualmente, cuando el programador de la producción decide volver a producir esos artículos hilados, se encuentran con la dificultad de cumplir la demanda debido a que faltan insumos productivos.

Para ese entonces, el sector de compras no puede acelerar el proceso de compras de esos insumos productivos, por lo cual existen problemas en la cadena de producción de hilados.

En este caso, la solución actual es usar otro tubo, pero ahí existe un problema posterior a la producción, porque este insumo productivo que se decide utilizar va a estar siendo usado por dos tipos de artículos, y eso confunde tanto a la hora del empaque como a los clientes que ya están acostumbrados a la relación color/tamaño de tubo con un artículo.

Lo mismo sucede con las cajas que se utilizan para la distribución de los artículos hilados. Las cajas son de diferentes tamaños y hay artículos que usan determinadas cajas de empaque en particular, y si no hay en stock ese insumo, también es una complicación.

En este caso puntual, se parte desde la necesidad de automatizar el proceso de compra y la administración del stock de los artículos de insumos productivos dado que la producción de hilado impacta de lleno en los insumos productivos que se utilizan para producir.

Actualmente, en TN&Platex el proceso de compra se realiza de la siguiente manera:

- i. Inicia el pedido con un **requerimiento** de X cantidad de artículos por parte de las fábricas.
- ii. Los artículos requeridos pertenecen a un rubro determinado, para el cual lo toma el **comprador** que tiene asignado ese rubro.
- iii. Luego, el **comprador** identifica proveedores para esos artículos (hay rubros para los cuales ya están determinados ciertos proveedores y otros que no).
- iv. Identificado el **proveedor, cantidad y precio**, el **comprador** efectúa la compra.
- v. Luego se produce el **envío** desde el proveedor a la planta de depósito.
- vi. De la planta de depósito, se envía finalmente a la planta que requería el insumo productivo.

El Departamento de Compras de la empresa argumenta que este proceso de compra tiene una demora mayor a 30 días. Lo cual es un problema si la planta necesita con urgencia un cierto producto. También es un tema importante el análisis de los proveedores, existencias de stocks, precios, costos de envíos y tiempos de envíos.

Por parte de la TN & Platex, actualmente no hay un criterio o una política definida de compra, por lo que se supone que es subóptima la compra que se hace.

Con respecto a la gestión del stock en planta, es importante tener en cuenta factores como: la producción, el tiempo que puede ser almacenado un artículo, la cantidad de artículos que caben en el almacén, entre otros.

Si miramos resumidamente como es el proceso de negocio de la empresa TN & Platex en el siguiente diagrama, se puede observar que el problema

planteado en este trabajo tiene una notable importancia para poder satisfacer las necesidades del negocio.

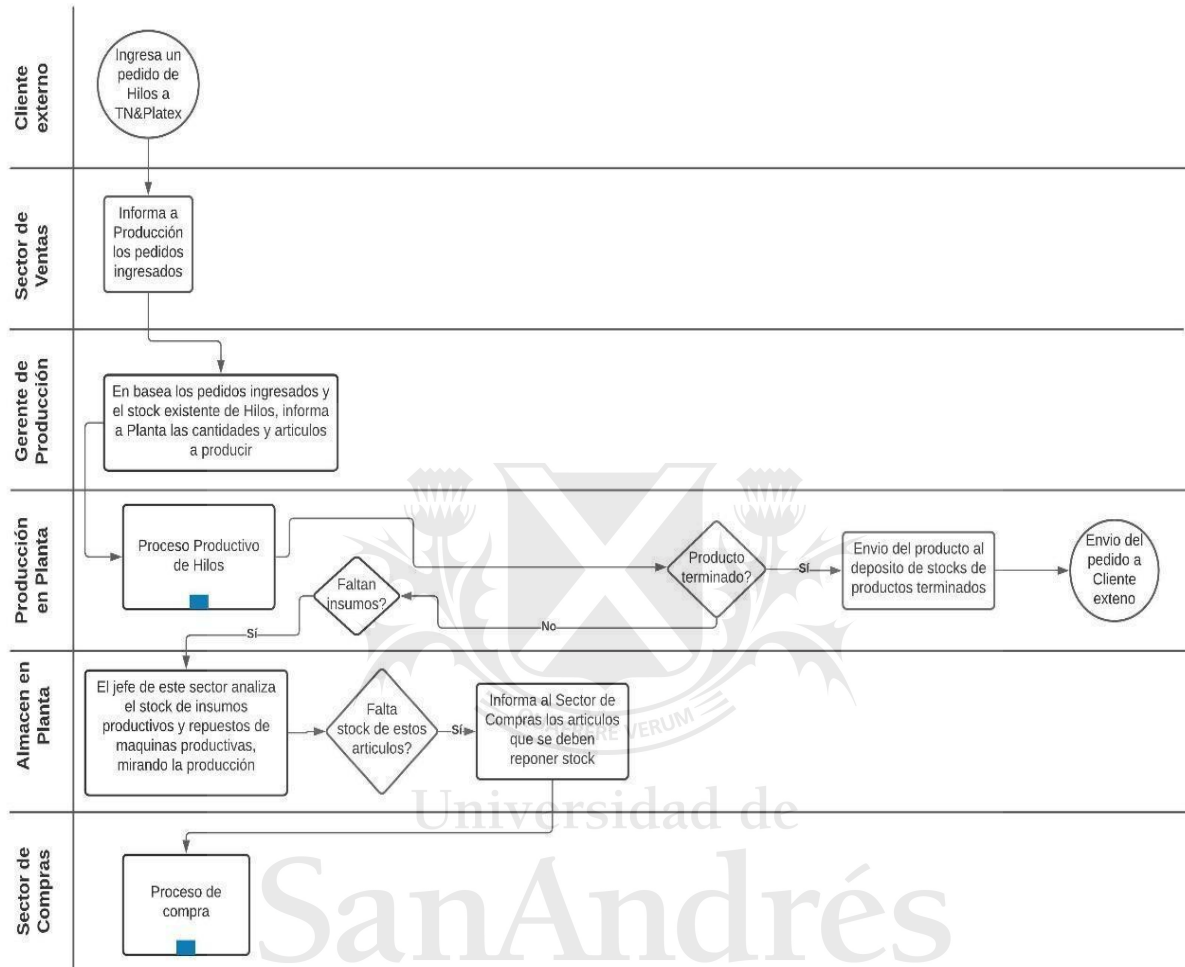


Figura 4. Proceso de negocio de TN & Platex. Fuente de elaboración propia.

El problema particularmente se da en los procesos que relacionan a Producción, Planta y Compras, que es allí donde se hará foco para entender y resolver tal problema. En la siguiente imagen, se remarca los procesos del diagrama del negocio en donde interactúan estas tres áreas:

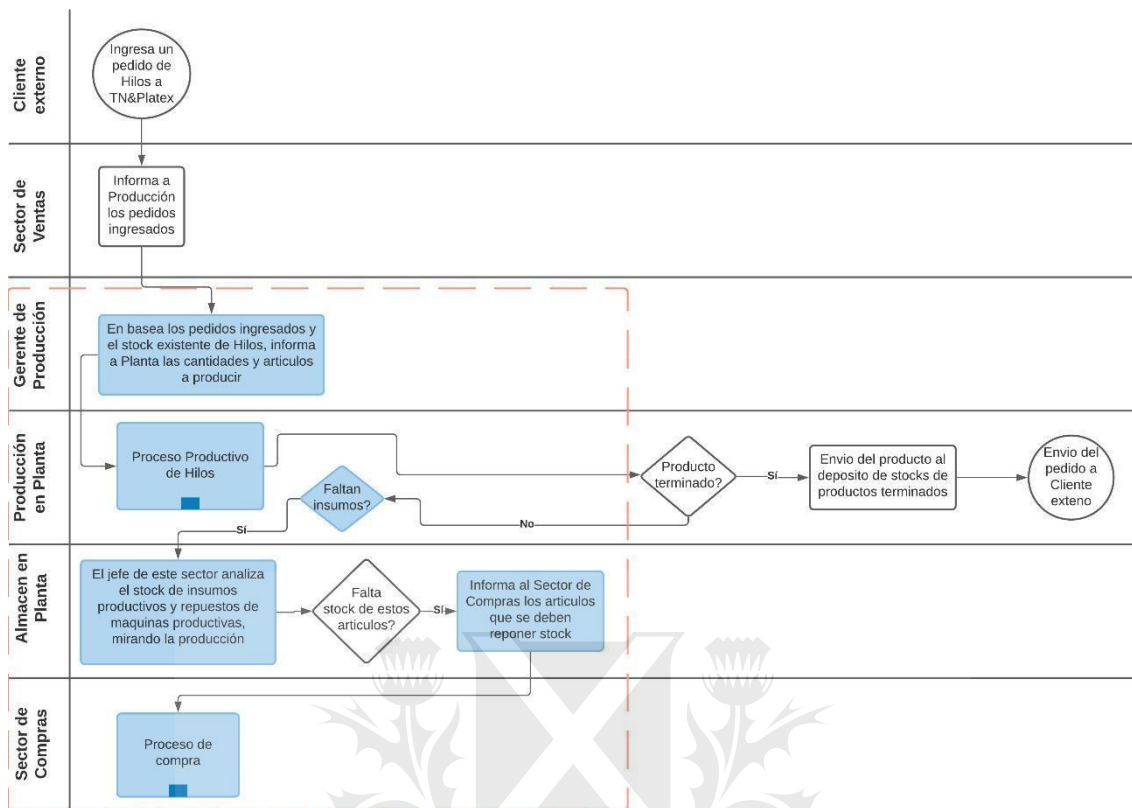


Figura 5. Procesos del negocio donde interactúan Producción, Planta y Compras. Fuente de elaboración propia.

1.3 Preguntas de investigación

- ¿De qué manera podemos automatizar y hacer más eficiente la gestión de compras e inventario en la empresa TN & Platex?
- ¿Es posible poder predecir cómo será la necesidad de insumos productivos en el futuro, utilizando algoritmos de Machine Learning?
- ¿Qué impacto tendrá el uso de un algoritmo para establecer una política de compras óptima de los artículos de insumos productivos?

1.4 Objetivos

Objetivo principal

Diseñar un modelo predictivo y algoritmos de optimización que funcionen como soporte para los departamentos de Producción, Almacén en Planta, y Compras de TN&Platex, los cuales sirvan para ayudar a tomar una decisión a la hora de comprar insumos productivos y lograr una manera más eficiente de gestionar el stock. Se buscará desarrollar un modelo predictivo para estimar la producción de la planta en una ventana de tiempo futuro (t). Como variables *inputs*, se tiene el comportamiento de los clientes en los periodos anteriores a t , que son los pedidos ingresados y facturación de hilado. Como así también se buscará alimentar el modelo de variables políticas y económicas correlacionadas con el nivel de actividad y expectativas futuras de la economía, las cuales se presume que impactan en las ventas, por ende, en la producción de la empresa. La salida de este modelo será artículos y cantidades de tales artículos a producir en el periodo t . Una vez que se logra predecir qué productos de hilos y que cantidades se producirán, se puede determinar por ejemplo qué cantidad de insumos se necesitarán tener en stock en el momento t .

1.5 Metodología

Caso de estudio

Este trabajo está orientado particularmente a brindar una solución en la empresa TN & Platex, que es el origen principal de esta investigación.

Nos enfocaremos en estudiar el proceso de compra, la producción de la empresa y los movimientos del almacén del stock para poder encontrar un resultado óptimo que resuelva la problemática planteada.

En primer lugar, se estudiará el pasado histórico de ventas de la empresa para diseñar un modelo predictivo confiable de la producción futura. En segundo

lugar, se analizarán los movimientos de compras de insumos productivos, para encontrar insights correspondientes a los tiempos de compra y necesidad de insumos en los distintos momentos del tiempo. Se buscará lograr un impacto positivo en la toma de decisiones relacionadas a la gestión de la producción final, la compra de insumos y la administración del stock.

Tipos y recolección de datos

Los datos a utilizar para alimentar los algoritmos a utilizar, serán datos internos de la empresa TN & Platex.

Por una parte, se cuentan con los datos de la producción diaria de la empresa entre enero de 2014 y julio de 2021. Por otro lado, existen los datos de pedidos y facturación de productos de la empresa, entre enero de 2005 y octubre de 2022.

Además, también están disponibles los datos de los movimientos de almacén de los insumos determinados en la primera sección, del periodo comprendido entre enero de 2014 hasta julio de 2021. Por otra parte, se poseen los registros de compras de la empresa desde enero de 2015 hasta octubre de 2021.

Por último, se plantea la posibilidad de realizar entrevistas informales con los diferentes sectores de la empresa para poder entender cuestiones del proceso actual.

CAPÍTULO 2 - MARCO TEÓRICO

A continuación, es necesario definir los conceptos relevantes a tener en cuenta para encarar el problema planteado. En primer lugar, se presentarán casos de éxito de empresas que aplicaron IA en determinadas situaciones y el impacto que generó esta adopción. Luego, se intentará explicar de la mejor manera en qué consiste la automatización, particularmente aplicada a la gestión de inventarios en una empresa. Por otra parte, también se buscará presentar los modelos matemáticos que se utilizan como herramientas para resolver problemas de este tipo. Además, se hará un repaso del estado de la Inteligencia Artificial, se definirá qué es el *machine learning*, como funciona y de qué manera es útil aplicarlo en el mundo empresarial, particularmente en este caso planteado. También, se explicará lo que es el *deep learning*, un subtipo del *machine learning*.

2.1 Impacto de la Inteligencia Artificial aplicada en las empresas

La Inteligencia Artificial (IA) es la capacidad que tienen las máquinas para aprender a partir de datos y tomar decisiones mediante este aprendizaje. En muchas empresas de diferentes industrias, la IA ya fue utilizada como una herramienta de transformación digital que generó mejores resultados.

En los últimos años, la IA avanzó en el Procesamiento de Lenguaje Natural y Visión Artificial. De esta manera, las grandes empresas por ejemplo pudieron aplicar chatbots sofisticados.

2.2 Administración de inventarios

La administración de inventarios, según Krajewski et al. (2008), se trata de la planificación y control de inventarios para cumplir con las prioridades competitivas de la organización. Poder gestionar los stocks de una manera

eficiente es importante para una empresa, dado que influye de manera directa en la cadena de valor. Como señalan Heizer & Render (2009), la mayoría de los modelos de inventario tienen como objetivo minimizar los costos totales (en especial los costos de mantener un artículo en stock y los costos de hacer el pedido de los artículos). Sin embargo, Krajewski et al. (2008) argumentan que el fin no consiste en abaratar los costos reduciendo los inventarios al mínimo, de la misma manera que tampoco el fin es acumular stock de manera exagerada para satisfacer siempre a las demandas que se generan dentro de la empresa. El objetivo, en palabras de Krajewski et al. (2008) es “mantener la cantidad adecuada para que la empresa alcance sus prioridades competitivas de la forma más eficiente posible”.

En la búsqueda permanente de mejorar la eficiencia y perfeccionar los procesos, Laudon & Laudon (2015) anuncian varias maneras de lograr un cambio organizacional, dentro de lo cual explican que la automatización de procesos es uno de los tipos de cambios organizacionales y el más utilizado a menudo. La automatización consiste en llevar a cabo actividades de una forma más eficiente y eficaz, por lo tanto, se utiliza para ayudar a los empleados. Poder lograr la automatización en procesos de compras y de gestión de inventarios es muy importante para obtener mejores recompensas dentro de la empresa.

En definitiva, lo que se quiere es encontrar una cantidad óptima de inventario, de manera que se minimicen los costos, y a la vez, poder cumplir la demanda solicitada en todo momento, para no afectar a la cadena de valor. En otras palabras, esta idea es lo que Winston (2004) define como *un modelo de optimización*, el cual es un modelo matemático que representa una situación real y el cual “*seeks to find values of the decision variables that optimize (maximize or minimize) an objective function among the set of all values for the decision variables that satisfy the given constraints.*” (p. 1).

Los modelos de optimización son técnicas utilizadas en el campo de la Investigación Operativa, lo que Winston (2004) sostiene que se trata de una

mirada científica que busca asignar recursos escasos de la mejor manera siguiendo determinadas condiciones, para mejorar y rediseñar un sistema que es utilizado para la toma de decisiones.

2.3 Analytics en el mundo empresarial: ML como arma de vanguardia

Poder mejorar la toma de decisiones es uno de los objetivos de la ciencia de datos, la cual involucra “principles, processes, and techniques for understanding phenomena via the (automated) analysis of data.” (p. 5) en palabras de Provost & Fawcett (2013). En el último tiempo, donde es importante la constante innovación en las empresas para no quedar atrás de la competencia, gracias a las nuevas tecnologías como Big Data y Analytics, las empresas obtuvieron la posibilidad de mejorar sus toma de decisiones aplicando ciencia de datos.

En "The Big Data-Driven Business: How to Use Big Data to Win Customers, Beat Competitors, and Boost Profits" (Glass & Callahan, 2015), Russell Glass y Sean Callahan explican que el big data se refiere a grandes cantidades de datos que se generan a partir de diversas fuentes, como por ejemplo transacciones comerciales (en el caso de TN&Platex, se pueden pensar como las ventas y pedidos), máquinas productivas (producción por día), interacciones en redes y dispositivos móviles. Estos datos pueden ser muy valiosos para las empresas, ya que pueden proporcionar insights sobre el comportamiento del consumidor, el rendimiento de los productos y la eficiencia de las operaciones.

El *Big Data* entonces, engloba la captura, almacenamiento y la transformación de una masiva cantidad de datos, los cuales lograron ser explotados utilizando *Analytics*, que consiste en la automatización del análisis de los datos.

Los autores sugieren utilizar técnicas de análisis de datos, como el machine learning para utilizar el *big data* de manera efectiva. El machine learning

(aprendizaje automático) es una técnica de análisis de datos que utiliza algoritmos para aprender y mejorar automáticamente a partir de los datos.

Por ejemplo, una empresa podría utilizar el *machine learning* para predecir qué productos serán más populares entre los consumidores a partir de datos sobre sus compras y comportamientos en línea. También, podría utilizarlo para detectar patrones en los datos de sus clientes y de esta manera obtener una segmentación de los mismos. De la misma manera, se podría usar el aprendizaje automático para prevenir el abandono de clientes, en base a la historia y a los clientes que fueron perdidos y los vigentes.

En este caso, se podrá usar los datos de ventas de TN & Platex para predecir cómo serán las ventas en el futuro, y de esta manera, anticiparse a la necesidad de insumos productivos.

Las aplicaciones de *machine learning* en un contexto empresarial son muchas, solamente es suficiente con detectar un problema, contar con datos históricos (no menos importante) para alimentar un algoritmo, y definir la mejor solución en cuanto a modelado y selección de parámetros. Sumado a esto, para aplicar y resolver problemas de una empresa *machine learning*, se necesita también un cambio de mentalidad dentro de las organizaciones.

Provost & Fawcett (2013) exponen la idea de *Data-driven decision-making*, que apunta a utilizar el análisis de datos, en vez de la intuición, para tomar mejores decisiones. Desde hace tiempo, las empresas que son *data-driven* están un paso delante de las empresas que no utilizan sus datos para tomar decisiones.

La consultora global Llorente y Cuentas (2021), realizó el estudio “Deep Digital Journey”, donde se encuestaron a más de 200 empresas de 16 industrias distintas, de América y Europa. Para contextualizar este informe, LLYC define 4 etapas de Deep Digital Business en las que puede estar una empresa en relación a la transformación digital: Digital Being, Digital Optimization, Digital Data Driven y Deep Digital.

Se encuadra a las empresas en la categoría *Digital Being*, cuando éstas recién están desarrollando una identidad mínima en el entorno digital. Cuando se encuentran en la fase *Digital Optimization*, se entiende que están en un proceso de mejora y puesta a punto de la digitalización. *Digital Data Driven* es la etapa donde las empresas ya se adaptaron al entorno digital, y toman sus decisiones con ayuda de los datos. Por último, en la posición de *Deep Digital* se encuentran las empresas que llegaron a su evolución total de la digitalización, y lograron la transformación digital.

El 33% de las empresas se ubican en el tercer nivel, es decir, son data driven. Solo el 10,8% de las empresas llegaron al nivel más alto de transformación digital. El resto de las empresas, siguen en camino de lograr evolucionar. Las empresas *data driven* potencian sus negocios a partir de la analítica de datos.

En "Predictive Analytics: The Power to Predict Who Will Click, Buy, Lie, or Die" (Siegel, 2013), Eric Siegel brinda una descripción general del uso del aprendizaje automático y el análisis predictivo en la toma de decisiones comerciales. El autor explica cómo se pueden utilizar las técnicas de análisis predictivo para mejorar el rendimiento y la eficiencia de las empresas, proporcionando ejemplos concretos y estudios de casos de cómo se han utilizado estas técnicas en diferentes industrias. A continuación, se realizará una extracción de las ideas principales que expone Siegel, para utilizar estos conceptos como punto de referencia para la aplicación de algoritmos de *machine learning* en este trabajo ligado a la empresa TN & Platex.

Eric Siegel comienza presentando los conceptos fundamentales del aprendizaje automático y el análisis predictivo, incluido el aprendizaje supervisado, el aprendizaje no supervisado y el aprendizaje por refuerzo.

- El aprendizaje supervisado se refiere a la tarea de entrenar un modelo de aprendizaje automático utilizando un conjunto de datos etiquetado, en el que se conocen las respuestas correctas. Por ejemplo, si quisiéramos

entrenar un modelo para predecir si un cliente comprará un producto en particular, podríamos usar un conjunto de datos que contenga información sobre los clientes que compraron y no compraron el producto en el pasado. El concepto de aprendizaje supervisado aplica para el caso de TN & Platex, dado que se podría intentar predecir las ventas con ventas de los periodos anteriores conocidos.

- El aprendizaje no supervisado, por otro lado, se refiere a la tarea de entrenar un modelo utilizando un conjunto de datos no etiquetado, en el que no se conocen las respuestas correctas. Por ejemplo, podríamos usar técnicas de aprendizaje no supervisado para detectar patrones o grupos en un conjunto de datos de clientes.
- El aprendizaje por refuerzo, finalmente, se refiere a la tarea de entrenar a un modelo para que tome decisiones en un entorno dinámico y reciba recompensas o castigos en consecuencia.

Siegel también analiza diferentes tipos de algoritmos de aprendizaje automático, como árboles de decisión, regresión lineal y redes neuronales. Los árboles de decisión son un tipo de algoritmo que utiliza un conjunto de reglas para tomar decisiones. A modo de ejemplo, podríamos usar un árbol de decisiones para predecir si un cliente comprará un producto en función de sus características demográficas, historial de compras y otras variables.

La regresión lineal es un tipo de algoritmo que se utiliza para predecir una variable numérica en función de la relación con una o más variables. Por ejemplo, podríamos usar la regresión lineal para predecir el ingreso anual de un cliente en función de su nivel de educación y años de experiencia.

Las redes neuronales son un tipo de algoritmo inspirado en la estructura y función del cerebro humano, y son especialmente adecuadas para tareas como la clasificación de imágenes y el procesamiento del lenguaje natural, como así también para las series de tiempo. En el último tiempo, las redes neuronales

artificiales incrementaron su implementación dada la capacidad de procesamiento y aprendizaje que pueden obtener.

Luego, el autor se enfoca en la aplicación del aprendizaje automático en la predicción comercial y brinda ejemplos de cómo se han utilizado estas técnicas para predecir el comportamiento del consumidor, el éxito del producto y el desempeño de los empleados. Eric Siegel menciona también, las cuestiones éticas y de privacidad relacionadas con el uso del aprendizaje automático y el análisis predictivo en el mundo empresarial, y ofrece recomendaciones para garantizar que estas técnicas se utilicen de manera responsable y ética. Para aplicar machine learning, como se mencionó es necesario contar con datos que puedan alimentar estos algoritmos.

Jhon V. Guttag (2021) en “Introduction to Computation and Programming Using Python: With Application to Understanding Data” menciona que la cantidad de datos que se generan en el mundo actualmente, se duplica cada tres años desde el año 1980. En este sentido, señala que “One approach that the world is using to attempt to wring more useful information from “big data” is statistical machine learning.” (p. 570). El autor también destaca que las personas utilizan la generalización para inferir nuevos acontecimientos a partir de hechos pasados.

Bajo la mirada expuesta en este apartado, se trabajará en el siguiente capítulo en aplicar algoritmos de aprendizaje automático en la problemática planteada para TN & Platex y de esta manera, buscar una solución competente que genere nuevas maneras de destinar los recursos que posee la empresa. A su vez, se expondrán las técnicas clásicas con las cuales se analizan series de tiempo y la comparación entre las nuevas herramientas que brinda el *machine learning* y *deep learning*.

CAPÍTULO 3 - MODELADO PREDICTIVO

En primer lugar, en este capítulo es importante volver a refrescar el concepto de Machine Learning para mantenerlo presente. Bishop en "Pattern Recognition and Machine Learning" (2006) describe el Machine Learning como "un conjunto de técnicas que permiten a las máquinas 'aprender' a partir de datos, sin ser explícitamente programadas" (p. 1). En este proceso una computadora se entrena con datos observados y deseados que se le proporcionan, y mediante el entrenamiento de un modelo, con cálculos matemáticos la máquina aprende ciertos patrones que existen en los datos, para luego hacer predicciones con nuevos datos que el modelo no conoce. Este entrenamiento que realiza la máquina, consiste en ajustar parámetros para minimizar la diferencia entre los datos deseados y los datos predichos. En términos matemáticos, el proceso de entrenamiento puede expresarse mediante la minimización de una función de pérdida o error.

Una vez que se ha elegido una función de pérdida, se puede utilizar un algoritmo de optimización para minimizarla y, por lo tanto, ajustar los parámetros del modelo de manera óptima. Bishop (2006) señala que "en el aprendizaje supervisado, la función de pérdida se elige para medir el error entre las etiquetas predichas y las etiquetas correctas proporcionadas en el conjunto de entrenamiento" (p. 2).

Según lo describe Bishop (2006), "la elección de una función de pérdida apropiada es esencial para el éxito del aprendizaje automático" (p. 1).

3.1 Estrategia de modelado

La estrategia a utilizar para analizar los datos de la empresa y modelar la predicción de los pedidos que ingresarán consta de dos etapas.

En primer lugar, se buscará predecir el total de los pedidos de la empresa para determinado periodo de tiempo, y luego se determinará qué proporción del total corresponde a cada artículo que comercializa TN & Platex.

La metodología empleada para modelar el problema es útil dado que permite dividir el problema en dos etapas.

Por un lado, predecir el total de pedidos de la empresa ayuda a detectar patrones y tendencias que caracterizan los pedidos de la empresa en el mercado y el comportamiento de sus clientes.

Por otro lado, al estimar la proporción del total de cada artículo se podrá conocer los productos más demandados de la empresa, y también la tendencia particular de cada artículo

Además, modelar la predicción de los pedidos totales de la empresa será menos difícil para ajustar los parámetros del modelo creado y para recopilar y procesar los datos que alimentarán el modelo.

De esta manera, el proceso completo analítico del trabajo queda determinado de la siguiente manera:

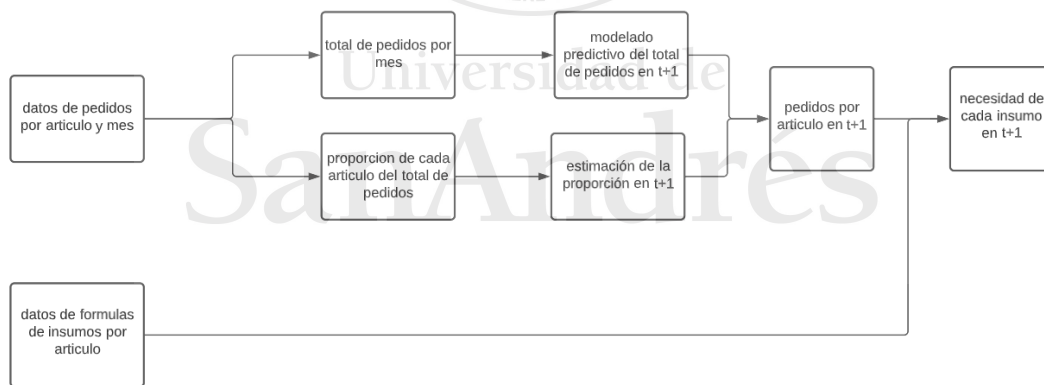


Figura 6. diagrama de trabajo dada la estrategia mencionada. Fuente de elaboración propia.

A partir de los datos de pedidos ingresados históricos por artículo, se diseña un modelo predictivo para el total de pedidos y se estima la proporción de cada artículo del total, y luego en base a fórmulas establecidas que determinan la cantidad de cada insumo productivo que necesita cada artículo, se obtiene la cantidad necesaria de insumos productivos para cumplir con los pedidos que ingresaran en el futuro periodo elegido.

3.2 Visualización y análisis de datos

Se buscará utilizar los datos de pedidos (de clientes de TN & Platex) para modelar el consumo de los productos que comercializa la empresa, y tener una noción acertada de cómo será el comportamiento de la demanda en los próximos meses. Es importante mencionar que solo se intentará predecir las ventas para algunos hilados de la empresa.

En el último año, la empresa comercializó más de 130 artículos de hilados. De los 130 artículos comercializados en el 2022, se decidió actuar sobre 21 hilados que se producen en la planta de Monte Caseros, que en el año representaron más del 60% de la facturación anual (Aclaración: no es posible anexar la justificación de los datos que brinda este indicador debido a políticas de confidencialidad de la empresa en cuanto a facturación).

En otras palabras, si bien la empresa comercializa muchos productos a lo largo de un periodo anual, se determinó trabajar solo con una parte de estos, pero que son fundamentales para la facturación, y a la vez, para la producción y fundamentalmente para el objetivo de este trabajo: la necesidad de insumos productivos.

Hilado	Uso	Descripción Hilado
1.0 - S/C - WAT - PABILLO CRU	trapos de piso, rejillas de cocina	hilo grueso, color crudo, materia prima desperdicios
10.0 - OE - BON - 50% POAL	remeras, medias, buzos, cordones	hilo gruesos, materia prima algodón y poliéster
10.0 - OE - FRIZA - ALG	buzos	hilo grueso de algodón
10.0 - OE - WAT - ALG	jeans, camisas	hilo grueso de algodón
12.0 - OE - BON - 50% POAL	remeras, medias, buzos	hilo gruesos, materia prima algodón y poliéster
12.0 - OE - BON - SOCK COL	remeras, medias, buzos	hilo grueso de materia prima color
12.0 - OE - FRIZA - ALG	buzos	hilo grueso de algodón
12.0 - OE - WAT - ALG	jeans, camisas	hilo grueso de algodón
14.0 - OE - WAT - ALG	jeans, camisas	hilo grueso de algodón
14.0 - OE - WAT - COLOR	jeans, camisas	hilo grueso de materia prima color
16.0 - OE - BON - ALG	remeras, medias, buzos	hilo fino de algodón
16.0 - OE - WAT - ALG	jeans, camisas	hilo fino de algodón
20.0 - OE - BON - ALG	remeras, medias, buzos	hilo fino de algodón
20.0 - OE - WAT - ALG	jeans, camisas	hilo fino de algodón
24.0 - OE - BON - 50% POAL	remeras, medias, buzos	hilo fino de algodón y poliéster
24.0 - OE - BON - 95/5% MEL	remeras, medias, buzos	hilo fino de algodón y poliéster
24.0 - OE - BON - ALG	remeras, medias, buzos	hilo fino de algodón
24.0 - OE - WAT - ALG	jeans, camisas	hilo fino de algodón
8.0 - OE - BON - ALG	remeras, medias, buzos, cordones	hilo grueso de algodón
8.0 - OE - WAT - ALG	remeras, medias, buzos, cordones	hilo grueso de algodón
8.0 - OE - WAT - COLOR	jeans, camisas	hilo grueso de materia prima color

Para entender mejor el comportamiento de cada artículo en cuanto a los pedidos, es necesario realizar un análisis exploratorio de los datos. En primer lugar, mediante la visualización de los pedidos en el tiempo se puede detectar si existe una estacionalidad, tendencias, periodos de tiempo anormales, etc.

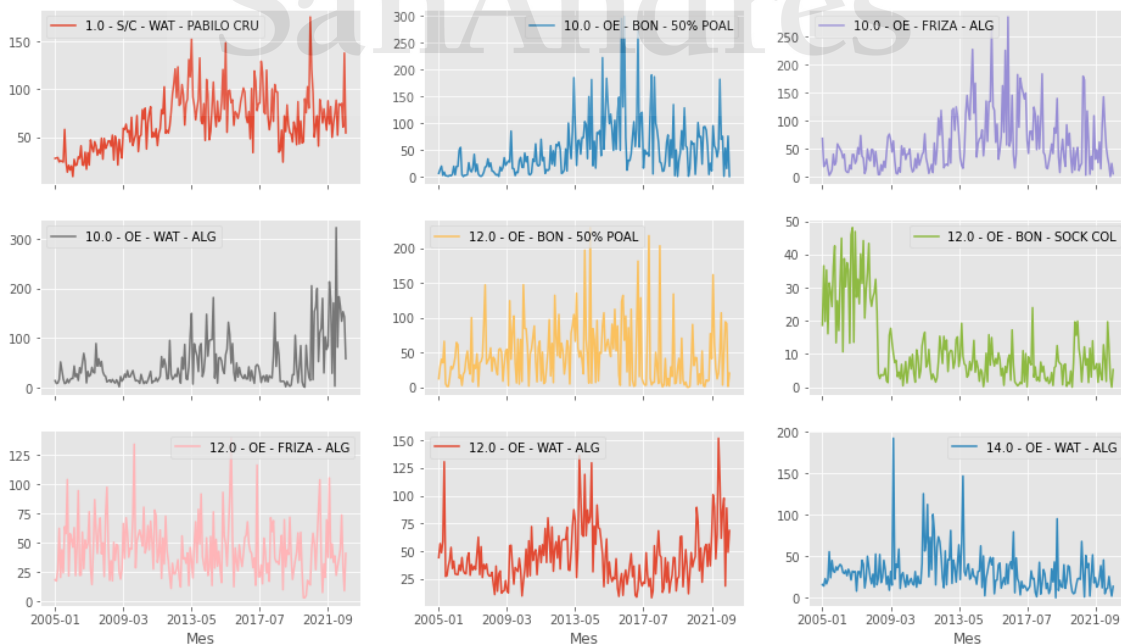


Figura 7. Representación gráfica de los pedidos en el tiempo para los artículos 1 a 9. Fuente de elaboración propia.

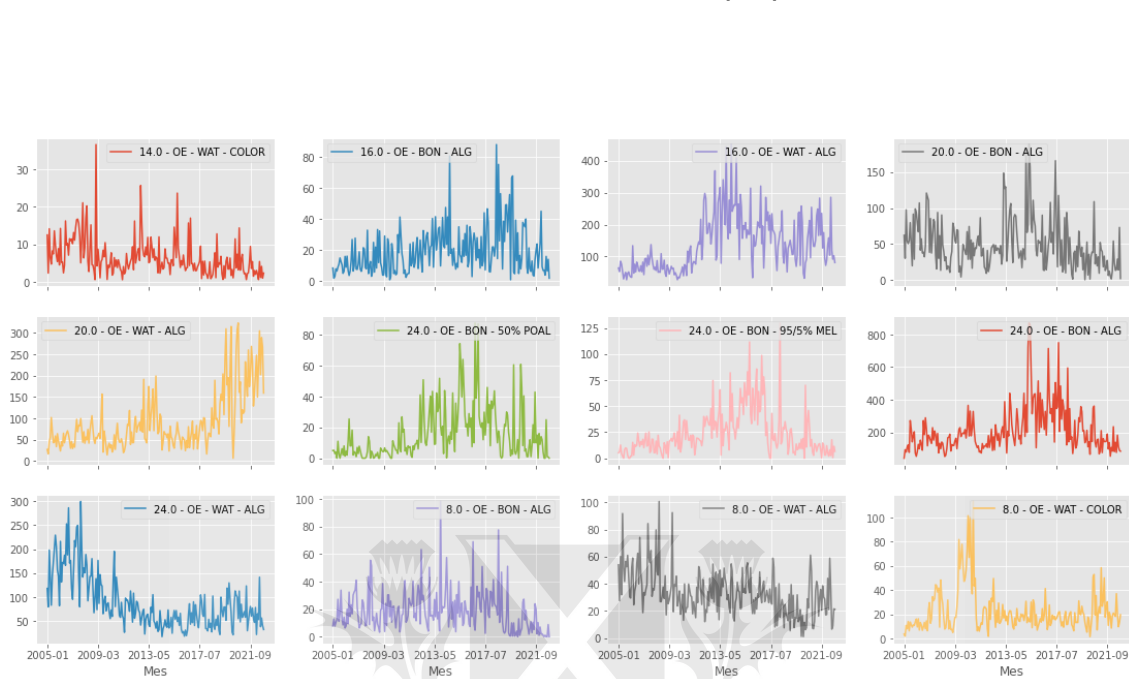


Figura 8. Representación gráfica de los pedidos en el tiempo para los artículos 10 a 21 artículos restantes. Fuente de elaboración propia.

Dentro del periodo de datos existentes, los pedidos de cada artículo tuvieron variaciones debido a cuestiones de nuevas fábricas, cierre de fábricas, mayor demanda por moda, caída de clientes, etc. Por tal motivo, al observar los gráficos se ve ciertas caídas bruscas y crecimientos grandes en la serie. A su vez, se deben contemplar las variables económicas que pueden impactar, como los cambios de gobierno, devaluación del tipo de cambio, inflación, etc.

También, es importante notar el comportamiento que tuvieron los pedidos en el año 2020 a raíz de la pandemia de Covid-19. En este punto, se puede observar que la mayoría de los pedidos decayeron a principio del 2020 y luego repuntaron bruscamente a comparación de los mismos meses en años anteriores. Todas estas variaciones que se ocasionan en las distintas series de

pedidos agregan un ruido a la estacionalidad, tendencia, y ciclo que tiene la serie en la historia.

Para entender mejor la tendencia y estacionalidad de la serie de pedidos de la empresa, en primer lugar analizaremos el total del periodo comprendido entre 2005 y 2022 junto al promedio móvil con una ventana de 9 meses, y luego, se hará foco en distintos periodos. Analizar los pedidos ingresados de cada mes y el promedio móvil ayuda a visualizar la tendencia general de las ventas, y detectar las fluctuaciones de la serie.




Figura 9. Visualización del total de los pedidos por mes y la media móvil con una ventana de 9 meses, entre 2005 y 2022. Fuente de elaboración propia.

Al dividir el tiempo en 4 etapas, podemos extraer percepciones de cómo evolucionaron los pedidos de la empresa en el tiempo.

Entre 2005 y 2009 (inclusive), las ventas mensuales de la empresa se mantuvieron relativamente constantes en un valor promedio de 880 toneladas y con variaciones de -300 y +700 toneladas de hilo. Con variaciones propias de la estacionalidad por mes, se puede ver que en los cinco años no existe una tendencia que demuestre un crecimiento notorio de la empresa en ventas, sino más bien, una etapa de estancamiento.




Figura 10. Representación gráfica de los pedidos entre 2005 y 2009 (inclusive).

Fuente de elaboración propia.

Como se mencionó anteriormente, existe una estacionalidad que se puede visualizar en la mitad de cada año, donde caen los pedidos. A su vez, al final y al principio de cada año es donde da lugar a las subas de los pedidos de hilo que comercializa la empresa.

Luego, entre 2010 y 2014 (inclusive), se comienza a notar un crecimiento de los pedidos, alcanzando pasar las 1500 toneladas de hilo y sobrepasando las 2000 toneladas en ciertos meses.




Figura 11. Representación gráfica de los pedidos entre 2010 y 2014 (inclusive).

Fuente de elaboración propia.

En este periodo podemos notar el crecimiento que se da a partir de 2013, y se mantiene la misma estacionalidad mencionada. Aproximadamente a mitad de cada año los pedidos caen un cierto de mínimo (por el momento, en el periodo los pedidos no bajan de las 500 toneladas por mes). Nuevamente, al final y comienzo de cada año los pedidos vuelven a conseguir el crecimiento, siendo más importante este crecimiento en 2013.

La tercera etapa a analizar se da entre 2015 y 2019 (inclusive). En esta etapa, los pedidos mensuales se mantuvieron en promedio entre las 1000 y 1500 toneladas, con meses donde se superaron las 2000 toneladas de pedidos, y meses por debajo de las 1000 toneladas.



Figura 12. Representación gráfica de los pedidos entre 2015 y 2019 (inclusive).

Fuente de elaboración propia.

En los últimos años del periodo anterior, los pedidos estaban en crecimiento, lo cual continuó en el comienzo del 2015, pero a partir del 2016 se aprecia una leve caída en los pedidos, contrarrestando lo que se vio reflejado en la segunda etapa marcada. Si bien no alcanzó el nivel de pedidos mensuales entre 2005 y 2010, claramente la empresa tuvo una disminución en sus ventas. Al igual que en los periodos anteriores, en la mayoría de los años se nota cierta caída de los pedidos en cada mitad de año.

Por último, el periodo comprendido entre 2020 y 2022 es totalmente atípico debido a variables externas. A comienzos del año 2020 se origina la pandemia del Covid-19, y la empresa se ve afectada totalmente en sus ventas.



Figura 13. Representación gráfica de los pedidos entre 2020 y 2022 (inclusive).

Fuente de elaboración propia.

En marzo de 2020 la empresa cae a su mínimo de pedidos en la historia comprendida (2005 a 2022) con solamente 280 toneladas. Meses después de

lo ocurrido en marzo de aquel año, la empresa repunta y compensa en cierta manera los pedidos perdidos por la pandemia. Esto genera que la estacionalidad representada en los 3 periodos anteriores no se aprecie a partir de 2020, variando los valores vistos mensualmente en el pasado. En este periodo se puede entender que el mercado textil y la empresa, al igual que sus clientes, se encuentren en un proceso de reivindicación y búsqueda de volver a la normalidad visualizada en el pasado.

3.3 Obtención, curado y transformación de datos

3.3.1 Recolección y curado de los datos

Tal como se mencionó anteriormente, para entrenar un modelo de machine learning, es necesario contar con datos históricos para que el modelo pueda aprender los patrones de estos datos, tal como los podría intentar deducir o intuir una persona para pronosticar una variable.

En este proceso de diseñar un modelo predictivo, es importante el curado de los datos con los cuales se entrena un modelo. Para obtener buenos resultados en el entrenamiento del modelo, es necesario que los datos no tengan errores, ni valores nulos o faltantes, dado que esto haría que el modelo generalice mal y en el futuro otorgue predicciones incorrectas.

3.3.1.1 Datos internos

En este caso, se contaban con los pedidos de artículos de hilados de TN & Platex por mes, desde enero de 2005 a octubre de 2022. En relación al curado de los datos, existían meses donde no hubieron pedidos, por lo cual, para obtener una serie de tiempo se completó aquellos valores faltantes con 0, es decir, se agregó el valor 0 a los meses donde no hubo pedidos ingresados.

Una vez que se cuentan con los datos limpios, se puede comenzar a trabajar con la preparación de estos datos como variables de entrada significativas para predecir variables de salida, es decir, crear un nuevo conjunto de datos (dataset).

Además, se decide incluir los datos de facturación de la empresa (en kilos) como variable predictora. La facturación y los pedidos tienen una correlación temporal, dado que la facturación responde a los pedidos en distintos momentos. Es decir, un pedido puede ser facturado al día siguiente, en dos semanas, en un mes, o en X meses, por lo tanto, la facturación aporta valor a la hora de predecir los pedidos que ingresarán. Otra justificación es que la facturación corresponde a los pedidos, y muchas veces hasta que un cliente no factura la cantidad total de kilos que hizo en su pedido, no vuelve a realizar otro pedido, y esto también no permite el ingreso de pedidos.

3.3.1.2 Datos externos

Sumado a los datos internos, se decide incluir 3 variables macroeconómicas que brindan información sobre el contexto económico y pueden estar correlacionadas con el comportamiento de los clientes.

En primer lugar, mediante una API proporcionada por el sitio web del Banco Central de La República Argentina, se obtuvieron los datos del Índice de Tipo de Cambio Real Multilateral. Según el BCRA (n.d.), el ITCRM “mide el precio relativo de los bienes y servicios de la economía argentina con respecto al de los de los principales 12 socios comerciales del país, en función del flujo de comercio de manufacturas.” (https://www.bcra.gob.ar/publicacionesestadisticas/indices_tipo_cambio_multilateral.asp). Este índice busca representar la evolución de los precios del consumo local a partir de una ponderación de los tipos de cambios reales.

Además, a través de la misma API que ofrece el sitio web del Banco Central de La República Argentina, se extrajeron los datos del Índice de Inflación mensual.

Por último, se extrajeron los datos del Estimador Mensual de Actividad Económica (EMAE) a través del sitio web del Centro de Información y Estudios Económicos de la Provincia de Buenos Aires (<https://estudioeconomicos.ec.gba.gov.ar/>). Este indicador, según el Instituto Nacional de Estadísticas y Censos (n.d.), “refleja la evolución mensual de la actividad económica del conjunto de los sectores productivos a nivel nacional. Este indicador permite anticipar las tasas de variación del producto interno bruto (PIB) trimestral.” (<https://www.indec.gob.ar/indec/web/Nivel4-Tema-3-9-48>).

Estos 3 índices macroeconómicos, cuentan con valores mensuales, al igual que los pedidos de la empresa.

3.3.2 Procesamiento de los datos

Luego del curado realizado a los datos para todos los artículos y el diseño de los mismos como serie de tiempo, se decide crear un dataset con variables de entrada y de salida para poder entrenar un modelo de predicción. En este punto, se decide convertir el problema en uno de aprendizaje supervisado. Es decir, lo que en un principio era un dataset con valores como serie de tiempo, se transformara en un dataset con variables conocidas de entrada y variables deseadas de salida.

Para este objetivo, se tomarán distintas variables input. Las variables de entrada para entrenar el modelo están relacionadas a los pedidos y facturación de todos los artículos, índices macroeconómicos del país y variables que representen los meses anteriores incluidos dentro del dataset.

Como valores de entrada del conjunto de datos, se tomarán los 9 meses anteriores al mes que se predecir. Se supone que lo que pasa en la ventana de

tiempo de hoy a 9 meses hacia atrás, tanto en los pedidos de hilado como en variables macroeconómicas, puede ser significativo a la hora de intentar predecir el mes futuro de pedidos.

La salida deseada siempre será 1 periodo futuro en el tiempo, es decir, $t+1$. En este caso, tomamos 1 periodo como un mes.

Por un lado, se determinó tomar n meses anteriores de pedidos como variables de entrada. A modo de ejemplo, se toma una ventana de 9 meses anteriores, y para el primer registro del nuevo set de datos, se toman los datos de Enero 2005 a Septiembre 2005 (inclusive) como datos de entrada, y de salida se toman los pedidos de Octubre 2005.

Además de usar los n meses de pedidos anteriores, también se incluyen los datos de n meses anteriores de la facturación, por lo tanto, como variables de entrada si se toma una ventana de 9 meses anteriores se incluyen los datos de Enero 2005 a Septiembre 2005 (inclusive) de la facturación total de los artículos.

En otras palabras, con la creación de este set de datos se intentará predecir el comportamiento futuro de los clientes de la empresa con la historia de ventas (pedidos) de todos los artículos. Además, en cada serie de pedidos está implícita la oferta de la empresa al mercado. En este sentido, Lucas K. (directivo de TN&Platex) comentaba que existen muchos momentos del año en donde se cruzan cuestiones de stocks, necesidad de venta (ya sea, por mayor rentabilidad u otro motivo comercial) y de pedidos, donde se decide ofrecer determinados artículos por sobre otros, por más allá de que los pedidos iniciales para ese momento no indican que se deben vender esos artículos. Por tal motivo, se presume que al incluir el total de pedidos de todos los artículos, implícitamente se introducen los patrones de tendencia general de la empresa.

Además, se decide realizar una transformación a los datos para reducir los valores y poder realizar un análisis más ameno, donde se convierten los registros de pedidos que estaban en kg a toneladas (es decir, dividir los valores

en 1000) para que el modelo empleado funcione mejor. En un modelo de *machine learning*, transformar los datos de entrada puede ayudar a mejorar la precisión y el aprendizaje de tal modelo dado que si los datos son valores muy grandes pueden tener un impacto perjudicial en el modelo, afectando a la convergencia de la métrica de error en el modelo, ya que las diferencias entre los valores deseados y los predichos pueden ser grandes y no se lograría obtener una solución óptima.

De igual manera que los pedidos, se agregan como variables los n últimos meses de cada índice macroeconómico recolectado.

Por último, a las variables de entrada del modelo es necesario también incluir *features* que indiquen el mes del año al que corresponde cada registro. Es decir, incluir al dataset esta información puede ayudar a capturar efectos de estacionalidad, dado que no es lo mismo un registro si se produjo en el mes de Enero o si se produjo en el mes de Julio, por ejemplo. Una opción posible es incluir n variables, donde cada una tome el valor del mes anterior al que se quiere predecir. Por ejemplo, si se quiere predecir para el mes de Diciembre 2022, y se toma una ventana de 9 meses anteriores, las variables a incluir serían: 11, 10, 9, 8, 7, 6, 5, 4, 3.

Esta opción podría funcionar bien para describir la relación de los meses continuos entre Febrero y Noviembre, dado que el número de mes en este rango son cercanos.

El problema existe cuando se intenta incluir los meses de Diciembre y Enero. Si bien los meses son cercanos en el tiempo, si miramos el número de mes de cada uno salta de 12 a 1, y se produce una discontinuidad en el rango. Por ende, si se quiere incluir la estacionalidad como variable de entrada, es necesario pensar otra metodología.

En este caso, se decide pensar cada mes del año como un punto de una circunferencia. De esta manera, los extremos (Enero y Diciembre), están a la misma distancia que los demás meses continuos.

Se supone una circunferencia de 0 a 2π , donde están distribuidos los 12 meses como puntos de la circunferencia y a la misma distancia. Luego, cada punto tiene un ángulo respecto al vector (1,0).

Este ángulo se obtiene con la siguiente ecuación:

$$\text{ángulo} = \frac{\text{Mes} * 2\pi}{12}$$

Cuando se conoce el ángulo, se puede extraer las coordenadas X e Y del punto en la circunferencia.

De esta manera:

$$\text{eje } x = \text{coseno}(\text{ángulo})$$

$$\text{eje } y = \text{seno}(\text{ángulo})$$

A modo de ejemplo, se presenta gráficamente lo explicado:




Figura 14. Representación de los meses en un espacio (x,y). Fuente de elaboración propia

Cada mes del año, es un punto en una circunferencia, por ende se puede extraer una coordenada (x,y).

Una vez que se cuenta con las coordenadas X e Y correspondientes para cada mes del año, se agregan al dataset de la misma manera que los pedidos y las variables externas, es decir, se toman las coordenadas X e Y de los últimos n meses anteriores al mes a predecir los pedidos.

3.3.3 Dataset final

Luego de las transformaciones realizadas a los datos existentes, el dataset a utilizar para entrenar el modelo cuenta con las siguientes variables de entrada:

- n meses anteriores de pedidos.
- n meses anteriores de facturación.
- n meses anteriores del índice de inflación.
- n meses anteriores del índice ITCRM.
- n meses anteriores del índice EMAE.
- n meses anteriores de coordenadas X e Y representativas del mes.

De esta manera, el dataset cuenta con $7*n$ variables de entrada, para intentar predecir el siguiente mes de pedidos totales. El valor de n es dinámico y se definirá a la hora de entrenar el modelo.

Por último, los datos existentes para entrenar cada modelo deben ser partidos en dos nuevos conjuntos: set de entrenamiento y set de validación.

- Conjunto de datos de entrenamiento. Este dataset se utiliza para entrenar propiamente el modelo (corregir los parámetros del mismo y minimizar el error generado entre las variables de salida conocidas y las variables de salida predichas) y también elegir hiperparámetros del mismo.
- Conjunto de datos de validación. Este set de datos se utiliza para evaluar un modelo ya entrenado, dado que el modelo no conoce estos datos, por lo cual se emplea para analizar si el modelo generalizó correctamente durante su aprendizaje.

3.4 Modelado autorregresivo: ARIMA

El análisis de series temporales desde hace mucho tiempo tiene aplicaciones con alto impacto en la ciencia, basada en responder preguntas mediante estadística y matemática a través de correlaciones de valores a lo largo del tiempo. De esta manera, Shumway y Stoffer (2011) mencionan que una de las primeras series de tiempo registradas se vio en el año 1906 a través de un estudio de Schuster, el cual estaba relacionado al número mensual de manchas solares. Los autores sostienen que existen muchas aplicaciones de la metodología estadística clásica para analizar correlaciones en el tiempo. Además, Shumway y Stoffer (2011) explican que existen 2 tipos de enfoques separados a la hora de analizar series temporales, identificadas como “the time domain approach and the frequency domain approach” (p. 2).

La primera apreciación de los autores, se encuadra en el modelado de una herramienta de pronóstico de un valor futuro con relación en sus propios valores pasados de tal serie. Por otra parte, el segundo enfoque propuesto se basa en relación a variaciones sinusoidales periódicas o sistemáticas, las cuales son causadas por fenómenos biológicos, físicos o ambientales, y además, se menciona que esta periodicidad se extiende a las ciencias

económicas y sociales donde se puede estudiar otros tipos de periodicidades en las variables.

Para este caso de estudio, se puede observar el primer enfoque como posible método de pronóstico. Dentro de este enfoque existe un modelo muy conocido expuesto por Box y Jenkins (1970), tal como mencionan los autores Shumway y Stoffer (2011), llamado modelo de promedio móvil integrado autorregresivo (ARIMA). Acerca de este modelo, Shumway y Stoffer (2011) mencionan que “The defining feature of these models is that they are multiplicative models, meaning that the observed data are assumed to result from products of factors involving differential or difference equation operators responding to a white noise input.” (p. 2)

Un modelo autorregresivo, se sostiene en el concepto de que el valor futuro de una serie se explica en una cierta cantidad de pasos anteriores en el tiempo del mismo valor. El modelo ARIMA posee de 3 componentes:

1. Auto regresivo (AR): Este factor representa la dependencia entre un valor observado y un valor observado anteriormente en el tiempo. En otras palabras, es el parámetro que determina cuántos periodos de retraso se incluyen en el modelo.
2. Integrado (I): Este componente muestra la diferenciación en la serie de tiempo. En otras palabras, elimina tendencias de largo plazo para convertir la serie en estacionaria, de manera que el promedio y la varianza sea constante en el tiempo.
3. Media móvil (MA): Este elemento indica la dependencia entre un valor observado y el error del residuo de un modelo de media móvil aplicado a valores observados anteriormente en el tiempo. Es decir, la cantidad de periodos de error de retraso que se incluyen en el modelo.

A continuación, se creará un modelo de autoregresión para predecir el total de pedidos en un periodo de tiempo futuro. Para crear este modelo, se deben determinar los componentes mencionados anteriormente, los cuales llamaremos p (AR), d (I) y q (MA). Estos parámetros deben ser elegidos mediante comparaciones para obtener los valores óptimos.

En primer lugar, se determinarán los parámetros p y q que están relacionados con la cantidad de periodos anteriores que debe incluir el modelo. En este caso, se usará la función de autocorrelación y la función de autocorrelación parcial. Estas funciones son útiles para determinar visualmente cuáles son los valores óptimos a incluir en el modelo de autoregresión.

Por un lado, la función de autocorrelación (ACF) expresa la correlación entre una observación en un momento determinado y las observaciones anteriores en un periodo de tiempo. La ACF permite encontrar el valor óptimo q en el modelo ARIMA.

Por otro lado, la función de autocorrelación parcial (PACF) muestra la correlación entre una observación en un momento determinado y las observaciones anteriores a lo largo del tiempo, luego de que se hayan eliminado las correlaciones explicadas por las observaciones anteriores. La PACF permite encontrar el valor óptimo p en el modelo ARIMA.

A través del paquete de modelos estadístico *statsmodels*, se grafica la ACF y PACF de la serie de tiempo de pedidos de la empresa. En los siguientes gráficos, se mostrará en el eje X la cantidad de períodos de retraso entre 1 y 24, mientras que en el eje Y el valor de la función correspondiente. Además, en cada gráfico se agrega una representación del intervalo de confianza donde se espera que caigan las correlaciones aleatorias de la serie de tiempo. Se espera que a un nivel de confianza del 95% las correlaciones aleatorias se coloquen dentro del intervalo de confianza, por lo que las correlaciones fuera de este intervalo no serían aleatorias, si no que son esencialmente de la serie de tiempo, y son cantidades de períodos óptimas para incluir en el modelo ARIMA.

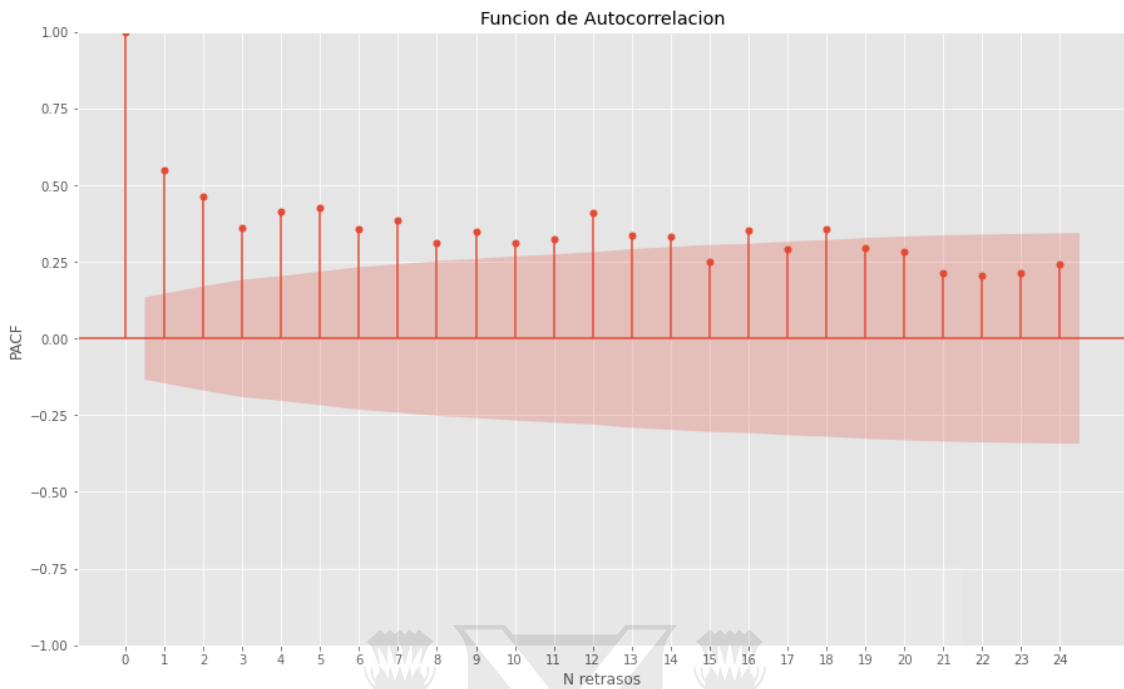


Figura 15. Función de autocorrelación ACF para los datos de pedidos. Fuente de elaboración propia.




Figura 16. Función de autocorrelación PACF para los datos de pedidos. Fuente de elaboración propia.

Mediante esta ayuda visual, se determina que para el parámetro p incluir 12 retrasos en el modelo es un número óptimo dado que contempla información relevante de los datos y es un valor significativo de la serie. Además, al ser una serie de tiempo con valores mensuales, se puede pensar que es lógico que el valor de p sea igual a 12, dado que puede existir una estacionalidad anual para los datos. Mientras que para el parámetro q , se determina tomar el valor 5, dado que muestra una autocorrelación parcial aún significativa y a partir de ese valor se muestra una caída de PACF, por lo que se interpreta que hasta un retraso de 5 periodos están correlacionados los residuos para incluir en el modelo ARIMA.

Para obtener el valor del parámetro d , se realizará una prueba estadística llamada “prueba de Dickey-Fuller aumentada” (ADF). Esta prueba consiste en determinar si una serie de tiempo es estacionaria o no, mediante una hipótesis nula y una hipótesis alternativa. La hipótesis nula es que la serie de tiempo no es estacionaria, por lo tanto necesita transformación para convertirse en estacionaria y poder ser utilizada en el modelo ARIMA. Por otra parte, la hipótesis alternativa significa que es estacionaria y no necesita ningún tipo de transformación. En este caso, se realiza la prueba para distintos valores del parámetro d , y se evalúa el valor p de la prueba ADF para determinar si la hipótesis nulas se rechaza. El valor p de la prueba mide la probabilidad de la evidencia en contra de la hipótesis nula. Se establece un nivel de significancia donde si el valor p es menor que el nivel de significancia se rechaza la hipótesis nula, dando por válida la hipótesis alternativa.

En este caso, se establece un nivel de significancia 0.05, y se realiza la prueba para valores d entre 0 y 12. En cada iteración, se realiza una diferenciación de orden d a los datos de la serie temporal, y se calcula el valor p de la prueba ADF.

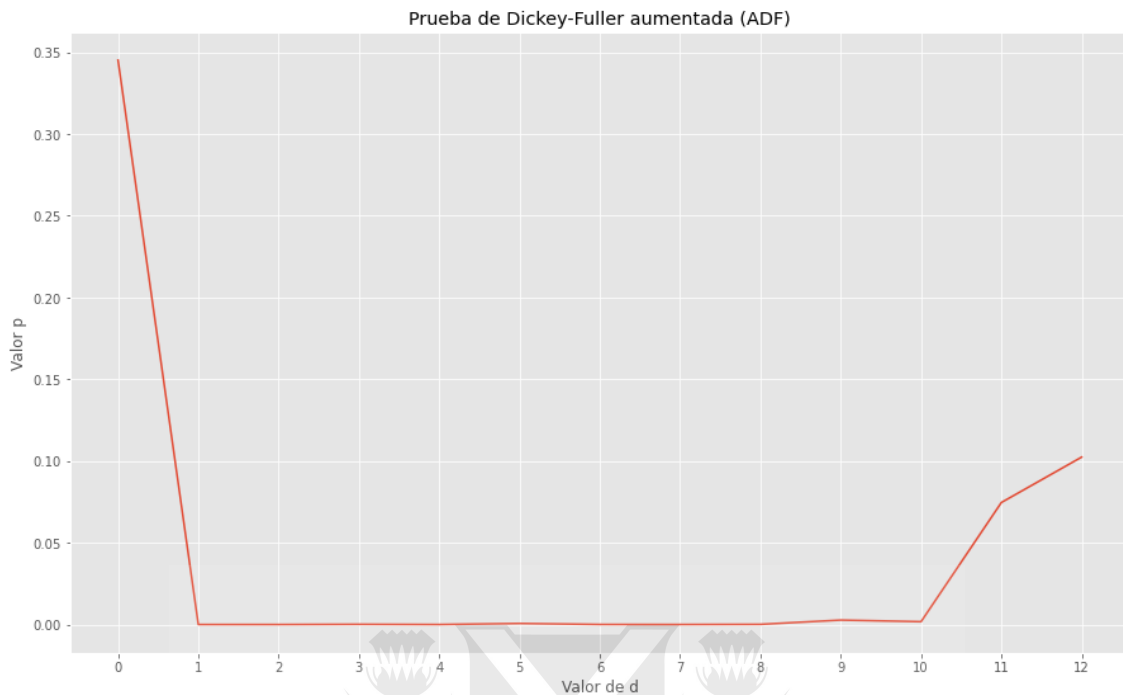


Figura 17. Prueba ADF para los datos de pedidos. Fuente de elaboración propia.

El objetivo de esta iteración es encontrar el valor d que produzca el menor valor p , que en este caso, determina que la serie estacionaria.

Se puede observar gráficamente que el valor $d = 1$, comprueba que la serie temporal es estacionaria, por lo tanto, se determina que el parámetro d será igual a 1 para incluir en el modelo ARIMA.

Una vez que contamos con los parámetros $p = 12$, $d = 1$ y $q = 5$, se ajustará un modelo ARIMA a los datos. Antes de ajustar el modelo, se decide dividir el dataset principal de pedidos en 2: entrenamiento y validación. Para esta división, se toma el primer 80% de los datos para entrenar, y el último 20% de los datos para validar. Es decir, con los datos de 01/2005 a 03/2019 se ajustarán los parámetros del modelo, y se realizará una predicción para los datos de 04/2019 a 10/2022. Con la comparación de los datos esperados en la validación y la predicción para ese periodo, se obtendrá el error MSE que

computa el promedio del cuadrado de los errores. En este caso, el MSE del modelo es de 276.218, representando el MSE a un valor en la misma escala que los datos de entrada, se obtiene que el error esperado es de 525 toneladas. Mientras que el error promedio mensual esperado es de 80 toneladas para la etapa de validación. A continuación, se muestra el gráfico con la serie completa de los pedidos, y el agregado de la predicción a partir de 04/2019.

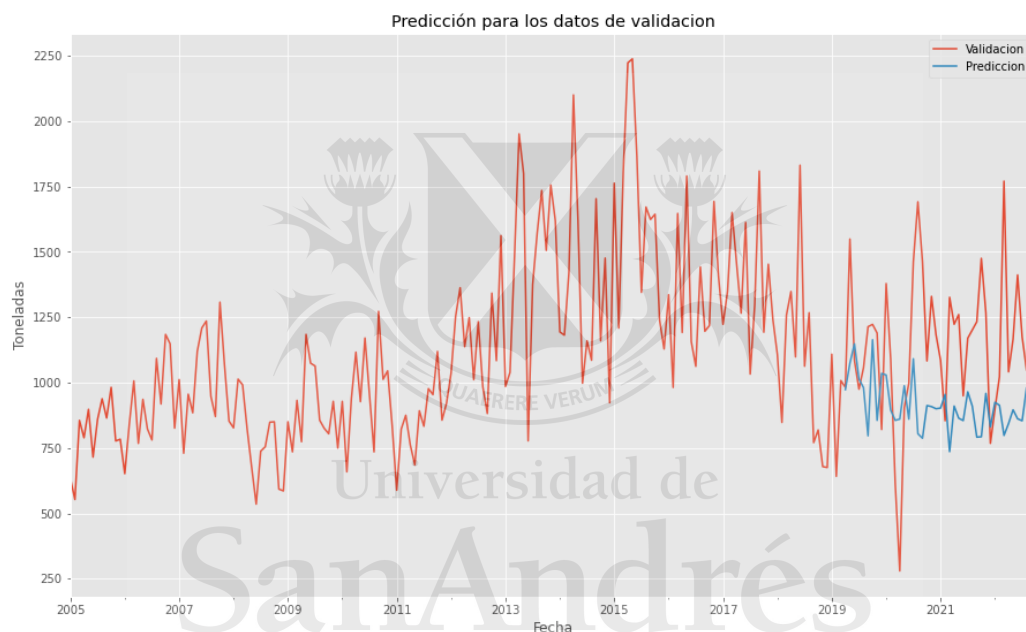


Figura 18. Predicción mediante ARIMA. Fuente de elaboración propia.

Un punto importante de trabajar con ARIMA en el análisis de series temporales es que estos modelos se limitan a series temporales estacionarias. Esto último significa que los promedios y varianza de la serie temporal no cambian en el tiempo. Es decir, los componentes de una serie deben ser estables en los distintos puntos del tiempo. Por lo tanto, utilizar estos modelos cuando una serie de tiempo no es estacionaria se convierte en una dificultad a la hora de intentar realizar una predicción en el futuro.

A pesar de buscar parámetros óptimos y diferentes maneras de ajustar un modelo, para este estudio se buscará un mejor modelo que pueda predecir la cantidad de toneladas de pedidos en un periodo futuro. Por lo tanto, se avanzará en el diseño de un modelo predictivo mediante machine learning en el siguiente apartado.

3.5 Modelado con deep learning: modelo de red neuronal MLP

En esta sección, se piensa en aplicar un algoritmo de deep learning para la predicción de los valores de pedidos futuros. Las redes neuronales artificiales poseen de mayor poder a la hora de modelar series temporales que no son estacionarias, dado que gracias a la capacidad de procesamiento que tienen pueden aprender patrones más complejos que habitan en los datos.

El autor Jason Brownlee (2020), sostiene que la predicción de series temporales es complicada, dado que es grande la dependencia de las observaciones anteriores, a diferencia de los problemas de regresión o clasificación. Además, Brownlee (2020) explica que los modelos ARIMA en un principio fueron útiles para resolver muchos problemas de manera efectiva, pero que dadas las limitaciones que tienen como por ejemplo relaciones lineales, datos univariados, pronósticos de un paso y dependencia temporal fija, el machine learning puede ser una solución superadora a los problemas más complejos donde existen muchas variables de entrada, no linealidad, etc.

El autor, trae a colación las redes neuronales MLP (*multilayer perceptron*). Este tipo de redes neuronales artificiales cuentan con una capa de entrada, capas ocultas, y capa de salida, que serán explicadas en las siguientes líneas con el caso de estudio presente.

Las redes neuronales multicapa son más robustas al ruido y a la no linealidad, tal como argumenta Brownlee (2020), por este motivo se presumen más valiosas para la predicción de series de tiempo. En este sentido, se considera

que dadas las múltiples variables de entrada incluidas en el dataset, es conveniente utilizar un modelo de redes neuronales MLP dado que gracias a su capacidad de aprendizaje y mediante sus capas ocultas, podrá detectar estos patrones en los datos que se le proporcionen como entrada.

Tal como se mencionó anteriormente, las redes neuronales artificiales son modelos matemáticos basados en el funcionamiento del cerebro humano. A través de nodos interconectados atraviesa la información desde una entrada hacia una salida.

Gustavo Lado (2020) explica el funcionamiento de las redes neuronales MLP, donde existen, además de una capa de entrada y una capa de salida, capas ocultas. En la misma línea, Lado (2020) menciona que la conexión entre las capas se pueden notar como **pesos**, donde la información se propaga hacia adelante a través de las capas, y representan la eficacia con que se transmite esta información.

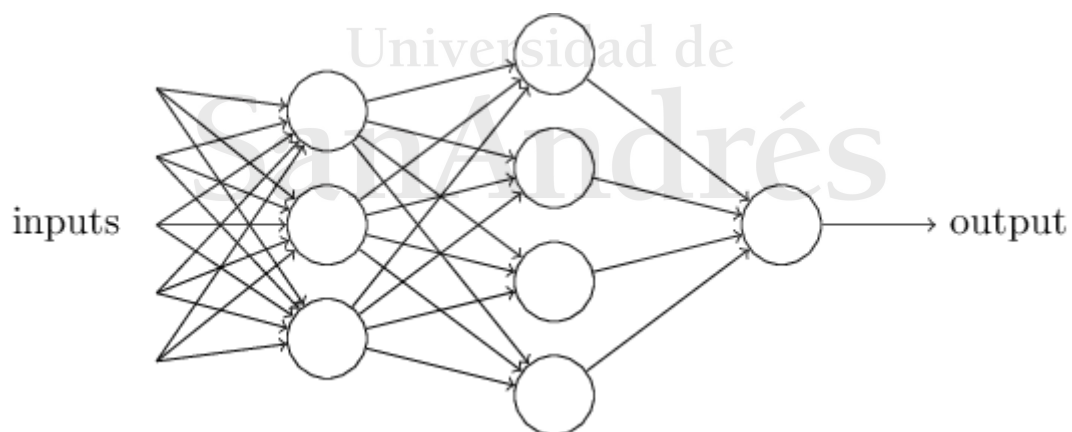


Figura 19. Arquitectura de una red neuronal: Las conexiones entre las neuronas son los pesos por los cuales se activan los valores. Imagen extraída de "Neural Networks and Deep Learning" de Michael Nielsen. (p. 4).

Este proceso mediante el cual la información se propaga hacia adelante desde la capa de entrada hasta la capa de salida se llama *feedforward*.

El aprendizaje de la red neuronal se obtiene a través del algoritmo *backpropagation*. En este proceso, mediante una función de costo, se busca minimizar el error entre los valores de salida deseados y los valores predichos, de manera que en cada iteración del aprendizaje de la red se actualizan los pesos en la búsqueda de optimizar esta función de costo hasta llegar al mínimo error aceptable. Cuando se intenta obtener el mínimo de la función de costo, se van modificando los pesos de manera que se obtienen nuevos puntos en la función de costo a evaluar en la búsqueda del punto mínimo.

Para diseñar el modelo de red neuronal se necesitan determinar los siguientes principales parámetros:

- cantidad de variables en la capa de entrada y en la capa de salida
- cantidad de capas ocultas y respectivas unidades de neuronas en cada capas
- funciones de activación en las capas ocultas y de salida
- función de pérdida del error
- learning rate
- optimizador

Tal como se mencionó en apartado **3.3.3**, el dataset cuenta con 63 variables de entrada y 1 variable de salida. En este caso, se definen 4 capas ocultas con la siguiente cantidad de neuronas: 128, 64, 32 y 16 respectivamente.

Para todas las capas, la función de activación establecida es la función **ReLU**. Esta función consiste en una función no lineal, que permite aprender patrones

complejos de los datos, y lo que realiza es obtener un valor de entrada x y devuelve el valor máximo entre 0 y X . ReLU desactiva los valores negativos que se propagan en la red, y esto es importante en este estudio dado que los pedidos siempre son mayores a 0, por lo que se espera siempre un valor positivo. Esta función es simple y se define de la siguiente manera:

$$f(x) = \max(0, x)$$

A modo de ejemplo, se puede observar gráficamente cómo evalúa la función cada valor de x entre -10 y 10 y retorna un valor:




Figura 20. Función de activación ReLU. Fuente de elaboración propia.

En este caso, se utilizó como métrica de error la métrica “Mean Squared Error (MSE)”. El MSE compara el valor de salida obtenido en la predicción y el valor

de salida deseado, y calcula la suma de los errores al cuadrado dividida por el tamaño de la muestra, según se explica en el artículo “Mean Squared Error” en Wikipedia (2022).

Además, existen 2 métricas MSE para cada modelo entrenado. Por un lado, existe el MSE obtenido durante el entrenamiento, es decir, el error generado por los datos de entrenamiento. Esta métrica sirve para evaluar la performance del modelo en relación a los datos de salida deseados.

Por otro lado, se obtiene el MSE de la validación, que es el error que se genera con los datos de validación, es decir, aquellos datos que no fueron usados para entrenar el modelo. Esta métrica de error es importante para entender cómo funciona el modelo con datos desconocidos.

La métrica MSE tiene algunas ventajas importantes:

- Penalizar errores grandes: al elevar al cuadrado la diferencia entre el valor deseado y la predicción, castiga las diferencias más significativas, y es bueno para los modelos que requieren alta precisión.
- Ajuste de parámetros: se puede calcular el gradiente y de esta manera utilizar técnicas de optimización para ajustar los parámetros del modelo y obtener una precisión mejor.

La función matemática es la siguiente:

$$MSE = \frac{1}{n} * \sum_{i=1}^{i=n} (y_i - \hat{y}_i)^2$$

donde n es la cantidad de observación, y_i es el valor real de la observación i y \hat{y}_i es el valor predicho por el modelo MLP para la observación i .

El *learning rate* es un hiper parámetro de la red que expresa cuánto debe cambiar el modelo en base a las correcciones de los pesos que se hace en

cada iteración del entrenamiento. Si el *learning rate* es bajo, el modelo necesitará muchas iteraciones para ajustar los pesos de la mejor manera. En cambio, un valor muy alto puede ocasionar una variación constante de los pesos de la red y no converger a un óptimo nunca. En este caso, se define inicialmente un *learning rate* = 0.001, dado el optimizador que se utilizará.

Por último, el optimizador es el algoritmo que trabaja en el ajuste de los pesos de la red neuronal durante la etapa de entrenamiento del modelo, y busca los valores óptimos para los pesos de manera que el valor predicho se acerque al valor esperado. En machine learning existen distintos optimizadores, y en este caso se utilizará el optimizador Adam, el cual es un optimizador popular en aprendizaje profundo, con las ventajas de que puede converger a un mínimo rápidamente y es menos susceptible a caer en mínimos locales.

Una vez establecidos los parámetros principales del modelo MLP, se puede observar visualmente la arquitectura de la red:

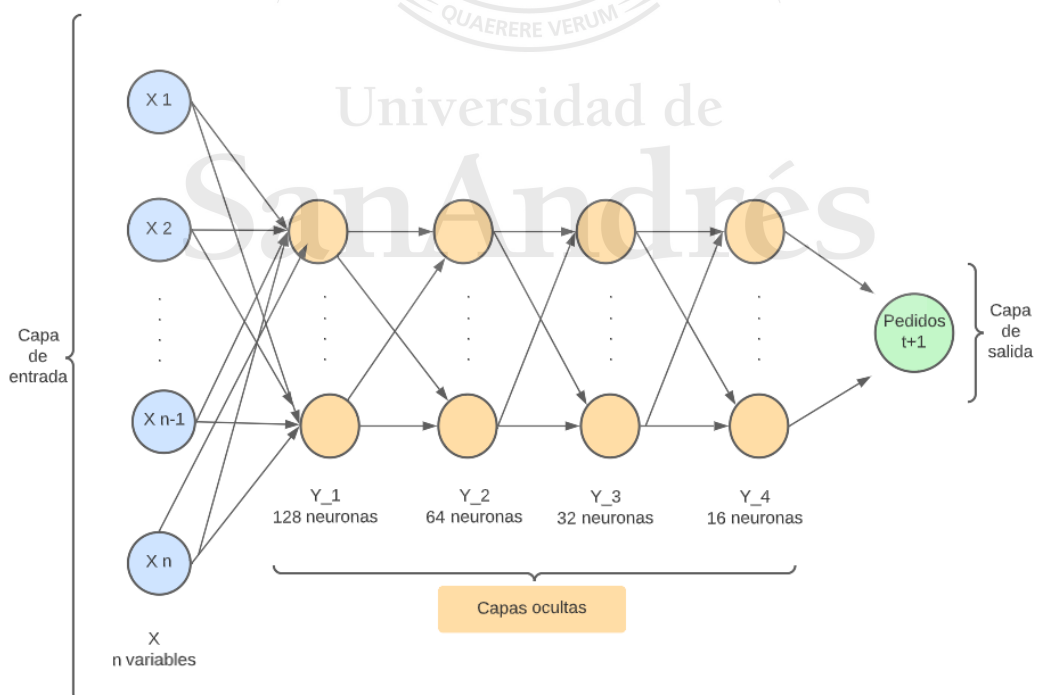


Figura 21. Arquitectura de la red MLP propuesta. Fuente de elaboración propia.

donde cada conexión entre las neuronas significan los pesos de la red por los cuales se transmite la información, y en cada neurona se aplica la función de activación antes de disparar el siguiente valor.

Luego de definir los parámetros del modelo y la arquitectura de la red, se utilizó la técnica de cross-validation para estimar el error de predicción del modelo sobre el set de datos de entrenamiento, que comprende el primer 80% de los datos, al igual que la división de datos en el modelo ARIMA. Además de evaluar la capacidad predictiva del modelo y evitar overfitting, esto nos permite seleccionar los hiper parámetros del modelo (como ser el *learning rate*, la cantidad de capas, funciones de activación, etc.). Principalmente, lo que se realiza mediante esta técnica es dividir los datos de entrenamiento en K partes, y entrenar sobre los K-1 parte de los datos, para validar con la parte de los datos que queda afuera. Para obtener el error del modelo, se calcula el promedio de las métricas obtenidas en la validación con cada uno de los K modelos.

Este modelo fue entrenado con $K = 5$ (o, sea 5 partes), por lo tanto, en cada entrenamiento el modelo utilizó el 80% de los datos de entrenamiento para entrenar y el 20% restante para validar. En otras palabras, el modelo se entrena 5 veces con datos distintos y evalúa el error con datos que no fueron utilizados en el entrenamiento. El error de entrenamiento del modelo consiste en el promedio de los errores de los k modelos, y para transformar el MSE a la escala de los datos de entrada, en este caso toneladas, se calcula la raíz del MSE, lo que determina un promedio de error absoluto. Además, dado que el MSE calcula la sumatoria de los errores, se calcula una métrica de error mensual, donde se divide el MSE promedio del modelo en la cantidad de meses que contiene cada k fold con los que se entrenó. Luego, se entrena el modelo con la totalidad del set de datos de entrenamiento, es decir, el primer 80% de la historia, y se predice para el siguiente 20% de los datos que el modelo no conoce, y se valida nuevamente el error del modelo en la predicción.

En este caso en particular, con los parámetros definidos, se entrena y valida el modelo con distintos n de meses anteriores para comprobar métricas de errores y elegir el modelo que mejor realice la predicción, y definir una ventana de tiempo atrás para tomar como parámetro n.

Resultados entrenamiento modelo MLP:

nMesesAtras	MSE_cv	MSE_val	MSE_cv en Toneladas	MSE_val en Toneladas	Error promedio mensual (ton) cv	Error promedio mensual (ton) val
3	871,422	119,886	934	346	161	53
6	870,712	101,915	933	319	162	49
9	877,934	76,288	937	276	164	43
12	896,366	71,569	947	268	167	42
15	429,867	1,347,085	656	1,161	116	184
18	570,032	77,364	755	278	135	44

En este caso, vemos que al entrenar el modelo MLP, el mejor parámetro n de meses anteriores a tomar para predecir el siguiente mes, es el que utiliza una ventana de 12 meses atrás, dado que en la validación presenta un error de 42 toneladas mensuales. Para contextualizar este dato, durante 2022 el promedio mensual de pedidos ingresados en toneladas fue de 1050, por lo que el error en la validación representa un 4% del total de toneladas mensuales.

A continuación, se presenta la predicción realizada por el modelo MLP con n = 9 para los datos de validación:




Figura 22. Predicción realizada por el modelo MLP. Fuente de elaboración propia.

Si bien visualmente se puede pensar que lo que predice el modelo es similar a los datos de validación, existen picos en la predicción que deben ser trabajados. Un punto a favor de este modelo sobre el de modelo ARIMA, es que en la predicción se acierta en la caída de los pedidos ocasionado por la pandemia de 2020.

Pese a obtener resultados a priori favorables con el modelo MLP, se busca mejorar la predicción y se incurre en la aplicación de redes neuronales recurrentes para la predicción de pedidos.

3.6 Modelado con deep learning: modelo de red neuronal LSTM

En esta sección se explicará la aplicación de un modelo de red neuronal recurrente llamado LSTM (Long Short Term Memory). Las redes LSTM son un tipo de red neuronal capaz retener información relevante en la secuencia de

propagación de la información, presentadas por Hochreiter & Schmidhuber (1997). A diferencia de las capas del modelo MLP, los autores explican que estas capas LSTM tienen la capacidad de almacenar u omitir la información según la relevancia para el trabajo que se intenta resolver, con una memoria a largo plazo. LSTM tiene una especie de “compuertas” que controlan el flujo de información que debe salir hacia la siguiente capa. La implementación de LSTM es interesante en problemas secuenciales dado que gracias a su memoria a largo plazo y su poder de agregar o eliminar información puede controlar eficientemente el flujo de información que se propaga para la predicción de salida. Algunos campos donde se trabaja con LSTM son las series de tiempo, procesamiento de lenguaje natural, generación de texto, reconocimiento de voz, detección de anomalías, entre otros.

La estructura de la red elegida, consiste en una capa de entrada con $n*7$ variables y una capa de salida con 1 unidad, al igual que en el modelo MLP. Las capas ocultas serán 5 LSTM. Se repiten los mismos hiper parámetros elegidos en el modelo MLP:

- *learning rate* = 0.001
- Funciones de activación ReLU en todas las capas ocultas, y de salida.
- Función de error MSE.
- Optimizador Adam

En el caso de estudio de este trabajo, la arquitectura de la red neuronal LSTM utilizada para la predicción se puede visualizar de la siguiente manera:

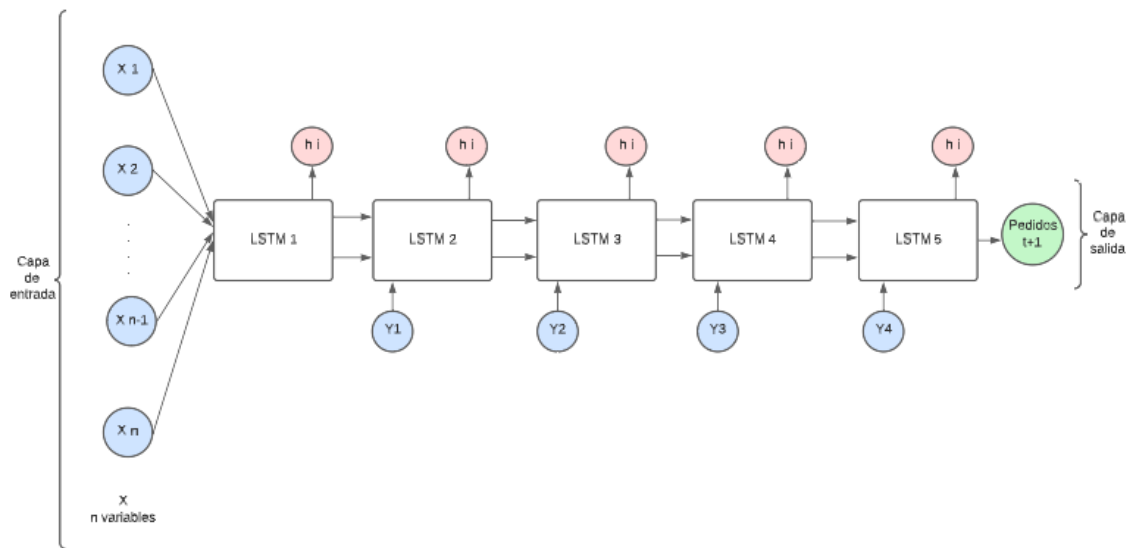


Figura 23. Arquitectura de la red LSTM propuesta. Fuente de elaboración propia.

Una vez que se eligió la arquitectura e hiperparámetros, se procede a entrenar con la misma técnica de cross-validation utilizada en el modelo MLP.

De la misma manera, se entrenan modelos con 3, 6, 9, 12, 15 y 18 meses atrás como variables de entrada, para comparar y definir cuál es el mejor modelo.

Resultados LSTM:

MesesAtras	MSE_cv	MSE_val	MSE_cv en toneladas	MSE_val en toneladas	Error promedio mensual (ton) cv	Error promedio mensual (ton) val
3	49,236	62,414	222	250	38	38
6	55,510	56,624	236	238	41	37
9	58,399	53,178	242	231	42	36
12	316,127	1,342,924	562	1,159	99	181
15	327,727	66,840	572	259	102	41
18	331,946	76,329	576	276	103	44

Al igual que en el modelo LPM, el mejor modelo se da cuando se mira una ventana de tiempo con 9 meses atrás al mes que se quiere predecir. El error

entonces promedio mensual del entrenamiento es 42 toneladas, mientras que el error esperado en la validación es de 36 toneladas. En este caso, el error representa un 3.4% del promedio mensual de pedidos ingresados durante 2022. En otras palabras, este indicador es muy útil para entender la relevancia del modelo: un 3% de error mensual esperado en problemas de predicción para series de tiempo tan complejas y relacionadas con distintas variables del mercado textil y variables macroeconómicas significa que la empresa puede basarse en este modelo para predecir los pedidos que ingresarán el siguiente mes, y utilizar esto para anticiparse a la demanda y stockearse de insumos productivos de manera óptima.

A continuación, se muestra la predicción realizada por el modelo LSTM con $n = 9$:




Figura 24. Predicción realizada por el modelo LSTM. Fuente de elaboración propia.

En la visualización se puede observar que el modelo predice bastante bien las variaciones ocasionadas por la pandemia, y además se ajusta bien a la nueva normalidad de pedidos ingresados en la empresa post pandemia.

Luego de entrenar distintos modelos predictivos, y hacer pruebas con distintas cantidades de meses atrás que se tomaban para usar como ventana de tiempo, hiper parámetros y modificar el tipo de la red neuronal empleada, analizando las comparaciones de métricas de error esperado, se determina que el mejor modelo obtenido es el presentado en este apartado: un modelo LSTM con 9 meses atrás como ventana de tiempo input.

En resumen, teniendo en cuenta las distintas variables que se deben analizar para realizar una predicción de la demanda, se supone que este modelo puede generalizar notablemente la información de entrada y se obtiene un error de predicción bajo.

3.7 Estimación de la proporción de cada hilado del total

Una vez que se cuenta con el modelo para la predicción total de pedidos, se debe determinar qué proporción del total le corresponde a cada artículo.

En este caso, para limitar el alcance del presente trabajo, se decide como primera aproximación que cada artículo tendrá una proporción del total de pedidos para cada mes del año de manera estadística.

Como vimos en el análisis anterior, el momento del tiempo influye demasiado en los pedidos, y año a año varía la demanda. No es lo mismo las ventas de enero del 2022 que las ventas de enero del 2013. Por lo tanto, se resuelve tomar los últimos dos años para la estimación de la proporción. Es decir, para el artículo X en enero de 2023, se tomará el promedio de las proporciones de enero 2022 y enero 2021. De esta manera, se busca obtener proporciones cercanas en el último tiempo para poder estimar de mejor manera la tendencia.

Trabajos futuros podrían evaluar la posibilidad de utilizar modelos de Machine Learning para hacer esta estimación.

La fórmula que determina la proporción del total de un artículo para el mes y el año determinado es:

$$proporcion_{artículo, mes, año} = \frac{1}{2} * \sum_{i=1}^{i=2} proporción_{artículo, mes, año-1}$$

Ejemplos:




Figura 25. Comparación de proporciones real vs estimada para el artículo “10 OE Friza Alg” . Fuente de elaboración propia..




Figura 26. Comparación de proporciones real vs estimada para el artículo “08 OE Wat Alg” . Fuente de elaboración propia

De esta manera, podemos calcular la proporción para Noviembre de 2022 para cada hilado:

Hilado	Proporción Esperada Nov/2022
1.0 - S/C - WAT - PABILO CRU	5.1%
10.0 - OE - BON - 50% POAL	6.1%
10.0 - OE - FRIZA - ALG	1.9%
10.0 - OE - WAT - ALG	12.7%
12.0 - OE - BON - 50% POAL	2.6%
12.0 - OE - BON - SOCK COL	0.1%
12.0 - OE - FRIZA - ALG	3.3%
12.0 - OE - WAT - ALG	6.4%
14.0 - OE - WAT - ALG	3.2%
14.0 - OE - WAT - COLOR	0.3%
16.0 - OE - BON - ALG	1.8%
16.0 - OE - WAT - ALG	16.5%
20.0 - OE - BON - ALG	1.2%
20.0 - OE - WAT - ALG	16.1%
24.0 - OE - BON - 50% POAL	0.2%
24.0 - OE - BON - 95/5% MEL	1.2%
24.0 - OE - BON - ALG	11.2%
24.0 - OE - WAT - ALG	4.8%
8.0 - OE - BON - ALG	1.1%
8.0 - OE - WAT - ALG	3.0%
8.0 - OE - WAT - COLOR	1.1%

Con un modelo de predicción del total de pedidos definidos y proporciones del total para cada artículo esperadas establecidas, en el siguiente capítulo se comparan los modelos mirando los pedidos para cada artículo, y además se comparan los insumos necesarios para satisfacer esos pedidos, en términos de unidades y monetarios.

3.8 Fórmulas de insumos productivos por artículo

Los insumos productivos se utilizan en la parte final de la producción de hilado y en la etapa posterior de empaquetado para mandar a distribución. Los insumos están determinados por la cantidad de hilado, es decir, por los kilos que se están produciendo de un hilado. Como se mencionó anteriormente, cada hilado tiene su respectivo insumo principal (tubo) y su formato de empaque. A su vez, cada formato de empaque tiene una cantidad de insumos de empaque a utilizar. La necesidad de estos insumos para determinada cantidad de hilados, están determinados por fórmulas establecidas que proporciona el Departamento de Producción y Planta de TN & Platex.

En resumen, los insumos productivos se pueden explicar en dos partes:

- Insumo principal: es el tubo en donde va enrollado el hilado. En principio, cada artículo tiene un tubo distinto.
- Insumos de empaque: son los insumos que se utilizan para el armado de cajas o pallets (según corresponda en base al artículo a empaquetar), como por ejemplo pallets, cajas, cintas, separadores, bolsas, etc.

Cada insumo tiene una cierta capacidad de hilado que puede contener, por tal motivo se utilizan las fórmulas establecidas para obtener la necesidad de insumos productivos.

En la siguiente tabla, se puede ver cada artículo del estudio, formato de empaque, su correspondiente tubo que utiliza y la cantidad de kg de hilado que caben en el tubo:

Agrupacion	IdFormato	Codigoinsumo	Producto	KgPorTubo
1.0 - S/C - WAT - PABLO CRU	1	19-03-554	TUBO CARTON P/O-E REMACHADO 170 MM. NATURAL	3.5
10.0 - OE - BON - 50% POAL	2	19-03-568	TUBO CARTON P/O-E REMACHADO 170 MM. RAYA VERDE	2.5
10.0 - OE - FRIZA - ALG	2	19-03-573	TUBO CARTON P/O-E REMACHADO 170 MM. PINTA NARANJA	3.5
10.0 - OE - WAT - ALG	2	19-03-328	TUBO CARTON P/O-E REMACHADO 170 MM. LLENO BLANCO	3.5
12.0 - OE - BON - 50% POAL	2	19-03-572	TUBO CARTON P/O-E REMACHADO 170 MM. RAYA AMARILLO	2.5
12.0 - OE - BON - SOCK COL	2	19-03-540	TUBO CARTON P/O-E REMACHADO 170 MM. LLENO AMARILLO	2.5
12.0 - OE - FRIZA - ALG	2	19-03-561	TUBO CARTON P/O-E REMACHADO 170 MM. PINTA AZUL	3.5
12.0 - OE - WAT - ALG	3	19-03-572	TUBO CARTON P/O-E REMACHADO 170 MM. RAYA AMARILLO	3.5
14.0 - OE - WAT - ALG	3	19-03-849	TUBO CARTON P/O-E REMACHADO 170 MM. ESTRELLA NEGRO	3.5
14.0 - OE - WAT - COLOR	2	19-03-849	TUBO CARTON P/O-E REMACHADO 170 MM. ESTRELLA NEGRO	3.5
16.0 - OE - BON - ALG	2	19-03-851	TUBO CARTON P/O-E REMACHADO 170 MM. ESTRELLA VERDE	2.5
16.0 - OE - WAT - ALG	3	19-03-560	TUBO CARTON P/O-E REMACHADO 170 MM. PINTA ROJO	3.5
20.0 - OE - BON - ALG	2	19-03-562	TUBO CARTON P/O-E REMACHADO 170 MM. PINTA VERDE	2.5
20.0 - OE - WAT - ALG	3	19-03-566	TUBO CARTON P/O-E REMACHADO 170 MM. PINTA MARRON	3.5
24.0 - OE - BON - 50% POAL	2	19-03-847	TUBO CARTON P/O-E REMACHADO 170 MM. ESTRELLA AZUL	2.5
24.0 - OE - BON - 95/5% MEL	2	19-03-847	TUBO CARTON P/O-E REMACHADO 170 MM. ESTRELLA AZUL	2.5
24.0 - OE - BON - ALG	2	19-03-567	TUBO CARTON P/O-E REMACHADO 170 MM. PINTA VIOLETA	2.5
24.0 - OE - WAT - ALG	3	19-03-563	TUBO CARTON P/O-E REMACHADO 170 MM. PINTA NEGRO	3.5
8.0 - OE - BON - ALG	3	19-03-571	TUBO CARTON P/O-E REMACHADO 170 MM. RAYA AZUL	2.5
8.0 - OE - WAT - ALG	3	19-03-569	TUBO CARTON P/O-E REMACHADO 170 MM. RAYA ROJO	3.5
8.0 - OE - WAT - COLOR	2	19-03-560	TUBO CARTON P/O-E REMACHADO 170 MM. PINTA ROJO	3.5

De la misma manera, para cada formato de empaque se puede observar que insumos de empaque utiliza y que cantidad en la siguiente tabla:

IdFormato	formato	bobinas_modulo	cantidad	CodigoinsumoEmpaque	ProductoEmpaque
1	Pabilo	140	0.25	19-04-327	CINTA ADHESIVA TRANSPARENTE 50 MM. X 100 MTS.
1	Pabilo	140	0.005	19-04-354	ETIQUETA AUTOADHESIVA 105 MM. X 153 MTS. B751B ILUSTR. BLANCA
1	Pabilo	140	0.005	19-04-359	CARBONICO RIBBON 110 MM. X 153 MTS. CERA
1	Pabilo	140	0.5	19-03-364	POLIETILENO FILM STRETCH 76 CMS. TRANSPARENTE
1	Pabilo	140	7	19-03-398	BOLSA POLIETILENO 120 MICR. 190 X 120 CMS. BLANCO
1	Pabilo	140	1	19-03-451	TARIMA DE MADERA 1350 X 1115 X 100 MM. PL.9007
1	Pabilo	140	7	19-03-714	SEPARADOR CARTON CIEGO 1100 X 1000 MM. 1 CORRUGADO 5 MM. PL.9016
2	CajaTN	450	0.03	19-04-354	ETIQUETA AUTOADHESIVA 105 MM. X 153 MTS. B751B ILUSTR. BLANCA
2	CajaTN	450	0.03	19-04-359	CARBONICO RIBBON 110 MM. X 153 MTS. CERA
2	CajaTN	450	50	19-03-068	SEPARADOR CARTON P/CAJA 435 X 652 MM. PL.9001
2	CajaTN	450	0.7	19-03-364	POLIETILENO FILM STRETCH 76 CMS. TRANSPARENTE
2	CajaTN	450	25	19-03-527	CAJA CARTON 666 X 450 X 526 MM. C/LOGO PL.9000
2	CajaTN	450	0.04	19-04-940	CINTA ADHESIVA TRANSPARENTE 72 MM. X 1000 MTS.
2	CajaTN	450	450	19-03-028	BOLSA POLIETILENO 10 MICR. 42 X 48 CMS.
2	CajaTN	450	1	19-03-866	TARIMA DE MADERA 1350 X 1115 X 130 MM. PL.9006
3	Paletizado	224	0.005	19-04-354	ETIQUETA AUTOADHESIVA 105 MM. X 153 MTS. B751B ILUSTR. BLANCA
3	Paletizado	224	0.005	19-04-359	CARBONICO RIBBON 110 MM. X 153 MTS. CERA
3	Paletizado	224	0.7	19-03-364	POLIETILENO FILM STRETCH 76 CMS. TRANSPARENTE
3	Paletizado	224	1	19-03-714	SEPARADOR CARTON CIEGO 1100 X 1000 MM. 1 CORRUGADO 5 MM. PL.9016
3	Paletizado	224	15	19-03-771	SEPARADOR CARTON 16 PERFORACIONES 1200 X 1200 MM. 6 CORRUGADO 19 MM. PL.9012
3	Paletizado	224	1	19-03-823	TARIMA DE MADERA 1200 X 1200 X 126 MM. REFORZADA PL.9008
3	Paletizado	224	1	19-03-006	LAMINA CUBRE PALLET POLIETILENO 60 MICR. 1600 X 1600 MM. TRANSPARENTE

Por ejemplo, para el formato de empaque "Paletizado", se necesita tarima de madera, láminas cubre tarimas, separadores de cartón, etiquetas autoadhesiva, etc.

Cada formato de empaque, tiene una cantidad de tubos de hilado que puede abarcar. El formato "Pabilo" tiene una capacidad de 140 tubos de hilado, el

formato “Caja” tiene una capacidad de 450 tubos de hilado y el formato “Paletizado” tiene una capacidad de 224 tubos de hilado.

Los insumos de empaque tienen una medida de utilización. La base de datos que provee la empresa, determina el comportamiento de la columna “cantidad”:

- Si la cantidad indica un valor menor a 1, significa que la necesidad está compuesta por la siguiente fórmula:

$$CantidadNecesaria = Cantidad * KgHilado$$

Los insumos que presentan una cantidad menor a 1, significa que el valor de ese campo en la base de datos interna representa una proporción que debe atribuirse ese insumo respecto de los kilos de hilado.

- Si la cantidad indica un valor mayor o igual a 1, significa que la necesidad está determinada por la siguiente ecuación:

$$CantidadNecesaria = \frac{cantidadTubos}{bobinasModulo} * Cantidad$$

Los insumos con valor mayor a 1 en la cantidad, expresan que son insumos de empaque que se atribuyen a una cantidad grande de tubos del hilado.

A modo de ejemplificación, se presenta el siguiente diagrama que muestra cómo se determinan la necesidad de insumos:

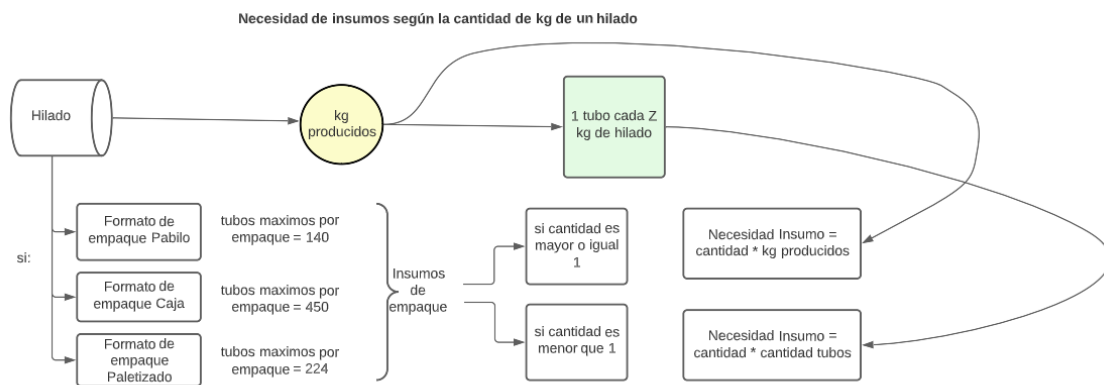


Figura 27. Diagrama de necesidad de insumos productivos según kilos de un artículo. Fuente de elaboración propia.



CAPÍTULO 4 - ANÁLISIS Y RESULTADOS FINALES

4.1 Análisis de resultados obtenidos en los modelos de predicción

Con los distintos modelos entrenados de ARIMA, MLP y LSTM, se seleccionan los mejores modelos de cada tipo ya mencionados y se comparan los errores mensuales esperados de cada modelo, tanto para la etapa de entrenamiento por cross validation y para la etapa de validación.




Figura 28. Comparación de errores entre los modelos ARIMA, MLP y LSTM.

Fuente de elaboración propia.

Se concluye en que el modelo LSTM con 9 meses como ventana de tiempo para las variables de entrada es el que mejor predice. Este modelo representa un 3% de error respecto a los pedidos por mes promedio en 2022. Significa, una clara aproximación a implementar modelos de machine learning para el beneficio de la empresa en términos logísticos, de almacén y económicos.

4.2 Predicción de necesidad de insumos para Noviembre 2022

En este apartado se comparará la predicción realizada y la programación de producción con los pedidos reales que ingresaron ese mes. En siguiente término, con las proporciones mencionadas en la **sección 3.7** se determinará la cantidad de kilos para cada hilado determinado por la predicción. Por último, mediante las fórmulas expresadas en la **sección 3.8** se presentará la necesidad de cada insumo, junto a su costo de compra total para la predicción, la realidad, y el programa de producción. El objetivo de esta sección es conocer cuál es la ventaja que tiene aplicar esta técnica de predicción, y representar de manera monetaria cómo afectará utilizar este modelo de predicción en la empresa.

El modelo de predicción seleccionado, predijo que para noviembre de 2022 ingresarían pedidos totales en 1138 toneladas. Por otra lado, los kg programados en ese mes fueron de 1208 toneladas totales. La realidad es que en ese mes se ingresaron pedidos en 1002 toneladas. A priori, la diferencia entre la predicción y la realidad es aceptable, y está dentro de lo que se expuso en la presentación de errores del modelo entrenado.

Hilado	Kg Predicción	Kg Realidad	Kg Programados
1.0 - S/C - WAT - PABILO CRU	57,981	52,000	42,000
10.0 - OE - BON - 50% POAL	69,134	62,000	54,000
10.0 - OE - FRIZA - ALG	21,224	2,000	15,000
10.0 - OE - WAT - ALG	144,355	139,000	90,000
12.0 - OE - BON - 50% POAL	29,702	27,000	20,000
12.0 - OE - BON - SOCK COL	1,366	2,000	1,300
12.0 - OE - FRIZA - ALG	37,668	33,000	27,000
12.0 - OE - WAT - ALG	72,832	68,000	55,000
14.0 - OE - WAT - ALG	35,904	33,000	41,000
14.0 - OE - WAT - COLOR	3,755	3,000	6,500
16.0 - OE - BON - ALG	20,939	14,000	26,000
16.0 - OE - WAT - ALG	187,372	165,000	146,000
20.0 - OE - BON - ALG	13,713	9,000	20,000
20.0 - OE - WAT - ALG	183,104	172,500	220,000
24.0 - OE - BON - 50% POAL	2,561	2,500	9,000
24.0 - OE - BON - 95/5% MEL	13,315	8,500	20,000
24.0 - OE - BON - ALG	127,741	118,000	200,000
24.0 - OE - WAT - ALG	55,079	46,000	75,000
8.0 - OE - BON - ALG	12,803	10,000	8,000
8.0 - OE - WAT - ALG	34,538	28,000	54,000
8.0 - OE - WAT - COLOR	12,803	7,500	79,000

De esta manera, las cantidades necesarias de insumos productivos (tubos y de empaque) son las siguientes:

Insumo	Cantidad Necesaria Predicción	Cantidad Necesaria Realidad	Cantidad Necesaria Programación
TUBO CARTON P/O-E REMACHADO 170 MM. ESTRELLA AZUL	6,350	4,400	11,600
TUBO CARTON P/O-E REMACHADO 170 MM. ESTRELLA NEGRO	11,331	10,286	13,571
TUBO CARTON P/O-E REMACHADO 170 MM. ESTRELLA VERDE	8,376	5,600	10,400
TUBO CARTON P/O-E REMACHADO 170 MM. LLENO AMARILLO	546	800	520
TUBO CARTON P/O-E REMACHADO 170 MM. LLENO BLANCO	41,244	39,714	25,714
TUBO CARTON P/O-E REMACHADO 170 MM. NATURAL	16,566	14,857	12,000
TUBO CARTON P/O-E REMACHADO 170 MM. PINTA AZUL	10,762	9,429	7,714
TUBO CARTON P/O-E REMACHADO 170 MM. PINTA MARRON	52,315	49,286	62,857
TUBO CARTON P/O-E REMACHADO 170 MM. PINTA NARANJA	6,064	571	4,286
TUBO CARTON P/O-E REMACHADO 170 MM. PINTA NEGRO	15,737	13,143	21,429
TUBO CARTON P/O-E REMACHADO 170 MM. PINTA ROJO	57,193	49,286	64,285
TUBO CARTON P/O-E REMACHADO 170 MM. PINTA VERDE	5,485	3,600	8,000
TUBO CARTON P/O-E REMACHADO 170 MM. PINTA VIOLETA	51,096	47,200	80,000
TUBO CARTON P/O-E REMACHADO 170 MM. RAYA AMARILLO	32,690	30,229	23,714
TUBO CARTON P/O-E REMACHADO 170 MM. RAYA AZUL	5,121	4,000	3,200
TUBO CARTON P/O-E REMACHADO 170 MM. RAYA ROJO	9,868	8,000	15,429
TUBO CARTON P/O-E REMACHADO 170 MM. RAYA VERDE	27,653	24,800	21,600
Total general	358,397	315,201	386,319

Insumo de Empaque	Cantidad Necesaria Predicción	Cantidad Necesaria Realidad	Cantidad Necesaria Programación
BOLSA POLIETILENO 10 MICR. 42 X 48 CMS.	174,188	149,914	202,262
BOLSA POLIETILENO 120 MICR. 190 X 120 CMS. BLANCO	828	743	600
CAJA CARTON 666 X 450 X 526 MM. C/LOGO PL.9000	9,677	8,329	11,236
CARBONICO RIBBON 110 MM. X 153 MTS. CERA	18,147	15,697	20,239
CINTA ADHESIVA TRANSPARENTE 50 MM. X 100 MTS.	14,495	13,000	10,500
CINTA ADHESIVA TRANSPARENTE 72 MM. X 1000 MTS.	19,932	17,100	22,712
ETIQUETA AUTOADHESIVA 105 MM. X 153 MTS. B751B ILUSTR. BLANCA	18,147	15,697	20,239
LAMINA CUBRE PALLET POLIETILENO 60 MICR. 1600 X 1600 MM. TRANSPARENTE	749	672	768
POLIETILENO FILM STRETCH 76 CMS. TRANSPARENTE	784,923	691,000	837,760
SEPARADOR CARTON 16 PERFORACIONES 1200 X 1200 MM. 6 CORRUGADO 19 MM. PL.9012	11,226	10,073	11,520
SEPARADOR CARTON CIEGO 1100 X 1000 MM. 1 CORRUGADO 5 MM. PL.9016	1,577	1,415	1,368
SEPARADOR CARTON P/CAJA 435 X 652 MM. PL.9001	19,355	16,657	22,474
TARIMA DE MADERA 1200 X 1200 X 126 MM. REFORZADA PL.9008	749	672	768
TARIMA DE MADERA 1350 X 1115 X 100 MM. PL.9007	118	106	86
TARIMA DE MADERA 1350 X 1115 X 130 MM. PL.9006	386	333	450
Total general	1,074,497	941,408	1,162,982

En primer lugar, con los precios de compra de los insumos se determinaron los costos del total del insumo productivo "tubo" necesario para cada hilado:

Hilado	Costo de Tubos Predicción	Costo de Tubos Real	Costo de Tubos Programación
1.0 - S/C - WAT - PABILO CRU	\$ 521,829	\$ 467,996	\$ 378,000
10.0 - OE - BON - 50% POAL	\$ 760,458	\$ 682,000	\$ 594,000
10.0 - OE - FRIZA - ALG	\$ 175,856	\$ 16,559	\$ 124,294
10.0 - OE - WAT - ALG	\$ 1,196,076	\$ 1,151,706	\$ 745,706
12.0 - OE - BON - 50% POAL	\$ 344,549	\$ 313,200	\$ 232,000
12.0 - OE - BON - SOCK COL	\$ 15,834	\$ 23,200	\$ 15,080
12.0 - OE - FRIZA - ALG	\$ 320,708	\$ 280,984	\$ 229,877
12.0 - OE - WAT - ALG	\$ 603,461	\$ 563,441	\$ 455,706
14.0 - OE - WAT - ALG	\$ 297,482	\$ 273,441	\$ 339,706
14.0 - OE - WAT - COLOR	\$ 31,117	\$ 24,853	\$ 53,853
16.0 - OE - BON - ALG	\$ 230,340	\$ 154,000	\$ 286,000
16.0 - OE - WAT - ALG	\$ 1,552,515	\$ 1,367,147	\$ 1,209,706
20.0 - OE - BON - ALG	\$ 159,065	\$ 104,400	\$ 232,000
20.0 - OE - WAT - ALG	\$ 1,517,135	\$ 1,429,294	\$ 1,822,853
24.0 - OE - BON - 50% POAL	\$ 29,696	\$ 29,000	\$ 104,400
24.0 - OE - BON - 95/5% MEL	\$ 154,454	\$ 98,600	\$ 232,000
24.0 - OE - BON - ALG	\$ 1,481,784	\$ 1,368,800	\$ 2,320,000
24.0 - OE - WAT - ALG	\$ 456,373	\$ 381,147	\$ 621,441
8.0 - OE - BON - ALG	\$ 161,312	\$ 126,000	\$ 100,800
8.0 - OE - WAT - ALG	\$ 286,172	\$ 232,000	\$ 447,441
8.0 - OE - WAT - COLOR	\$ 106,082	\$ 62,147	\$ 654,559
Total general	\$ 10,402,297	\$ 9,149,915	\$ 11,199,422

Universidad de

San Andrés

Si se compara el costo total real de ese mes con el costo obtenido por predicción y el costo obtenido por la programación de la producción, el costo de predicción es el que más se acerca al costo real. El costo de predicción es un 14% más que el costo real, mientras que el costo de programación de la producción es un 22% más que el costo real.

Por otra parte, si miramos el costo total de empaque de cada artículo, vemos la siguiente tabla:

Hilado	Costo de Empaque Predicción	Costo de Empaque Realidad	Costo de Empaque Programación
1.0 - S/C - WAT - PABILO CRU	\$ 36,685,662	\$ 32,902,094	\$ 26,575,310
10.0 - OE - BON - 50% POAL	\$ 23,541,793	\$ 21,114,808	\$ 18,390,334
10.0 - OE - FRIZA - ALG	\$ 7,124,198	\$ 670,987	\$ 5,035,837
10.0 - OE - WAT - ALG	\$ 48,456,744	\$ 46,658,982	\$ 30,211,085
12.0 - OE - BON - 50% POAL	\$ 10,114,261	\$ 9,195,167	\$ 6,811,411
12.0 - OE - BON - SOCK COL	\$ 466,489	\$ 681,300	\$ 442,572
12.0 - OE - FRIZA - ALG	\$ 12,645,777	\$ 11,077,620	\$ 9,063,277
12.0 - OE - WAT - ALG	\$ 10,738,390	\$ 10,027,128	\$ 8,108,730
14.0 - OE - WAT - ALG	\$ 5,294,885	\$ 4,864,987	\$ 6,043,873
14.0 - OE - WAT - COLOR	\$ 1,259,338	\$ 1,007,291	\$ 2,181,614
16.0 - OE - BON - ALG	\$ 7,133,495	\$ 4,767,133	\$ 8,854,585
16.0 - OE - WAT - ALG	\$ 27,627,464	\$ 24,327,446	\$ 21,526,060
20.0 - OE - BON - ALG	\$ 4,671,954	\$ 3,065,056	\$ 6,811,411
20.0 - OE - WAT - ALG	\$ 26,999,332	\$ 25,433,709	\$ 32,439,158
24.0 - OE - BON - 50% POAL	\$ 869,695	\$ 851,228	\$ 3,065,056
24.0 - OE - BON - 95/5% MEL	\$ 4,536,491	\$ 2,895,506	\$ 6,811,411
24.0 - OE - BON - ALG	\$ 43,505,916	\$ 40,186,305	\$ 68,112,523
24.0 - OE - WAT - ALG	\$ 8,120,438	\$ 6,783,385	\$ 11,059,556
8.0 - OE - BON - ALG	\$ 2,030,784	\$ 1,586,421	\$ 1,267,442
8.0 - OE - WAT - ALG	\$ 5,092,821	\$ 4,129,713	\$ 7,962,272
8.0 - OE - WAT - COLOR	\$ 4,296,733	\$ 2,517,919	\$ 26,518,465
Total general	\$ 291,212,658	\$ 254,744,183	\$ 307,291,980

San Andrés

En este caso, el costo de empaque total obtenido por la predicción también es más cercano al costo de empaque total real, que el costo de empaque total por la programación de la producción. De igual manera, el costo de predicción representa un 14% más que el costo de empaque real. El costo de programación es un 21% más que el costo real.

4.3 Resultado final

El estudio realizado comprueba que aplicar un modelo predictivo para predecir la cantidad total de pedidos, y luego una estimación de la proporción de cada artículo, es más eficiente que la manera de programar la producción actual. Por

lo tanto, la necesidad de insumos para cumplir con los pedidos ingresados se realizaría de óptimamente, en comparación de la manera actual.




Figura 29. Costo total de insumos productivos para la predicción realizada, la programación de la producción y los datos reales. Fuente de elaboración propia.

Si se hubiera utilizado el modelo de predicción para determinar la necesidad de insumos productivos en noviembre de 2022, la empresa TN & Platex se hubiese ahorrado \$16 millones de pesos que se podrían haber destinado a otro fin del negocio.

Al conocer la necesidad de insumos productivos en determinado momento del tiempo futuro, el sector de compras de TN & Platex puede accionar en este

punto, realizando compras óptimas negociando con los distintos proveedores, y llevando a cabo distintas estrategias de negocio para destinar el dinero no necesario en otra actividad que pueda generar más rendimientos. La combinación de stocks de insumos productivos, junto a la predicción mencionada, puede generar un mejor desempeño del área de compras y del área productiva de la empresa.



Universidad de
San Andrés

CAPÍTULO 5 - CONCLUSIONES Y TRABAJO A FUTURO

5.1 Repaso de impacto de implementar ML

En el presente trabajo se propuso analizar de qué manera impacta la implementación de herramientas que brinda la Inteligencia Artificial en la empresa TN & Platex, y principalmente la predicción de necesidades de insumos productivos.

A partir de esta problemática, en el primer capítulo, se realizaron las siguientes preguntas de investigación:

- ¿De qué manera podemos automatizar y hacer más eficiente la gestión de compras e inventario en la empresa TN & Platex?
- ¿Es posible poder predecir cómo será la necesidad de insumos productivos en el futuro, utilizando algoritmos de Machine Learning?
- ¿Qué impacto tendrá el uso de un algoritmo para establecer una política de compras óptima de los artículos de insumos productivos?

Para obtener los resultados de esta investigación, se utilizó una metodología descriptiva y cuantitativa. Luego de conocer la problemática, se realizó una exploración de los datos existentes, y un entendimiento de las posibilidades de aplicar algoritmos de machine learning.

En el capítulo 2, se expusieron los principales conceptos de inventarios, machine learning y deep learning, para entender de qué manera se podía utilizar la IA en la búsqueda de automatizar el proceso de compras de insumos productivos y la gestión del inventario.

En el tercer capítulo, se analizaron los datos internos y externos recolectados. Luego, se realizó un curado a los datos, para poder procesarlos y crear un dataset del tipo de un problema de aprendizaje supervisado, para utilizar un algoritmo de *deep learning* para la predicción de pedidos de hilados, y de esta manera, determinar la necesidad futura de insumos productivos.

En la búsqueda de la automatización, mejorar la eficiencia de los procesos, y apoyarse en los datos para la toma de decisiones, en este trabajo queda demostrado que empezar a utilizar la IA en una empresa como TN & Platex puede mejorar distintos aspectos del negocio.

En este contexto, el cambio cultural mencionado en el primer capítulo, es importante para poder adoptar la IA y no ser reacios al cambio de paradigma actual en el mundo de los negocios. Si bien es complejo el primer paso, que consiste en trabajar en la recolección de los datos que puedan aportar valor al negocio, luego de eso hay bastante camino por recorrer con buenos augurios en la adopción de la Inteligencia Artificial como herramienta de apoyo para los negocios de la empresa.

5.2 Resultados obtenidos y mejoras

La necesidad de insumos productivos está ligada a las ventas de los hilados que usan estos insumos. Para poder hacer más eficiente los procesos que rodean a los insumos productivos, como las compras y la gestión de inventarios, se puede afirmar que es importante conocer cómo serán las ventas de la empresa en el futuro.

En principio, conocer la predicción de pedidos o de ventas de una empresa no es una tarea sencilla. En esta búsqueda se conoció que muchos factores

juegan un papel importante en la predicción de ventas de una empresa, como por ejemplo el contexto económico del país y de la industria, como así también las ventas pasadas de la empresa.

5.3 Impacto del trabajo en la empresa

Principalmente, los resultados obtenidos de este trabajo impactan en 2 puntos claves de la empresa: mejor uso del recurso humano y capacidad financiera.

Por un lado, al conocer la necesidad de insumos productivos la empresa puede decidir ocupar a las personas que se encargaban de estar atentos a este problema, en otras actividades. Por ejemplo, se libera casi al 100% al personal de almacén en planta de esta tarea, dado que el sector de compras ya sabrá anticipadamente cuáles serán las necesidades de los insumos productivos. El único contacto que existirá entre el sector de compras y el almacén en planta, será para conocer el stock en determinado momento. Por otro lado, el sector de compras deberá accionar menos veces que antes para realizar la compra, dado que en vez de comprar insumos cada vez que se requiere, se realizará una compra más eficiente dado que se conoce la necesidad de los insumos productivos, y que a la larga se optimizará en cuanto a espacio que ocupa este stock en planta.

Por otro lado, al realizar compras de insumos productivos más eficientes y en momentos conocidos, la empresa puede tomar medidas y planificar los gastos en estos insumos, liberando así la capacidad económica en otro momento que antes no se conocía. Este factor es importante dado que la empresa puede decidir invertir la plata que le sobra, o destinarla a otros gastos que se ocasionan en las plantas.

5.4 Trabajo a futuro

En primer lugar, el punto más importante del trabajo a futuro posible es estudiar otra manera de estimar la proporción de cada artículo respecto al total de pedidos. Una opción es el modelado de las proporciones mediante *deep learning*, al igual que el modelo LSTM utilizado para la predicción de pedidos. Como se apreció en los capítulos anteriores, las aplicaciones de *machine learning* en la predicción de series de tiempo complicadas resultan mejores que los modelos clásicos estadísticos. En este caso, al ser más de 20 artículos utilizar un modelado mediante deep learning puede ser beneficioso para determinar la proporción de cada artículo, debido a que cada producto contiene su propia estacionalidad y tendencia, sumado a las variables macroeconómicas que afectan los pedidos de la empresa.

Con respecto al modelo ya entrenado, se plantea la posibilidad de en el futuro incluir datos más significativos de la industria y el mercado textil del país, que actualmente no están disponibles. Se espera poder recopilar esta información para poder agregar al modelo y poder obtener un modelo más acertado.

Por último, se exponen las distintas áreas de la empresa donde se pueden implementar soluciones de IA. Un ejemplo claro es utilizar un algoritmo de *machine learning* para poder prevenir fallas en las máquinas productivas que ocasionan cortes de la producción. La detección de clientes que pueden dejar de comprar en la empresa, detección de fallas en los productos mediante imágenes, o predecir la demanda del total de artículos que comercializa la empresa, son otras posibles avenidas que puede encontrar TN & Platex en un futuro si continúa con una mentalidad data-driven, y de la mano de la transformación digital.

BIBLIOGRAFÍA

Guttag, J. V. (2021). Introduction to Computation and Programming Using Python: With Application to Understanding Data. MIT Press, 3rd Edition.

Heizer, J. & Render, B. (2009). Principios de la administración de operaciones Prentice Hall, Inc., 7ma edición.

Hillier, F. and Lieberman, G. (2015). Introduction to Operations Research. McGraw-Hill, 10th Edition.

James, G. Witten, D. M. Hastie, T. & Tibshirani, R. (2013). Introduction to Statistical Learning. Springer Series in Statistics.

Krajewski, Ritzman & Malhotra. (2008). Administración de operaciones. 8va edición.

Laudon, K. & Laudon, J. (2015). Management Information Systems. Prentice Hall, Twelfth Edition.

Provost, F. & Fawcett, T. (2013). Data Science for Business. O'Reilly Media, Inc.

Rice, J. A. (2005). Mathematical Statistics and Data Analysis. Wadsworth Brooks/Cole Statistics/Probability Series.

Winston. (2004). Operations Research, Applications and Algorithms. Thomson, 4th

EBishop, C. (2006). Pattern recognition and machine learning (1st ed.). New York, NY: Springer edition.

Siegel, E. (2013). Predictive analytics: the power to predict who will click, buy, lie, or die. John Wiley & Sons.

Shumway, R. H., & Stoffer, D. S. (2011). Time series analysis and its applications: with R examples (3rd ed.). Springer.

Brownlee, J. (2020). Deep learning for time series forecasting: Predict the future with MLPs, CNNs and LSTMs in Python. Melbourne, Australia: Machine Learning Mastery.

Nielsen, M. (2015). "Neural Networks and Deep Learning". Londres: Determination Press.

Glass, R., & Callahan, S. (2015). The big data-driven business: How to use big data to win customers, beat competitors, and boost profits. John Wiley & Sons.

BCRA (n.d.). "API Estadísticas BCRA". Disponible en: <https://estadisticasbcra.com/api/documentacion>

Centro de Información y Estudios Económicos de la Provincia de Buenos Aires (n.d.). "Estimador Mensual de la Actividad Económica". Disponible en: <https://estudioeconomicos.ec.gba.gov.ar/coyuntura-nacional/estimador-mensual-de-la-actividad-economica-emaef/>

Hochreiter, Sepp & Schmidhuber, Jürgen. (1997). Long Short-term Memory. Neural computation. 9. 1735-80

Gustavo Lado (2020, mayo 5). "RNA 03 - Introducción al Perceptrón Multicapa". En Youtube. (<https://www.youtube.com/watch?v=MSdWO79lv4k>)

Gustavo Lado (2020, abril 14). "RNA 01 - Introducción a las Redes Neuronales Artificiales". En Youtube. (<https://www.youtube.com/watch?v=Cu76RUzsKXQ>)

Wikipedia. (2022). "Mean squared error". Recuperado de: https://en.wikipedia.org/wiki/Mean_squared_error