

[211003] Diseño de un modelo de pronóstico de demanda basado en Machine Learning y un modelo multi-objetivo para planeación de la producción en una industria panificadora.

María Afanador Jiménez^{a,c}, Isabella Campo Maichel^{a,c}, Silvia Juliana Casadiegos Chaparro^{a,c}, Juan Sebastián Casallas Estrella^{a,c}

Juan Carlos García Díaz^{b,c}

^aEstudiante de Ingeniería Industrial

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

^cPontificia Universidad Javeriana, Bogotá, Colombia

Resumen

Production planning and demand forecasting are fundamental aspects for the proper development of the productive activity of a manufacturing company, especially for those producers of perishable and fast-moving foods. “La Cascada” bakery and pastry shop currently manages its production and sale under a system based on experience, which is not reliable for the fulfillment of the company's objectives. This management of production and sales generates cases of surpluses and shortages, which represent losses and representative expenses. Production performance and Demand Forecasting present an opportunity of improvement because there is currently a waste of resources in production processes and the needs of customers are not being met due to the lack of availability of products. In this way, an application proposal was developed for the bakery and pastry shop “La Cascada”. First, Demand Forecasting was generated using Machine Learning techniques, under the CRISP - DM methodology where different variables that affect demand were handled, such as weather data, special dates, days of the week and internal policies of the company. A high accuracy in the predictions was achieved, finding that the best results were obtained using Neural Networks for most of the Pareto products. Second, Production Planning was carried out under a Linear Programming Model of Multiple Objectives, modeled in Python, which determines the daily units to be produced, achieving an increase of 17.23% in profit, as well as a 4.33% increase in machine utilization and a decrease of 6.36% in costs. In this way, the company is provided with an application that integrates Demand Forecasting and Production Planning, which is used to determine the daily quantity of products ordered by sales and the units to be produced by the area in charge.

Keywords: Machine Learning, Neuronal Networks, Linear Programing Model of multiple objectives, Demand Forecasting, CRISP-DM, Production Planning, Bakery Industry, Pareto

1. Justificación y planteamiento del problema

En el sector de la manufactura la producción es uno de los pilares de las empresas, debido al amplio manejo de factores que incurren en esta actividad. La planeación de la producción representa un reto para las mismas, ya que, si no se tiene un plan sólido y confiable para gestionar y programar las ordenes de producción, se pueden llegar a presentar sobrecostos para las empresas. Relacionado con lo anterior, se encuentra que una parte fundamental para una buena planeación de la producción son los pronósticos de demanda, los cuales permiten alinear los recursos en función de las exigencias del mercado actual. Es por esto que los productores requieren cada vez más procesos de predicción y planificación robustos sustentados por diferentes herramientas tecnológicas, que se adapten a cada detalle de los procesos productivos de manufactura y ventas. Los diferentes programas de software y modelos para la planificación de la producción en conjunto con la predicción de la

demanda ayudan a que se obtenga la máxima eficacia del proceso productivo, y que se encuentre una sinergia al satisfacer la demanda en función de los recursos de las empresas (Huber & Stuckenschmidt, 2021).

En Colombia la industria de los alimentos según los resultados presentados por el DANE (Departamento Administrativo Nacional de Estadística) representó para el año 2018 el 2,83% del PIB nacional. Dentro de esta industria se encuentra la elaboración de alimentos procesados en donde están los productos de panadería y repostería, que figuran de primera necesidad para el consumo de los colombianos. Según esto, el caso de estudio se realizará en la panadería y repostería “Industria Alimentaria “La Cascada” SAS”, una empresa dedicada a la producción y venta de líneas de panadería y repostería, ubicada en la ciudad de Yopal, Casanare. Esta empresa carece de un plan sólido de predicción de la demanda y planeación de la producción, sin embargo, tiene un gran potencial no solo por ser una marca establecida en el mercado en el cual se desenvuelve, sino que también tiene una visión de crecimiento que motiva a ser cada vez más eficientes de la mano con la optimización de sus procesos, para el aprovechamiento máximo de recursos y que sus planes de producción no representen pérdidas para la empresa misma (Alejandro Mesa, Gerente general de la panadería y repostería “La Cascada”, 2021).

“La Cascada” es una empresa que se dedica a la producción y venta de alimentos procesados de panadería, repostería y servicio de restaurante; esta cuenta con 95 trabajadores, 6 puntos de venta y una planta de producción ubicados dentro de la ciudad de Yopal. Su estructura organizacional es jerárquica y se divide en cinco áreas las cuales son: el área administrativa encargada del funcionamiento general de la empresa, el área de ventas encargada de la gestión de los puntos de venta, el área de cocina encargada de la elaboración de los productos del servicio de restaurante, el área logística la cual es responsable de la distribución desde la planta de producción a los puntos de venta, y finalmente el área de producción que se divide en panadería (línea de pan, galletería y hojaldre) y repostería (tortas y postres).

Sobre el contexto establecido anteriormente, al realizar un diagnóstico del estado actual de la empresa, se encontró que debido a la naturaleza de los productos (perecederos y de rápida rotación), no se tiene una organización ideal y sistematizada de la producción, en otras palabras, no se ha establecido un sistema de planeación de la producción que a su vez esté directamente relacionado con las exigencias del mercado. De igual forma se encontró que en los puntos de venta, las listas de productos que se envían al área de producción, son listas realizadas manualmente a consideración del trabajador encargado del punto de venta con base en su experiencia y algunos factores externos como lo son los días especiales. Esta situación en la que se encuentra “La Cascada” representa una oportunidad de mejora debido a que se pueden estar perdiendo ventas por faltantes, como también tener bajas en producción o en los puntos de venta por exceso de producto.

En consecuencia, a las falencias encontradas en el diagnóstico, para efectos prácticos de este caso de estudio se realizaron dos encuestas. La primera evalúa la percepción del cliente frente a la disponibilidad de los productos y la segunda evalúa la percepción de los trabajadores en los puntos de venta. Cada encuesta con su respectivo enfoque. Se aplicaron las encuestas a 120 personas, habitantes de la ciudad de Yopal y clientes de “La Cascada”, de las cuales el 46,7% dijo que no había encontrado el producto que buscaba al momento de pedirlo en el punto de venta, lo que se interpreta como una oportunidad de mejora en los pronósticos de la demanda y por ende en la planeación de la producción de estos productos, lo cual se puede ver en la gráfica 1.

¿Alguna vez no ha encontrado el producto que busca en “La Cascada”?




Gráfico 1 Percepción del cliente sobre disponibilidad de los productos de “La Cascada”

Debido a la extensa variedad de productos que ofrece la empresa, solo se hará énfasis en la familia de productos que representan mayores costos y que exijan mayor dificultad al momento de realizar pedidos y por ende en la planeación de su producción. Con el objetivo de establecer la familia de productos que representa en mayor medida el problema de faltantes en los puntos de venta, se le preguntó a los clientes y trabajadores que línea de producto es la que no encuentran con mayor frecuencia. Como lo muestra la gráfica 2, la línea de producto escogida tanto por los clientes como los trabajadores, fueron los postres con 21,4% y 30% respectivamente.



Gráfico 2 Productos que presentan problemas por faltantes según clientes y trabajadores

De la igual forma se le preguntó a los trabajadores cuál era la línea de producto que más dificultad representaba al momento de realizar el pedido a producción. Debido a que existen variables externas que pueden afectar las ventas de algunos productos, los trabajadores dudan de las cantidades que deben pedir y esto puede resultar en excesos y que estos productos no roten en su totalidad convirtiéndose en bajas, o por el contrario en faltantes que pueden representar pérdidas en ventas. Los resultados arrojados como se observa en la gráfica 3, muestran que la línea de producto que más dificultades representa son los postres con un 55%.

¿Cuál es la línea de producto que mayor dificultad la representa al momento de realizar el pedido a Producción?




Gráfico 3 Líneas de producto con problemas al realizar pedidos según los trabajadores

Aunque la línea de postres representa el porcentaje más alto en cuanto a dificultades para realizar un pedido a Producción, debido a que esta línea comparte insumos, inventario y maquinaria con la línea de tortas y panadería, se concluye que se deben tener en cuenta las líneas de panadería y repostería para la planeación de la producción y pronósticos de la demanda para así poder obtener una solución óptima y que sea aplicable en el contexto de la empresa.

Para establecer la situación de la empresa frente a las pérdidas de productos, se analizaron los datos de las bajas existentes en los últimos 6 meses, en la planta de producción y en los puntos de venta. Este análisis se realizó tomando los datos de bajas suministrados por el software de la empresa y en conjunto con los precios de cada uno. Como se muestra en la gráfica 4, se encontró que estos costos, presentados en naranja, representan entre 2.94% - 11.12% de los ingresos en cada uno de estos meses que se muestran en color verde. Es importante destacar que uno de los meses con más pérdidas de productos fue diciembre, este mes al ser especial hace que se ofrezcan mayor cantidad de productos de temporada alcanzando el mayor porcentaje de participación de costos frente a los ingresos. Lo mencionado anteriormente evidencia otra oportunidad de mejora en términos de pronósticos de demanda y planeación de la producción.

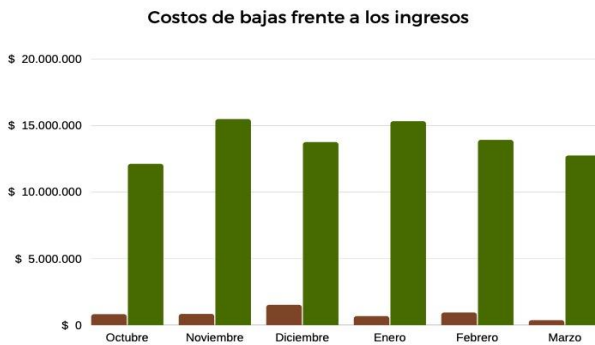


Gráfico 4 Comparación de los costos de las bajas totales frente a los ingresos

Con el fin de dar una alternativa de solución para las problemáticas expuestas, se propone un método eficiente para pronosticar la demanda de las familias de productos escogidas, además se desarrollará un modelo de optimización de múltiples objetivos para planeación de la producción en donde exista una sinergia entre estas dos etapas, para que productos como los que ofrece la panadería “La Cascada” (percederos, con alto índice de deterioro), sean elaborados en las cantidades correctas, y mantengan un nivel adecuado de inventario. En este tipo de productos las unidades no vendidas son desperdicios, lo cual genera costos innecesarios que se traducen en pérdidas y pueden ser reducidos significativamente mediante un buen pronóstico de demanda. La predicción

de demanda por métodos automatizados genera una ventaja competitiva, al reducir pérdidas, incrementar ganancias y al mantener el stock de seguridad al mínimo para asegurar productos frescos y de calidad a los clientes. Por último, es importante tener en cuenta que una planeación de la producción mediante un modelo de optimización con múltiples objetivos permite mejorar la producción diaria, maximizando las ganancias, maximizando la utilización de las máquinas y minimizando el costo de producción (Ezra et al., 2020).

Esto lleva a formular la pregunta de investigación, ¿Es posible desarrollar un modelo de pronóstico de la demanda, basado en técnicas de aprendizaje de máquina (*Machine Learning*), y un modelo de optimización multi-objetivo para la planeación de la producción, en la Panadería y Repostería “La Cascada”? Los cuales contribuyan a una mayor utilización de la maquinaria, minimización de los costos de producción y las desviaciones en el cumplimiento de la demanda.

2. Antecedentes

Los productos de repostería y panadería tienen rápida rotación, por lo que la calidad va estrechamente ligada con la frescura del producto. Durante los últimos años se han elaborado distintos modelos y métodos para disminuir los desperdicios por sobreproducción, pérdida de ventas por faltantes y mejorar el manejo de los costos de producción. La predicción de las ventas a corto plazo mediante el *Machine Learning* permite a estas empresas reducir el inventario de sus productos almacenados y evitar las pérdidas de ventas en sus locales (Tsoumakas, 2019).

Se han estudiado modelos de *Machine Learning*, regresión lineal con variables ficticias y otros para el sector de productos de alta rotación; el menor error se obtuvo con *Machine learning*; red neuronal artificial (ANN) fue mejor que el modelo autoregresivo integrado de media móvil (ARIMA) y regresión lineal múltiple para pronósticos mensuales y red neuronal recurrente (RNN) tuvo mejor desempeño que máquinas de vector de apoyo (SVM) (Huber & Stuckenschmidt, 2020). De igual manera, (Yang & Sutrisno, 2018) emplearon el método red neuronal prealimentada (FFNN) de *Machine Learning* que arroja pequeños errores y permite seguir patrones de ventas para los productos vendidos a corto plazo.

El uso de herramientas como los algoritmos de *Machine Learning*, redes neuronales de memoria a corto plazo (LSTM) o la regresión por vector de apoyo (SVR), se mostraron eficientes a la hora de manejar datos no lineales, este permite predecir el comportamiento de demanda de forma no lineal aprendiendo de las tendencias de las ventas, insatisfacción del consumidor y el agotamiento de existencias (Priyadarshi et al., 2019). Otras técnicas tales como redes bayesianas y redes artificiales de hidrocarburos (AHN), muestran buenos resultados en sus pronósticos, pero las técnicas de *Machine Learning*, *Deep Learning* y *Extreme Learning Machine*, tienen los pronósticos más precisos. Las redes bayesianas, la regresión de árbol de decisión potenciada y el método *Stepwise* muestran resultados muy similares en el pronóstico de demanda para este tipo de productos (Tanizaki et al., 2019).

La información de entrada para un buen modelo de pronóstico es fundamental, y la agrupación y ponderación de estos datos reduce el error (Huber & Stuckenschmidt, 2020). Tener datos de historial de ventas, características de los productos, clima, entre otros, integra factores internos y externos influyentes en la demanda (Elcio Tarallo et al., 2019); independientemente de la situación modelada, las técnicas que tienen en cuenta factores externos son más acertadas, esto deja en desventaja a el ARIMA y suavización exponencial (Lasek et al., 2016). Realizar un pronóstico de la demanda agregada, permite reducir el coste computacional al detectarse un patrón de ventas en productos similares (Huber et al., 2017).

Los datos históricos se analizan e interpretan creando un sistema inteligente de predicción de la demanda usando diferentes métodos que incluyen técnicas de *Machine Learning*, análisis de series de tiempo y modelos de *Deep Learning*, mostrando mayor precisión que los pronósticos tradicionales (Kilimci et al., 2019). Un sistema de planeación de la producción con un enfoque intradiario, mediante una red LSTM pronostica la demanda tomándola como entrada, usando una heurística basada en la asignación de trabajos en franjas horarias establecidas, esto permitió mejorar el margen de error entre lo producido y demandado (Huber & Stuckenschmidt, 2021).

Por otro lado, el nivel de producción adecuado influye en la competitividad de la compañía y en el éxito de un sistema de producción (Hassan et al., 2013), aquí es donde se puede incurrir en altos costos, que podrían reducirse mediante una política de control de inventarios para responder a las oscilaciones del mercado. Es así, como (Duarte et al., 2021) proponen un modelo para minimizar costos de producción en una panadería multiproducto; las entradas fueron costos de producción, inventario, operación y costos relacionados a la calidad de los productos. De ahí parte el modelo de enteros mixtos basado en dos contextos: el consumo determinístico sin control de inventarios y el consumo estocástico con retraso en el control de inventarios. Los resultados demuestran que el contexto del consumo estocástico se adapta mejor a la realidad.

Un buen pronóstico de la demanda es un factor crítico para la planeación de la producción, tener mejor tasa de utilización y productividad. Así mismo, la simulación en las líneas de producción de las panaderías es una buena oportunidad para optimizar los procesos y mejorar el consumo de energía de la maquinaria utilizada, reducir costos de salario y aligerar las tareas de los trabajadores (F. Hecker et al., 2010) La optimización por objetivos (GP) es una técnica que considera más de un objetivo y a cada una de las funciones objetivo se le asigna una meta a alcanzar. Los tres objetivos considerados aquí son: maximizar ganancias por ventas diarias, minimizar costos de producción y maximizar la utilización de las máquinas de producción (Ezra et al., 2020).

(Seubert et al., 2020) han abordado el problema de los desperdicios, empleando una ANN con el fin de realizar una predicción de la demanda objetiva y planear la producción para las siguientes 24 horas. Así mismo, (Garre et al., 2020) demostraron que a través del *Machine Learning* es posible reducir la incertidumbre en cuanto a producción, proporcionando mayor rentabilidad y disminución del impacto ambiental por la generación de residuos. Sin embargo, se ha comprobado que los enfoques de optimización exactos (matemáticos) pueden obtener el valor óptimo para problemas de optimización (Wari & Zhu, 2016).

(F. T. Hecker et al., 2014), evalúan el uso de diferentes métodos como el algoritmo genético (GA), el algoritmo de optimización por colonia de hormigas (ACO) y búsqueda aleatoria para analizar y optimizar la planeación de la producción de una panadería, se analizan dos funciones objetivo (*makespan* y tiempo total de ocupación de las máquinas), dando como resultado que la mejor opción era el algoritmo genético. Los algoritmos evolutivos como lo son la optimización por enjambre de partículas (PSO) y ACO se pueden adaptar para resolver problemas de planeación de la producción en panaderías, mostrando resultados óptimos en tiempos de ejecución predefinidos (F. T. Hecker et al., 2013).

La programación por objetivos (GP) es una extensión de la programación lineal, este tipo de programación es ideal para compañías con diferentes tipos de productos, y diferentes objetivos a mejorar. Esta es usada comúnmente para tratar problemas con múltiples objetivos minimizando las desviaciones de las metas definidas por los tomadores de decisiones, para poder maximizar ganancias y reducir costos (Ezra et al., 2020). (Onasanya et al., 2020), evaluaron el uso de la programación lineal difusa (FLP), en donde se obtuvo un conjunto de soluciones con mejores resultados de la planeación de la producción en una panadería frente al modelo clásico de programación lineal (LP).

Sumado a esto, (Kumar, 2019) propone un modelo de programación prioritaria por objetivos ponderados (PPWGP) para la producción de una industria a pequeña escala, con este demuestra que PPWGP funciona como un método óptimo para encontrar soluciones a problemas presentes en pequeñas empresas y que estas cuenten con un aumento en sus ganancias gracias a la cantidad de producto programado para producir. Al establecer parámetros de costos para todo tipo de objetivos de producción, los gerentes pueden mantener el equilibrio entre múltiples objetivos y lograr la gestión y el control optimizados en el proceso de fabricación (Wang & Liu, 2013).

Apoyado en estas investigaciones se decide usar la técnica de *Machine Learning* para la elaboración de los pronósticos de demanda, apoyándonos principalmente en el algoritmo ANN por su bajo error en estudios anteriores, asignando un patrón de carga a las fechas de demanda inusual para evitar los errores, crear agrupaciones entre días de demandas similares, teniendo en cuenta todos los días del año. Adicionalmente es necesario tener en cuenta los datos de demanda históricos y criterios adicionales como ubicación, tipos de

productos, entre otros. Para la planeación, de la producción se propone el desarrollo de un modelo de programación lineal de múltiples objetivos, ya que este considera la capacidad, recursos y variedad de alternativas que existen para la gestión y administración de objetivos de procesos de producción. Se tendrán en cuenta restricciones de tiempo, mano de obra, materia prima, stock de seguridad y pronósticos obtenidos.

3. Objetivos

Diseñar un aplicativo para la panadería y repostería “La Cascada” que integre los pronósticos de la demanda con la planeación de la producción de las líneas de producto de panadería y repostería para así lograr la utilización óptima de los recursos y equipos, asegurando el cumplimiento de los parámetros de tiempo, costos y calidad.

Objetivos específicos

- Desarrollar un modelo de *Machine Learning* para pronóstico de la demanda diaria - tanto para días normales como para fechas especiales- de los productos elaborados por la panadería y repostería “La Cascada”.
- Formular un modelo de optimización de múltiples objetivos para la planeación de la producción de las líneas de producto de panadería y repostería en “La Cascada” que utilice la proyección de la demanda generada en el primer objetivo.
- Desarrollar un aplicativo de software para operación integrada de los modelos de pronóstico de la demanda y planeación de la producción.
- Medir el impacto de la solución comparando los datos históricos con respecto a los resultados de la propuesta.

4. Metodología

OBJETIVO 1:

Para el desarrollo del modelo de *Machine Learning*, se utilizó la metodología CRISP-DM, la cual proporciona una descripción del ciclo de vida de un proyecto de análisis de datos (CRISP-DM, 2016). Según esto y con el fin de cumplir con la metodología mencionada, el proyecto debe desarrollarse dentro de las siguientes fases:

1. Comprensión del negocio

A lo largo del desarrollo del proyecto, se agendaron reuniones con el gerente de la compañía para identificar la situación de la empresa, el modelo de negocio y factores externos influyentes en el comportamiento de la demanda de los diferentes productos, como lo pueden ser los climatológicos y estacionales. A su vez se realizaron encuestas tanto a clientes, como a empleados de la panadería, para empezar con el levantamiento de información sobre la disponibilidad de productos (para clientes), y dificultades al momento de hacer los pedidos a producción de las distintas líneas de productos (para empleados).

2. Comprensión y preparación de los datos

Se solicitó a la empresa la información correspondiente al histórico de las ventas para todos los productos ofrecidos desde el 1 de enero del 2018, hasta el 30 junio del 2021. Partiendo de esta información, se revisó el comportamiento de los productos durante este periodo de tiempo, para así depurar aquellos que tuvieran alguna de las siguientes características: discontinuados, histórico de demanda menor a 3.5 años, inconsistencias en la demanda debido a la pandemia, fabricados bajo pedido u ofrecidos en el servicio de restaurante y no fabricados por “La Cascada” (velas, manteles, gaseosas, etc.).

Se encontraron varios productos que cuentan con distintas presentaciones (ej. Pan de Mantequilla x8, Pan de Mantequilla x3, Pan de Mantequilla x1, ...), para tomar una decisión frente a como asimilar estos datos, el gerente de la compañía indicó que estas varían mensualmente desde el 2020, debido a las normativas sanitarias

impuestas por la coyuntura mundial por el Covid-19; por lo cual se decidió unificar la demanda de estos productos. Adicional a esto, y gracias a los datos recolectados con las encuestas, e información suministrada por el gerente, se simuló los faltantes y sobrantes de los productos mediante la asignación de probabilidades a cada uno de estos sucesos, y así poder estimar la demanda real. Dado el volumen de productos que maneja “La Cascada”, se decidió buscar los que tienen una mayor rotación y participación en las ventas, para centrar el esfuerzo de los pronósticos en estos, y no necesitar de tanto tiempo y recursos computacionales en su ejecución. Con este fin, se realizó el análisis de Pareto de los productos depurados, en donde se buscó tener el 80% de la participación y rotación inicialmente. Sin embargo, al obtener los resultados se bajó el umbral de los Pareto al 70% debido a que en los últimos productos la rotación representaba menos del 2%.

3. Modelado

Para generar la base de datos que utilizarán los pronósticos de la demanda de los productos Pareto, se tuvo en cuenta los factores mencionados en el artículo “*Daily retail demand forecasting using machine learning with emphasis on calendric special days*” (Huber & Stuckenschmidt, 2020) donde se destaca la importancia de incluir las variables climatológicas y de días especiales, aspecto que también resaltó el gerente de “La Cascada”.

Con el fin de incluir las variables climatológicas seleccionadas (temperatura y precipitación), se descargó el histórico climatológico diario de Yopal desde el 1 de enero 2018 hasta el 30 de junio 2021 de las bases de datos de la NASA (*POWER / Data Access Viewer*, s. f.) los cuales se incluyeron en el entrenamiento de los modelos. Para la generación de nuevos pronósticos que no estén dentro del rango de tiempo de los datos que se manejaron, se decidió implementar la API Open Weather Map (One Call API: weather data for any geographical coordinate - OpenWeatherMap, s. f.) donde por medio del código de los pronósticos se solicita la información climatológica de 7 días con el fin de usarla para bases de datos futuras de manera automática.

En cuanto a los días especiales, se crearon funciones con el fin de identificar si el día para el que se genera el pronóstico es un día festivo o no, además de si es anterior o posterior a una fecha especial.

Para identificar los días especiales se tuvo en cuenta los siguientes factores:

- Se tomaron los principales días festivos de Colombia.
- Se numeraron los días festivos según el orden de ocurrencia del 1 al 16, por lo cual la función retorna alguno de estos valores en caso tal de que la fecha del pronóstico caiga en alguno de estos días feriados. En caso contrario retorna el número 17 (día no feriado).

De igual forma, se crearon funciones adicionales relacionadas con el modelo de negocio de “La Cascada” en donde se establecieron qué día de la semana es, si es fin de semana o entre semana y qué tipo de política de inventario se maneja ese día.

En la etapa de construcción del modelo, se decidió utilizar el lenguaje de programación Python en el entorno de Colab (Google Colaboratory, s. f.), en conjunto con Google Drive para la creación de la Red Neuronal de Regresión, y guardar la información del modelo entrenado. Esta recibe la base de datos previamente consolidada, y para la detección de datos atípicos en la demanda de manera no supervisada, utiliza el método de Bosques de Aislamiento (Top Big Data, 2020) para así hacer una segunda limpieza de los datos con los que se va a trabajar. Luego, se dividió la base de datos dejando los últimos 21 días para prueba de los modelos, que abarcan desde el día 10 de junio de 2021 hasta el 30 del mismo mes. Se realizó la estandarización de las variables del modelo para tener un mejor rendimiento, y se ajustaron varios de los hiperparámetros de la Red Neuronal según el producto Pareto como se muestra en la tabla No. 1.

Tabla 1. Hiperparámetros productos Pareto

Hiperparámetros	Pastel de Pollo	Para los demás Productos Pareto*
Batch	80	10
Epochs	500	1000
Learning_rate	0.001	0.01
Momentum	0.9	0.0
Optimizer	Adam	RMSprop
Kernel_initializer	he_uniform	he_normal
Activation	relu	relu
Dropout	0.0	0.0
Weight	1	3
Neurons	30	100

*Pan Mantequilla Mediano R-A; Pan Mantequilla Mediano R-B; Pan Mantequilla Unificado; Pan Nevado; Pan Rollo Unificado; Sandwich de Pollo Pequeño.

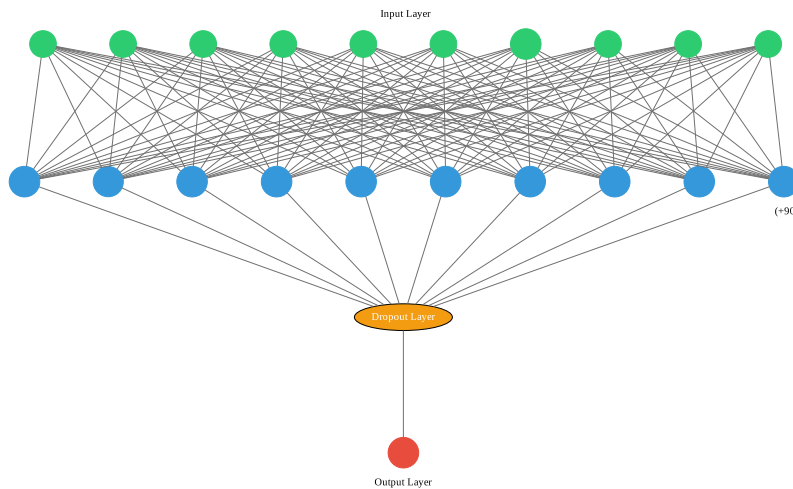


Ilustración 1 Ejemplo Red Neuronal estructurada Pan Rollo

Por último, se agregó una capa adicional de regularización de las salidas de la red, para evitar el sobreajuste a los datos de entrenamiento, como se evidencia en la ilustración No. 1 que muestra el esquema que se maneja en todos los modelos.

Para los productos no Pareto, se decidió enfocar los pronósticos con modelos de regresión lineal teniendo en cuenta su poca rotación a lo largo del año. El manejo de la base de datos fue igual al de los productos Pareto (limpieza y eliminación de datos atípicos). De acuerdo con los resultados de la regresión se generaron los pronósticos de la demanda.

4. Evaluación de los modelos

Por último, se revisó el rendimiento de los modelos de *Machine Learning* comparando las métricas de RMSE (error cuadrático medio) y MAPE (error porcentual absoluto medio) para cada uno de los productos Pareto, usando métodos convencionales como lo pueden ser Regresión Lineal, Árboles de Regresión, Boosting y SVM.

Tabla 2 Resultados errores modelos productos Pareto

Productos	Redes Neuronales		Regresión lineal		Árboles de regresión		Boosting		SVM	
	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE
PAN ROLLO UNIFICADO	258.20	✓ 11,21%	265.25	✓ 11,54%	370.31	✓ 15,65%	358.61	✓ 15,45%	370.57	✓ 11,21%
PAN MANTEQUILLA UNIFICADO	190.25	✓ 13,92%	197.45	✓ 14,31%	228.21	✓ 15,63%	279.42	! 22,48%	224.00	✓ 15,41%
PAN INTEGRAL UNIFICADO	233.23	✓ 18,57%	261.27	! 22,97%	326.04	✗ 31,57%	304.46	! 28,08%	287.68	! 25,61%
PASTEL DE POLLO	42.81	! 23,21%	43.31	! 23,52%	39.86	! 21,97%	57.82	✗ 33,10%	40.19	! 23,27%
PAN MANTEQUILLA MEDIANO R-B	46.64	! 24,49%	47.83	! 22,99%	51.86	! 25,08%	58.76	✗ 30,21%	49.78	! 23,70%
PAN MANEQUILLA MEDIANO R-A	37.95	! 21,72%	38.78	! 24,31%	38.09	! 21,79%	50.00	✗ 31,39%	39.25	! 23,66%
PAN NEVADO	38.23	! 21,75%	47.06	! 23,19%	47.86	! 24,05%	44.01	! 24,84%	48.62	! 24,29%
SANDWICH DE POLLO PEQUEÑO	40.73	! 27,95%	38.82	! 29,12%	30.44	! 21,42%	38.96	✗ 34,02%	34.85	! 26,77%
Promedio	111.01	20,35%	117.47	21,49%	141.58	22,15%	149.01	27,45%	136.87	21,74%

Como se puede evidenciar en la tabla 2, los modelos más avanzados de *Machine Learning* como lo son las Redes Neuronales, obtuvieron en promedio los mejores resultados para 6 de los 8 productos Pareto. Para el caso del sandwich de pollo pequeño y pastel de pollo los mejores resultados son presentados con modelos tradicionales como árboles de regresión. De esta forma, se logró obtener una aproximación a la demanda real de todos los puntos de venta de la panadería y repostería “La Cascada”, con un porcentaje de error menor al 28% a pesar de la alta variabilidad a diario en esta. Adicionalmente se realizó una clasificación de los porcentajes del error MAPE la cual consta de tres banderas, con el fin de que el usuario pueda identificar visualmente los pronósticos que tienen buenos resultados (verde), los que representan una variabilidad considerable (amarillo) y por ultimo los que directamente no son precisos presentando una alta variabilidad (rojo) en los pronósticos.

OBJETIVO 2:

Con el fin de formular el modelo de múltiples objetivos, se tuvo en cuenta la propuesta del artículo “*Goal Optimization of a Pastry Company*” (Ezra et al., 2020) la cual se adaptó a los requerimientos de la empresa. Fue necesario recolectar información de materias primas, costos y maquinaria involucrada en la producción de la línea de productos ofrecidos; para así construir las matrices correspondientes a las variables relacionadas con los objetivos de minimizar costos de producción, maximizar las utilidades diarias y utilización de las máquinas.

Para recolectar los datos de materias primas, fue necesario revisar las recetas de cada uno de los productos, donde se obtuvo una primera tabla la cual refleja la cantidad de materias primas requeridas para producir una unidad de cada referencia (anexo 1). Partiendo de esto, se consolidó la información referente a las cantidades pronosticadas con el modelo del primer objetivo para cada producto, con el fin de obtener los datos de la cantidad de materias primas necesarias para la producción diaria total (anexo 2). Posteriormente se realizó una tercera tabla para presentar los costos totales de materias primas, para lo cual fue necesario solicitar a la empresa las unidades (gramaje/unidades/litros) de compra de materias primas, para poder calcular el precio por gramo (anexo 3). De igual forma, se revisó cada proceso productivo para todas las referencias de producto, con el fin de identificar las maquinas involucradas en los mismos, y los tiempos de utilización de estas en términos de unidades de producto (anexo 4).

Con esta información, se procedió a hacer el costeo de los productos, involucrando costos de materia prima y mano de obra; esto se calculó teniendo en cuenta los parámetros utilizados por “La Cascada” en su metodología de costeo. Los parámetros utilizados fueron los siguientes:

- El costo de mano de obra directa representa el 35% de los costos de materias primas.
- El costo de carga fabril representa el 25% del costo de las materias primas.

La suma de estos factores dio como resultado el costo final de cada producto.

Por último, se realizó una tabla del costo total, precio de venta (información suministrada por la empresa) y utilidad por cada producto (anexo 5). Todo esto para poder construir el modelo de optimización, cumpliendo con los objetivos planteados.

Una vez construidas las matrices, se ingresaron los parámetros al software de optimización Gusek (Bettoni, 2018). Sin embargo, dado el volumen de datos, el software presentó la advertencia de que las matrices eran muy grandes para poder ejecutar el modelo, por tal motivo se tomó la decisión de programar el modelo de múltiples objetivos en Python con las mismas bases del artículo, utilizando la librería Pulp (*Main Topics* —

PuLP 2.6.0 documentation, 2009) para modelar el código, utilizando una estructura similar a la que se usaría en Gusek como se presenta a continuación.

- **Conjuntos:**

- Productos [P]: 121 productos de “La Cascada”
- Materia Prima [MP]: 126 materias primas

- **Parámetros:**

- PD_p : Pronósticos de la demanda de producto P.
- $RMP_{MP,P}$: Requerimiento de materias primas para producto P
- CMP_{MP} : Cantidad disponible de materia prima al día.
- C_p : Costos del producto P.
- U_p : Utilidades del producto P.
- TP_p : Tiempo de producción del producto P.
- INV_p : Inventarios del producto P.
- B_p : Lote de producción en unidades del producto P.
- I_p : Ingresos del producto P.
- IU: Incremento de la utilidad= 1.15
- MO: Meta de costos=0.4
- UM: Utilización de las maquinas= 840 min

- **Variables:**

- x_p : Número de veces que se produce un lote del producto P.
- d_1^+ : Cantidad adicional al cumplimiento del objetivo 1.
- d_1^- : Cantidad faltante al cumplimiento del objetivo 1.
- d_2^+ : Cantidad adicional al cumplimiento del objetivo 2.
- d_2^- : Cantidad faltante al cumplimiento del objetivo 2.
- d_3^+ : Cantidad adicional al cumplimiento del objetivo 3.
- d_3^- : Cantidad faltante al cumplimiento del objetivo 3.

- **Restricciones de metas:**

- *Utilidades*: $\sum_{i \in P} (x_i \times U_i \times B_i) - (d_1^+) + (d_1^-) = \sum_{i \in P} (PD_i \times U_i) \times IU$ (Ec.1)
- *Costos*: $\sum_{i \in P} (x_i \times C_i \times B_i) - (d_2^+) + (d_2^-) = \sum_{i \in P} (PD_i \times I_i) \times MO$ (Ec. 2)
- *Uso maquinaria*: $\sum_{i \in P} (x_i \times TP_i) - (d_3^+) + (d_3^-) = UM$ (Ec. 3)

- **Restricciones:**

- *Materias primas* $\forall j \in MP$: $\sum_{i \in P} (x_i \times B_i \times RMP_{i,j}) \leq CMP_j$ (Ec. 4)
- *Producción* $\forall i \in P$: $x_i \times B_i + INV_i \geq PD_i$ (Ec. 5)
- *No negatividad*: $x, d_1, d_2, d_3 \geq 0$ (Ec. 6)
- Variables enteras: $x \in \mathbb{Z}$ (Ec. 7)

- **Función de múltiples objetivos:**

$$MIN Z = 0.5d_1^- + 0.3d_2^+ + 0.2d_3^- \text{ (Ec. 8)}$$

- *Objetivo 1: Maximizar la utilidad diaria*
- *Objetivo 2: Minimizar los costos diarios*
- *Objetivo 3: Maximizar la utilización diaria de las máquinas*

La ecuación No. 1, 2 y 4 cuentan con una lógica similar ya que se toma la variable x , que representan las corridas de producción para un determinado producto, multiplicado por un bache de producción (B) establecido por la empresa para estimar un total de productos diarios, con el fin de poder calcular distintos resultados, como utilidades, costos y materias primas llegando al cumplimiento de metas sin sobrepasar los recursos disponibles.

La ecuación No.3 multiplica las rondas de producción (x) por los tiempos de duración de los procesos (TP) para llegar al objetivo de utilización de las maquinas. La ecuación No.5 se encarga del cumplimiento de la demanda diaria, estimando la cantidad a producir la cual debe ser mayor o igual a lo demandado durante el día (PD). Las ecuaciones No.6 y No.7 hacen referencia a las características de las variables, ya que en este caso se requiere que sean mayores o iguales a cero (no negatividad) y adicionalmente las rondas de producción deben ser números enteros.

Por último, la ecuación No. 8 es la ponderación de los objetivos teniendo en cuenta la consideración del gerente de la panadería respecto a la importancia que cada uno de estos representa para la empresa. Adicional a esto, se realizaron pruebas variando los pesos en distintos escenarios, en donde se encontró que la mejora era poco significativa (menos del 1.5%) para el requerimiento computacional (tiempo de ejecución del modelo), por lo que al final se decidió continuar con la decisión del gerente que presenta buenos resultados en poco tiempo para la planeación diaria de la compañía.




Gráfico 5 Cumplimiento de los objetivos en periodo de prueba

Como se puede observar en la Gráfica 5, fue posible abordar las tres metas propuestas para “La Cascada”. El objetivo No. 1 (maximizar las utilidades diarias) se alcanzó en un 94.56% para los 21 días de prueba, esto mismo ocurrió con el objetivo No. 3 (maximizar el uso de las máquinas) con un 97.73%. Para el caso del objetivo No. 2, (minimizar los costos diarios) este también se cumplió con un menor porcentaje referente a los anteriores objetivos en un 70.27%. Este cumplimiento parcial fue dado a que, para satisfacer la demanda diaria de los productos y seguir el modelo de producción de “La Cascada” representó una sobreproducción para algunas referencias lo que aumentaba los costos y en algunos casos la disminución de la utilidad diaria y utilización de las maquinas al tener en cuenta el manejo de inventarios. En el anexo 6 se puede ver el código utilizado para realizar las pruebas.

OBJETIVO 3:

Para la implementación de este aplicativo se decidió usar Excel® como entorno de trabajo para su desarrollo dada su versatilidad. Se creó una interfaz interactiva con botones para que el personal de “La Cascada” pueda ingresar de manera sencilla a la planeación de la producción y pronósticos de la demanda al igual que visualizar los datos del modelo. El aplicativo se desarrolló según 3 ejes principales teniendo en cuenta los objetivos planteados: Pronósticos de la demanda, Planeación de la producción y Datos del modelo. Con el apoyo de Visual Basic, estos 3 objetivos se enlazan con Google Colab, como se muestra a continuación.

- **Pronósticos de la demanda**



Ilustración 2 Interfaz Pronósticos de la demanda

Cuando el usuario, ingresa al botón “Abrir pronósticos” es redireccionado al modelo de pronósticos de la demanda en Google Colab referente al objetivo No. 1 para luego visualizar los resultados generados haciendo click en el botón “Resultados pronósticos”. Para dar claridad en el uso de la interfaz, en la misma podrán encontrar un instructivo de uso de pronósticos con el paso a paso.

- **Entrenamiento de los modelos**



Ilustración 3 Interfaz Entrenamiento modelos

En caso de ser necesario, el usuario puede volver a entrenar los modelos para generar una nueva Red Neuronal para cada uno de los productos Pareto. Cuando el usuario, ingresa al botón del producto deseado (ejemplo: “Pan Rollo”) es redireccionado al modelo de entrenamiento en Google Colab referente al objetivo No. 1 para luego utilizar dicha red en los modelos de pronósticos de la demanda de estos productos. Para dar claridad en el uso de la interfaz, en la misma podrán encontrar un instructivo de uso de los entrenamientos de las Redes Neuronales con el paso a paso.

- **Planeación de la producción**



Ilustración 4 Interfaz Planeación de la producción

El usuario debe seleccionar primero el botón “Inventarios”, el cual lo redireccionará a un documento Excel en donde debe actualizar el inventario de cada producto al final del día, ofrecido por “La Cascada”. Una vez actualizado, se debe hacer click en “Planeación de la producción” donde se utilizará dicha información de

inventarios para generar los resultados en el modelo. Con el fin de ver los resultados, el usuario debe ir a la hoja “Resultados” en el aplicativo para ser redirigido a estos.

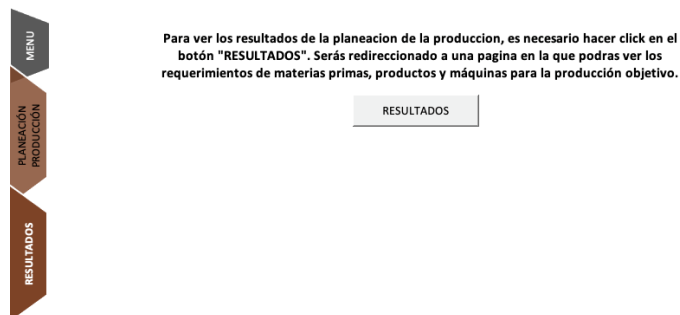


Ilustración 5 Interfaz Resultados planeación de la producción

Una vez en la hoja de Resultados, es necesario hacer click en el botón "RESULTADOS". El usuario será redireccionado a una página en la que podrá visualizar los requerimientos de materias primas y las cantidades a producir para el cumplimiento de los objetivos.

- **Datos del modelo**

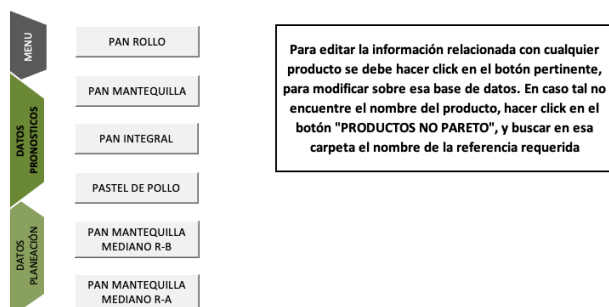


Ilustración 6 Interfaz Datos pronóstico

Para editar la información relacionada con cualquier producto se debe hacer click en el botón pertinente, para modificar sobre esa base de datos. En caso tal no encuentre el nombre del producto, el usuario debe hacer click en el botón "PRODUCTOS NO PARETO", y buscar en esa carpeta el nombre de la referencia requerida.

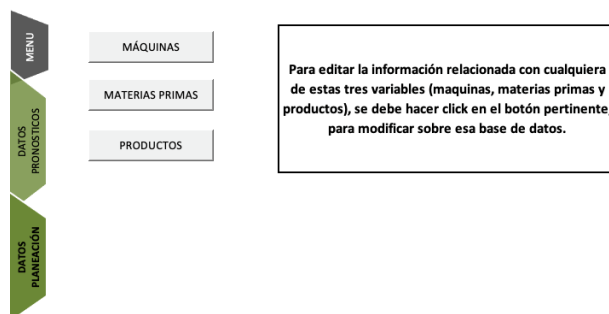


Ilustración 7 Interfaz Datos planeación

Para editar la información relacionada con cualquiera de estas tres variables (maquinas, materias primas y productos), se debe hacer click en el botón pertinente, para modificar sobre esa base de datos. El aplicativo lo pueden encontrar en el anexo 7.

OBJETIVO 4

Con el fin de evaluar el rendimiento del modelo propuesto para “La Cascada” en su proceso productivo y ventas, se analizaron datos durante el periodo de prueba en donde se establecieron los siguientes indicadores.

- **Utilidad**

El primer objetivo que contempla el modelo de planeación de la producción es maximizar la utilidad, es por esto que se toma como un indicador, mostrando así la variación obtenida comparando los datos reales obtenidos durante el mismo período de prueba (entregados por la empresa) y los resultados obtenidos con el modelo para el mismo rango de tiempo.

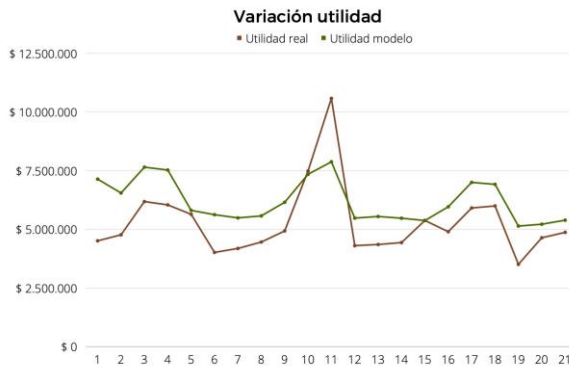


Gráfico 6 Comportamiento de la utilidad en el periodo de prueba

De la gráfica anterior se sacaron los resultados en donde se obtuvo un incremento del 17.23%, lo que demuestra el cumplimiento del objetivo y de esta forma una mejora representativa para “La Cascada”. Durante los 21 días de prueba, la utilidad real para “La Cascada” fue de \$111,107,277 mientras que en el modelo desarrollado fue de \$130,246,911.

- **Costos de producción**

Al igual que en el indicador anterior, los costos fueron el segundo objetivo planteado en el modelo de planeación de la producción, con el fin de minimizarlos. En la siguiente gráfica se comparan los costos reales con los costos obtenidos con el modelo.



Gráfico 7 Comportamiento costos de producción en el periodo de prueba

Al analizar la gráfica No. 7, se tomaron los costos reales de producción durante los 21 días que fueron de \$137,730,196 mientras que en el modelo estos representaron \$128,963,670. De esta manera, hay una

disminución de 6.36%, lo que demuestra el cumplimiento del objetivo a pesar de no haber llegado a la meta deseada.

- **Utilización de las máquinas**

Lo mismo ocurre con la utilización de las máquinas al ser el tercer objetivo planteado en el modelo de la planeación de la producción, con el fin de maximizarla. En la siguiente gráfica se compara el uso real de las maquinas con la utilización de estas empleando el modelo.

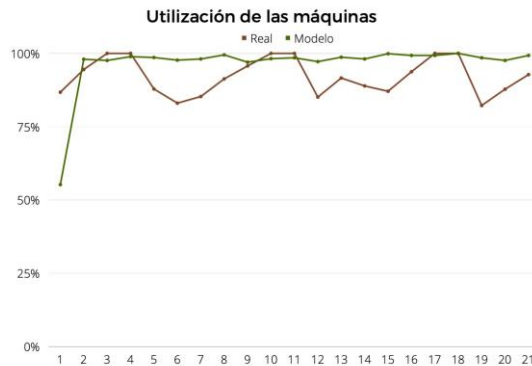


Gráfico 8 Utilización de las máquinas en el periodo de prueba

Según la gráfica anterior, se puede ver un incremento en la utilización de las máquinas respecto a los datos reales. Durante el periodo de prueba, dicho aumento estuvo en promedio 4.33% por encima de la utilización real de las máquinas, lo que demuestra el cumplimiento del objetivo y de esta forma una mejora representativa para “La Cascada”.

- **Ingresos**

En el presente indicador, se buscó evaluar la variación respecto a los ingresos de “La Cascada” teniendo en cuenta el modelo desarrollado.



Gráfico 9 Comportamiento ingresos en el periodo de prueba

Al analizar la gráfica No. 9, se tomaron los ingresos reales durante los 21 días los cuales representaron \$248,837,473 mientras que en el modelo estos fueron \$ 259,210,581. De esta manera, hay un incremento de 4.17%, lo que demuestra una mejora representativa para “La Cascada”.

- **Cumplimiento de la demanda**

El último indicador establecido, muestra la asertividad de los pronósticos frente a los datos reales de demanda con lo que se buscaba disminuir los faltantes y sobrantes de la mayoría de los productos ofrecidos por “La Cascada”.



Gráfico 10 Cumplimiento de la demanda periodo de prueba

Como se observa en la gráfica anterior, el cumplimiento de la demanda presenta el promedio de los 121 productos Pareto y no Pareto de la línea de repostería y panadería del catálogo de “La Cascada”. Estos resultados varían entre un 77.29% y 97.40%, lo cual se debe a que en los días de prueba algunos productos no Pareto presentaron comportamientos irregulares que no están relacionados a algún día especial o datos climatológicos (temperatura, precipitación, pronóstico del clima), lo cual dificulta que el pronóstico sea acertado ya que no presenta una variable específica a la cual asociar el comportamiento inusual.

Los resultados de una manera más detallada del cumplimiento de la demanda se pueden encontrar en el anexo 8.

5. Limitaciones, conclusiones y recomendaciones.

5.1 Limitaciones

Al encontrarse con el catálogo de “La Cascada” fue evidente la gran extensión de productos que se manejan, en algunos de estos se detectaron anomalías en el comportamiento histórico debido a la crisis sanitaria, lo que generó cambios en la presentación de las referencias ya existentes; lo cual afectaría más adelante la precisión de los pronósticos de la demanda. Por otro lado, al recibir la información relacionada con las ventas de la empresa, fue notorio que “La Cascada” no cuenta con bases de datos unificadas, por lo que fue necesario la creación de un archivo en donde se consolidó la información requerida para el correcto funcionamiento de los modelos. Así mismo la compañía no cuenta con la estandarización de sus procesos productivos, por lo cual los tiempos y materias primas requeridas no están registradas de manera exacta ya que son valores aproximados, producto de la experiencia de los trabajadores.

Con respecto a los modelos generados en el entorno de Colab, los tiempos de ejecución para la sintonización de los hiperparámetros de las Redes Neuronales que generaban los pronósticos de la demanda fueron muy altos, ya que no se contaban con los recursos para adquirir una suscripción de la plataforma. Es importante tener en cuenta que los dos modelos presentados están limitado a los 121 productos existentes en el catálogo de “La Cascada”, para las líneas de Panadería y Repostería, si se desean añadir nuevos productos es necesario hacer modificaciones sobre los modelos propuestos. Por otro lado, la planeación de la producción se rige bajo la planificación semanal que hace “La Cascada”, por lo que se decidió que este genere los resultados para este mismo lapso. Por último, toda la información necesaria para ejecutar los modelos se encuentra en la cuenta de Google Drive de “La Cascada”, por tal motivo es necesario ingresar para correr de manera satisfactoria la planeación de la producción y pronósticos de la demanda.

5.2 Conclusiones

Respondiendo la pregunta de investigación, sí es posible utilizar técnicas de Machine Learning para generar los pronósticos de la demanda que a su vez logren resultados positivos, llegando a un cumplimiento promedio de la misma de 86.72%. De igual manera, se logró desarrollar un modelo de optimización multi-objetivo logrando mejorar las utilidades diarias en 17.23%, disminuyendo los costos en 6.36% y maximizando la utilización de las maquinas en 4.33% frente a los resultados presentados por “La Cascada” en ese mismo periodo.

De igual forma, se evidenció la importancia de tratar los datos de manera adecuada para mejorar la asertividad de los pronósticos de la demanda, principalmente cuando se trata de datos atípicos, ya que estos pueden generar cambios en la parametrización y desempeño de los diferentes modelos. Adicionalmente, entre las distintas técnicas de Machine Learning, el que mejor resultados obtuvo en las métricas de RMSE y MAPE fue el de Redes Neuronales, siendo mejor en el 75% de las ocasiones (6 de 8 productos Pareto). Sin embargo, estas técnicas, no presentaron una buena asertividad en los productos con una baja rotación diaria (menos de 20 pedidos al día), para el caso de “La Cascada” en donde presentarían mejores resultados usando Promedios Móviles o modelos ingenuos.

Con esta investigación se logró aportar al uso de servicios en la nube como Google Colab y Google Drive complementado con herramientas tradicionales como Excel, las cuales permitieron establecer una mejor administración de los recursos de “La Cascada” en el horizonte de planeación de la producción diaria, cumpliendo con las metas de la compañía.

5.3 Recomendaciones

Para futuros estudios se recomienda realizar la comparación del método propuesto de pronósticos, con los modelos de series de tiempo ARIMA, o combinación de modelos de Machine Learning (stacking) para comprobar si se adapta mejor a la demanda en este tipo de negocio. Por último, para la planeación de la producción se sugiere realizar la normalización de las variables en la función objetivo ponderada para compensar el peso que tienen dentro de esta.

6. Referencias

Bettoni, L. (2018). *GUSEK*. <http://gusek.sourceforge.net/gusek.html>

CRISP-DM: La metodología para poner orden en los proyectos. (2016, agosto 2). Sngular. <https://www.sngular.com/es/data-science-crisp-dm-metodologia/>

Duarte, B. P. M., Gonçalves, A. M. M., & Santos, L. O. (2021). Optimal Production and Inventory Policy in a Multiproduct Bakery Unit. *Processes*, 9(1), 101. <https://doi.org/10.3390/pr9010101>

Elcio Tarallo, Akabane, G. K., Shimabukuru, C. I., Mello, J., & Amancio, D. (2019). Machine Learning in Predicting Demand for Fast-Moving Consumer Goods: An Exploratory Research. *IFAC-PapersOnLine*, 52(13), 737-742. <https://doi.org/10.1016/j.ifacol.2019.11.203>

Ezra, P. N., Oladugba, A. V., Ohanuba, F. O., & Opara, P. N. (2020). Goal Optimization of a Pastry Company. *American Journal of Operational Research*, 10(1), 17-21.

Garre, A., Ruiz, M. C., & Hontoria, E. (2020). Application of Machine Learning to support production planning of a food industry in the context of waste generation under uncertainty. *Operations Research Perspectives*, 7, 100147. <https://doi.org/10.1016/j.orp.2020.100147>

Google Colaboratory. (s. f.). Recuperado 10 de enero de 2022, de <https://colab.research.google.com/notebooks/welcome.ipynb?hl=es>

Hecker, F., Hussein, W., & Becker, T. (2010). Analysis and optimization of a bakery production line using

- ARENA. *International Journal of Simulation Modelling*, 9(4), 208-216.
[https://doi.org/10.2507/IJSIMM09\(4\)4.175](https://doi.org/10.2507/IJSIMM09(4)4.175)
- Hecker, F. T., Hussein, W. B., Paquet-Durand, O., Hussein, M. A., & Becker, T. (2013). A case study on using evolutionary algorithms to optimize bakery production planning. *Expert Systems with Applications*, 40(17), 6837-6847. <https://doi.org/10.1016/j.eswa.2013.06.038>
- Hecker, F. T., Stanke, M., Becker, T., & Hitzmann, B. (2014). Application of a modified GA, ACO and a random search procedure to solve the production scheduling of a case study bakery. *Expert Systems with Applications*, 41(13), 5882-5891. <https://doi.org/10.1016/j.eswa.2014.03.047>
- Huber, J., Gossmann, A., & Stuckenschmidt, H. (2017). Cluster-based hierarchical demand forecasting for perishable goods. *Expert Systems with Applications*, 76, 140-151. <https://doi.org/10.1016/j.eswa.2017.01.022>
- Huber, J., & Stuckenschmidt, H. (2020). Daily retail demand forecasting using machine learning with emphasis on calendric special days. *International Journal of Forecasting*, 36(4), 1420-1438.
<https://doi.org/10.1016/j.ijforecast.2020.02.005>
- Huber, J., & Stuckenschmidt, H. (2021). Intraday shelf replenishment decision support for perishable goods. *International Journal of Production Economics*, 231, 107828. <https://doi.org/10.1016/j.ijpe.2020.107828>
- Kilimci, Z. H., Akyuz, A. O., Uysal, M., Akyokus, S., Uysal, M. O., Atak Bulbul, B., & Ekmis, M. A. (2019). An Improved Demand Forecasting Model Using Deep Learning Approach and Proposed Decision Integration Strategy for Supply Chain. *Complexity*, 2019, 1-15. <https://doi.org/10.1155/2019/9067367>
- Lasek, A., Cercone, N., & Saunders, J. (2016). *Restaurant Sales and Customer Demand Forecasting: Literature Survey and Categorization of Methods* (A. Leon-Garcia, R. Lenort, D. Holman, D. Staš, V. Krutilova, P. Wicher, D. Cagánová, D. Špírková, J. Golej, & K. Nguyen, Eds.; pp. 479-491). Springer International Publishing. https://doi.org/10.1007/978-3-319-33681-7_40
- Main Topics—PuLP 2.6.0 documentation*. (2009). <https://coin-or.github.io/pulp/main/index.html>
- Onasanya, B. O., Feng, Y., Wang, Z., Samakin, O. V., Wu, S., & Liu, X. (2020). Optimizing Production Mix Involving Linear Programming with Fuzzy Resources and Fuzzy Constraints. *International Journal of Computational Intelligence Systems*, 13(1), 727-733. <https://doi.org/10.2991/ijcis.d.200519.002>
- One Call API: weather data for any geographical coordinate—OpenWeatherMap*. (s. f.). Recuperado 10 de enero de 2022, de <https://openweathermap.org/api/one-call-api>
- POWER / Data Access Viewer*. (s. f.). Recuperado 10 de enero de 2022, de <https://power.larc.nasa.gov/data-access-viewer/>
- Priyadarshi, R., Panigrahi, A., Routroy, S., & Garg, G. K. (2019). Demand forecasting at retail stage for selected vegetables: A performance analysis. *Journal of Modelling in Management*, 14(4), 1042-1063. <https://doi.org/10.1108/JM2-11-2018-0192>
- Seubert, F., Taigel, F., Stein, N., & Winkelmann, A. (2020). *Making the Newsvendor Smart – Order Quantity Optimization with ANNs for a Bakery Chain*. 11.
- Tanizaki, T., Hoshino, T., Shimmura, T., & Takenaka, T. (2019). Demand forecasting in restaurants using machine learning and statistical analysis. *Procedia CIRP*, 79, 679-683. <https://doi.org/10.1016/j.procir.2019.02.042>
- Top Big Data. (2020, julio 8). *4 algoritmos de detección de valores atípicos automáticos en Python*. <https://topbigdata.es/4-algoritmos-de-deteccion-de-valores-atipicos-automaticos-en-python/>
- Tsoumakas, G. (2019). A survey of machine learning techniques for food sales prediction. *Artificial*

Intelligence Review, 52(1), 441-447. <https://doi.org/10.1007/s10462-018-9637-z>

Wang, C., & Liu, X.-B. (2013). Integrated production planning and control: A multi-objective optimization model. *Journal of Industrial Engineering and Management*, 6(4), 815-830. <https://doi.org/10.3926/jiem.771>

Wari, E., & Zhu, W. (2016). A survey on metaheuristics for optimization in food manufacturing industry. *Applied Soft Computing*, 46, 328-343. <https://doi.org/10.1016/j.asoc.2016.04.034>

Yang, C., & Sutrisno, H. (2018). Short-Term Sales Forecast of Perishable Goods for Franchise Business. *2018 10th International Conference on Knowledge and Smart Technology (KST)*, 101-105. <https://doi.org/10.1109/KST.2018.8426091>