

**UNIVERSIDAD SAN FRANCISCO DE QUITO USFQ**

**Colegio de Ciencias e Ingenierías**

**Optimización de Operaciones en una Florícola Utilizando  
Métodos de Predicción y Programación Lineal**

**Mauricio Nicolás Castillo Santander**

**Samantha Micaela Correa Navarrete**

**Andrés Fernando Paz Liger**

**Ingeniería Industrial**

Trabajo de fin de carrera presentado como requisito para la obtención del título  
de

Ingeniero Industrial

Quito, 11 de diciembre de 2023

**UNIVERSIDAD SAN FRANCISCO DE QUITO USFQ**

**Colegio de Ciencias e Ingenierías**

**HOJA DE CALIFICACIÓN  
DE TRABAJO DE FIN DE CARRERA**

**Optimización de Operaciones en una Florícola Utilizando  
Métodos de Predicción y Programación Lineal**

**MAURICIO NICOLÁS CASTILLO SANTANDER**

**MICAELA SAMANTHA CORREA NAVARRETE**

**ANDRÉS FERNANDO PAZ LIGER**

**Nombre del profesor, Título académico: Carlos Suárez, Ph.D**

Quito, 11 de diciembre de 2023

## © DERECHOS DE AUTOR

Por medio del presente documento certifico que he leído todas las Políticas y Manuales de la Universidad San Francisco de Quito USFQ, incluyendo la Política de Propiedad Intelectual USFQ, y estoy de acuerdo con su contenido, por lo que los derechos de propiedad intelectual del presente trabajo quedan sujetos a lo dispuesto en esas Políticas.

Asimismo, autorizo a la USFQ para que realice la digitalización y publicación de este trabajo en el repositorio virtual, de conformidad a lo dispuesto en la Ley Orgánica de Educación Superior del Ecuador.

Nombres y apellidos: Mauricio Nicolás Castillo Santander

Código: 00208750

Cédula de identidad: 1723357222

Nombres y apellidos: Andrés Fernando Paz Liger

Código: 00209141

Cédula de identidad: 1719058610

Nombres y apellidos: Samantha Micaela Correa Navarrete

Código: 00214157

Cédula de identidad: 1750770909

Lugar y fecha: Quito, 11 de diciembre de 2023

## **ACLARACIÓN PARA PUBLICACIÓN**

**Nota:** El presente trabajo, en su totalidad o cualquiera de sus partes, no debe ser considerado como una publicación, incluso a pesar de estar disponible sin restricciones a través de un repositorio institucional. Esta declaración se alinea con las prácticas y recomendaciones presentadas por el Committee on Publication Ethics COPE descritas por Barbour et al. (2017) Discussion document on best practice for issues around theses publishing, disponible en <http://bit.ly/COPETHeses>.

## **UNPUBLISHED DOCUMENT**

**Note:** The following capstone project is available through Universidad San Francisco de Quito USFQ institutional repository. Nonetheless, this project – in whole or in part – should not be considered a publication. This statement follows the recommendations presented by the Committee on Publication Ethics COPE described by Barbour et al. (2017) Discussion document on best practice for issues around theses publishing available on <http://bit.ly/COPETHeses>.

## RESUMEN

En el actual panorama de constante desarrollo tecnológico, la adopción de nuevas tecnologías como el aprendizaje automático o Machine Learning, el aprendizaje profundo o Deep Learning y la inteligencia artificial proporciona a las empresas una ventaja significativa sobre sus competidores al permitirles tomar decisiones basadas en información más precisa sobre el comportamiento del mercado, como también tener métodos matemáticos que permitan optimizar procesos.

Ante la ausencia de una metodología de pronóstico de demanda para una empresa florícola, se comparó el rendimiento de las metodologías de pronóstico tradicionales como SARIMA, ARIMA y Holt-Winters con los modelos de aprendizaje automático de Series de Fourier y redes neuronales de memoria larga a corto plazo o por sus siglas en inglés Long Short-Term Memory (LSTM). Con esta información, se propone mejorar la toma de decisiones de la empresa al definir la mínima cantidad de flor que debe producir.

Por otro lado, se propone un problema de asignación de programación lineal para mejorar la asignación de producción de rosas, para optimizar el costo total de operación. Este problema toma en cuenta los parámetros de costos de producción, calidad de la flor, cumplimiento de producción de las fincas y la cantidad mínima de flores que se deben cosechar cada semana. De esta manera, la empresa tendrá un método matemático que reduzca los costos operativos y las pérdidas por devolución de flores que no cumplan con la calidad acordada con el cliente.

**Palabras clave:** predicción, Machine Learning, florícola, estacionalidad, programación lineal.

## ABSTRACT

In the current scenario of constant technological development, the adoption of new technologies such as Machine Learning, Deep Learning and artificial intelligence provides companies with a significant advantage over their competitors by allowing them to make decisions based on more accurate information about market behavior, as well as mathematical methods to optimize processes.

In the absence of a demand forecasting methodology for a flower company, the performance of traditional forecasting methodologies such as SARIMA, ARIMA and Holt-Winters was compared with Fourier Series Machine Learning models and Long Short-Term Memory (LSTM) neural networks. With this information, it is proposed to improve the company's decision making by defining the minimum number of flowers to produce.

On the other hand, a linear programming allocation problem is proposed to improve the rose production allocation to optimize the total cost of operation. This problem takes into account the parameters of production costs, flower quality, production compliance of the farms and the minimum number of flowers to be harvested each week. In this way, the company will have a mathematical method to reduce operating costs and losses due to the return of flowers that do not meet the quality agreed with the customer.

**Key words:** prediction, Machine Learning, floriculture, seasonality, linear programming.

## Tabla de Contenidos

1. GLOSARIO .....	9
2. OBJETIVOS.....	10
2.1 Objetivo general.....	10
2.2 Objetivos específicos.....	10
3. INTRODUCCIÓN .....	11
Gráfico 1: Pareto de demanda por tipo de flor mostrando los 10 primeros tipos de flor.....	13
Tabla 1: Variedades de flores producidas en fincas .....	13
4.1 Impacto al negocio .....	14
4. METODOLOGÍA DMADV (DEFINIR, MEDIR, ANALIZAR, DISEÑAR, VERIFICAR).....	15
5. PREDICCIÓN DE DEMANDA .....	17
5.1 Revisión de literatura .....	17
5.2 Metodología DMADV.....	19
5.2.1 Definir .....	19
5.2.2 Medir.....	19
5.2.3 Analizar .....	20
5.2.4 Diseñar .....	21
5.2.5 Verificar .....	23
7. ASIGNACIÓN DE PRODUCCIÓN .....	24
7.1 Revisión de literatura .....	24
7.2 Metodología DMAV .....	26
7.2.1 Definir .....	26
7.2.2 Medir.....	26
7.2.3 Analizar.....	28
Gráfico 2: % Notas de crédito de las fincas por mes del año 2023. ....	28
Gráfico 3: % Cumplimiento de las fincas por semana del año 2023 de Rosa Color. ....	29
Gráfico 4: % Cumplimiento de las fincas por semana del año 2023 de Rosa Roja. ....	29
Gráfico 5: % Precio y Costos de Rosa Roja por semana del año 2023. ....	30
Gráfico 6: % Precio y Costos de Rosa Color por semana del año 2023.....	30
Gráfico 7: Comparación capacidad vs asignación por semana del año 2023.....	31
7.2.4 Diseñar .....	32
Modelo 1: Optimización de la asignación de la producción semanal.....	32
Modelo 2: Optimización de asignación de la producción por órdenes de compra .....	36
7.2.5 Verificar .....	40
Tabla 2: Comparación resultados cantidad asignada a cada finca 2023. ....	40
Tabla 3: Comparación costos asociados con la producción 2023 (Modelo 1).....	40

<b>Tabla 4:</b> Comparación ganancias en la producción 2023 (Modelo 2). .....	41
<b>8. CONCLUSIONES Y RECOMENDACIONES</b> .....	41
<b>9. LECCIONES APRENDIDAS Y SIGUIENTES PASOS</b> .....	43
<b>10. REFERENCIAS</b> .....	46
<b>11. ANEXOS</b> .....	49
<b>Anexo 1:</b> Pareto de producción por tipo de flor .....	49
<b>Anexo 2:</b> Pareto de demanda por cliente.....	49
<b>Anexo 3:</b> Modelo del problema de asignación.....	50
<b>Anexo 4:</b> Tabla con los campos de los datos obtenidos para predicción de demanda .....	51
<b>Anexo 5:</b> Comportamiento de la demanda de Rosa Roja y Rosa Color por semana .....	52
<b>Anexo 6:</b> Boxplot de los datos de demanda por año .....	52
<b>Anexo 7:</b> tabla con los resultados de la limpieza y agrupación de datos para la demanda. Se muestran los 5 primeros registros para Rosa Color. ....	53
<b>Anexo 8:</b> Tabla con resumen de los MAPE obtenidos para cada metodología y rosa. ....	53
<b>Anexo 9:</b> Cantidad de hectáreas por cada finca en Ecuador. ....	54
<b>Anexo 10:</b> Porcentaje de notas crédito de las fincas por mes en el año 2023 .....	54
<b>Anexo 11:</b> Porcentaje de cumplimiento de las fincas por semana en el año 2023 .....	55
<b>Anexo 12:</b> Tabla costos de producción de las rosas en las fincas en dólares. ....	56
<b>Anexo 13:</b> Tabla precio de las rosas en el mercado de Miami en dólares.....	56
<b>Anexo 14:</b> Tabla capacidad máxima y mínima de producción de tallos por día de las fincas. ....	56
<b>Anexo 15:</b> Tabla producción y capacidad de Rosa Roja con porcentaje de tercerización 2023. ....	56
<b>Anexo 16:</b> Tabla producción y capacidad de Rosa Color con porcentaje de tercerización 2023.....	57

## 1. GLOSARIO

Término	Significado
ARIMA	Media móvil integrada autorregresiva
Gipsófila	Flores de hasta 15 centímetros de altura de color blanco
Holt-Winters	Método de predicción que utiliza suavizamiento exponencial
Long Short-Term Memory o Memoria Larga a Corto Plazo (LSTM)	Modelo de Deep Learning o aprendizaje profundo de redes neuronales
Modelos de aprendizaje automático de series de Fourier	Las series de Fourier son series de términos coseno y seno utilizadas para representar funciones.
Programación lineal	Conjunto de técnicas de modelado y solución de problemas utilizado en Investigación de Operaciones que involucran funciones lineales.
Rosa Color	Rosa de tipo Freedom que se puede producir en varios colores
Rosa Roja	Rosa de tipo Freedom de color rojo
SARIMA	Media móvil integrada autorregresiva estacional

## 2. OBJETIVOS

### 2.1 Objetivo general

- Optimizar la asignación de la demanda de rosas en las 4 fincas encargadas del cultivo de rosas, utilizando metodologías de pronóstico tradicionales como SARIMA, ARIMA y Holt-Winters frente a modelos de aprendizaje automático de Series de Fourier y memoria a corto plazo (LSTM) para predecir series de tiempo estacionales. Se planteará un problema de programación lineal para la asignación de órdenes a cada una de las fincas tomando en cuenta parámetros como la calidad de flor, nivel de servicio de las fincas, costos de producción de las fincas por tipos de flor y las capacidades mínimas y máximas de producción.

### 2.2 Objetivos específicos

- Realizar pronósticos de la demanda de la familia de SKU Rosa Color y Rosa Roja para una empresa florícola colombiana con sede en Ecuador, mediante metodologías de pronóstico tradicionales de SARIMA, ARIMA y Holt-Winters versus modelos de aprendizaje automático de series de Fourier y memoria a corto plazo (LSTM).
- Comparar las predicciones de ambas metodologías y establecer cuál es más precisa para el mercado de clientes de la empresa.
- Optimizar la asignación de la producción de Rosa Color y Rosa Roja entre las 4 diferentes fincas que pertenecen a la empresa.
- Presentar al gerente de la sede ecuatoriana los resultados en términos de costos de operación que se puede alcanzar con el uso del algoritmo de asignación propuesto en la investigación para cambiar las políticas de asignación actuales de la empresa.

### 3. INTRODUCCIÓN

Ecuador es el tercer exportador de flores más grande del mundo, en donde el 73% de la exportación de flores cortadas son rosas. Esto es posible debido a la posición privilegiada del país, ya que se encuentra en la línea media del planeta lo que permite que tenga luz natural la mayor parte del año asegurando una producción continua de varios tipos de flores. El éxito de Ecuador al plantar flores se debe a los factores geográficos y climáticos que permiten operar los invernaderos a costos menores comparados con los invernaderos europeos (Conefrey, 2015).

Esta ventaja se debe a que el país tiene menos variaciones extremas de temperatura y solo debe enfocarse en proteger a las flores de elementos externos que puedan dañarlas, mientras que, por ejemplo, en Alemania deben invertir en tecnologías más avanzadas para mantener invernaderos con una temperatura estable y con un nivel de rayos UV constantes para que las flores puedan crecer (Hair, 2019). A pesar de la ventaja de producción, la exportación de flores hacia países europeos no ha sido una prioridad para el país, debido a los altos costos de envío y al corto tiempo de vida de las flores, las cuales deben cumplir con estándares de calidad que no siempre se pueden garantizar en los envíos internacionales. Acorde a la Comisión Económica de las Naciones Unidas para Europa o la UN/ECE (1994), el mercado floricultor debe tener los siguientes estándares de calidad para alcanzar un grado de exportación o de categoría de calidad superior («UN/ECE STANDARD H-1 concerning the marketing and commercial quality control of CUT FLOWERS moving in international trade between and to UN/ECE member countries», 1995. P. 2).

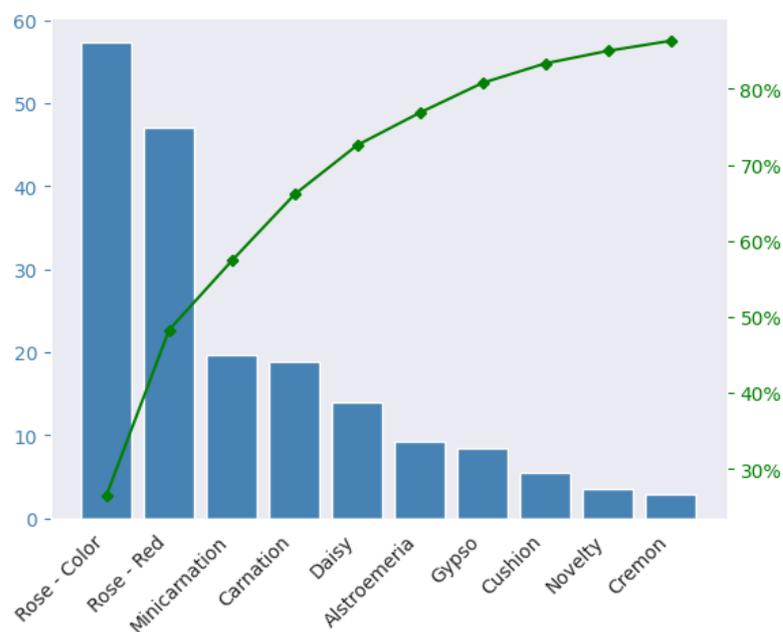
- Libre de daños causados por cualquier tipo de parasito de procedencia animal o vegetal.
  
- Libre de cualquier tipo de materia extraña la cual afecte a la apariencia de la flor.

- Libre de golpes.
- Libre de defectos de desarrollo.
- El tallo debe estar acorde a la especie y la variedad, debe ser fuerte y rígido para soportar el peso de la flor.

Los principales países importadores de flores son Estados Unidos, Alemania, Países Bajos, Reino Unido y Rusia teniendo una cuota del mercado cercana al 60%. Como se menciona, los países europeos son aquellos que compran más flores siendo ellos los que tienen el 60% de las importaciones mundiales, seguido por Estados Unidos y Japón (Guaita-Pradas et al., 2023).

Debido a los altos costos de transportar hacia Europa las flores, el principal enfoque de exportaciones es hacia Estados Unidos, debido a la cercanía continental en la que se encuentran. Durante el periodo de 2016 a 2020 las variedades que más se exportaron de Ecuador fueron las rosas con un 73%, flores frescas y gipsófilas con un 22%, mientras que el resto de los productos florícolas varían entre 2% y 1%. Demostrando que el principal producto florícola de exportación de Ecuador son las rosas (Guaita-Pradas et al., 2023).

La empresa donde se va a realizar el presente proyecto se fundó en 1987 como una compañía de distribución de flores cultivadas en Ecuador y Colombia, las cuales venden a clientes ubicados en Estados Unidos y Canadá. Dentro de su portafolio de productos ofrecen 40 variedades de flores, pero este estudio se enfocará en la rosa del tipo Freedom, la cual es la Rosa Roja y de otros 26 colores que se producen en 4 de las 5 fincas en Ecuador. El estudio se realizará en estos dos tipos de flores debido a que componen el 80% de las ventas de Ecuador además de ser el producto más solicitado por sus clientes. En el Anexo 1 se puede observar la producción de flor en Ecuador.

**Gráfico 1:** Pareto de demanda por tipo de flor mostrando los 10 primeros tipos de flor.

Las 5 fincas están ubicadas en Otavalo, Cayambe, Tabacundo y el Quinche; por confidencialidad se va a mencionar los códigos de las fincas. Dentro de cada una se producen distintas variedades de flores, cómo se detalla en la siguiente tabla.

**Tabla 1:** Variedades de flores producidas en fincas

Finca	Flores que produce
SM	Rosa Color y Roja
CW	Rosa Color y Roja
MN	Rosa Color y Roja
MB	Rosa Color y Roja
FS	Gipsófila

Por otro lado, los clientes que componen el 80% de los ingresos se encuentran en Estados Unidos, los cuales son Walmart, Cosco, Polo y Aldi (Anexo 2).

Por este motivo, el objetivo de este estudio se centra en la predicción de la demanda de las rosas rojas y de color para que la empresa implemente una metodología que permita visualizar la demanda de las rosas, además se va a complementar con el modelo de asignación el cual va a permitir que el proceso de asignación que maneja la empresa sea mejorado al demostrar que el modelo matemático desarrollado entrega mejores resultados reduciendo los costos totales de producción.

#### **4.1 Impacto al negocio**

A partir de los resultados obtenidos en este proyecto se espera determinar la mejor metodología de predicción para la demanda de flores. Actualmente la sede ecuatoriana no maneja pronósticos de ventas con modelos matemáticos, esta es reactiva en sus decisiones de producción con la información proporcionada por el departamento comercial ubicado en Miami. Este departamento recibe los pedidos de los clientes e ingresan las órdenes al sistema semanalmente.

Además, este departamento realiza una inferencia de la cantidad que lograrán vender el siguiente año, en base a esta inferencia el departamento comercial brinda al área de producción un número mínimo de tallos que deben producir cada semana del año y es la información que maneja Ecuador y en base a esta, toma decisiones de producción. Debido a incrementos o descensos en la demanda real, Ecuador se ha visto obligado a comprar flor cuando la demanda crece inesperadamente y a desechar flor en el caso contrario. Estos desperdicios y falta de stock se dan debido a que la sede ecuatoriana es incapaz de tener información sobre el mercado para reaccionar a tiempo. Por lo que con la predicción obtenida se proporcionará a la empresa una herramienta certera en la visualización de la demanda para así mejorar la toma de decisiones en cuanto a la producción y operación del negocio.

Por otro lado, una segunda problemática que se observa en la empresa es que maneja una política de asignación de producción la cual no es eficaz. Los pedidos se asignan de manera equitativa a las fincas sin importar que cada finca tenga diferentes costos de producción, niveles de servicio y calidad de flor. Esto hace que no se asegure el mayor rendimiento posible para la empresa, por lo que se va a adaptar un modelo del problema de asignación que minimice los costos de producción totales cumpliendo la demanda y asegurando la mayor calidad de flor, nivel de servicio y las capacidades de producción. Este modelo se validará asignando las órdenes del año 2023 hasta la semana 30 para así obtener un costo esperado. Al comparar los costos optimizados con los costos reales se presentará a la empresa el ahorro esperado al usar una asignación óptima de sus pedidos para que cambien su política de asignación.

Por último, las dos herramientas aplicadas en este proyecto se pueden usar en conjunto para tener una mejor idea de lo que pasará durante el siguiente año en temas de demanda y de la producción. Alimentando al modelo de asignación con los datos de la predicción de la demanda, se busca obtener un detalle de las producciones y flores tercerizadas que posiblemente tendrá que comprar la empresa en las distintas semanas, así como se obtendrá un costo óptimo con la distribución de los pedidos del siguiente año.

#### **4. METODOLOGÍA DMADV (DEFINIR, MEDIR, ANALIZAR, DISEÑAR, VERIFICAR)**

Esta metodología es utilizada por las empresas cuando se requiere rediseñar productos y procesos con el objetivo de lograr una certificación Lean Six Sigma y por este motivo dentro del ámbito académico se lo llama Diseño para Seis Sigma (DPSS). Por lo que esta metodología es adecuada para este proyecto de investigación debido a que se busca mejorar procesos ya existentes dentro de la empresa, los cuales son la metodología de predicción de

demanda y de asignación de producción. A continuación, se explica cada uno de los pasos de esta metodología. (Montoya & Rendón, 2012).

1. **Definir:** El objetivo de esta fase es identificar las metas del proyecto las cuales debe estar alineadas con el objetivo que busca obtener la empresa, además de identificar las áreas clave en donde se va a desarrollar el estudio.
2. **Medir:** En esta fase, el objetivo es recolectar los datos planificando las fechas y responsables que estarán a cargo de estas tareas para poder entender las necesidades del cliente y así poder cuantificarlas.
3. **Analizar:** En esta etapa se debe revisar, evaluar y seleccionar las posibles alternativas para el diseño del nuevo proceso para satisfacer las necesidades del cliente.
4. **Diseñar:** Durante esta fase se debe desarrollar los detalles de las mejoras que se van a proponer, en donde se deben identificar las distintas dificultades que se pueden presentar además de desarrollar los planes de las pruebas piloto con el objetivo de llegar al resultado deseado.
5. **Verificar:** Para esta etapa se desarrolla el producto/proceso de forma que se pueda aplicar en la vida real y validar su desempeño aplicado.

## 5. PREDICCIÓN DE DEMANDA

### 5.1 Revisión de literatura

Al conocer el proceso de producción de flores dentro de la empresa florícola se identificó que los pronósticos que realizan no se basan en metodologías de predicción existentes, sino que lo realizan en base al estimado de producción de las fincas y lo intentan alinear con la demanda real. Este pronóstico lo realizan utilizando la demanda del año anterior y lo revisan con la producción de las fincas durante el año y con eso generan las predicciones, en esta reunión participan los gerentes y durante esa reunión establecen las decisiones operativas para el siguiente año. Por este motivo se propuso desarrollar en Python algoritmos de predicción de demanda que permitan a la empresa entender como ha ido cambiando el mercado y puedan tomar decisiones en base a esta información. Por este motivo, la selección de metodologías de predicción se realizará en base a revisión de literatura e identificando que modelos se utilizan dentro de la industria florícola.

Dentro de la cadena de suministro de las empresas ha existido la dificultad de predecir la demanda de los consumidores, más aún cuando se trata de productos de corta vida útil, ya que, al tener un exceso de este tipo de productos, se deberán desechar aquellos que no se vendan. Los pronósticos permiten a los tomadores de decisiones reaccionar ante los cambios del mercado modificando sus estrategias para obtener mayores retornos (Haselbeck et al., 2022). Por ello, la importancia de tener un buen modelo de predicción que se ajuste a la demanda del mercado y a sus cambios va a brindar la oportunidad de tomar decisiones mejor informadas y planificar a corto y mediano plazo.

Para poder realizar pronósticos se debe recolectar información histórica de la demanda que contenga factores que permitan describir el comportamiento del mercado, asimismo se debe determinar modelos de predicción que se ajusten al comportamiento de los datos cuando

se haga el análisis respectivo. Actualmente, se puede hacer uso de otras herramientas que permiten predecir esta demanda como son modelos de aprendizaje automático más conocidos como Machine Learning (Punia & Shankar, 2022). Dentro de la demanda de productos afectan muchos factores ya sean fechas festivas o sean por una necesidad urgente, un ejemplo de esto fue el aumento de demanda de mascarillas por la pandemia de COVID-19.

Las flores al ser un producto que es perecible, es posible hacer una comparación con el comportamiento de las frutas. Dentro del artículo de Chen et al. (2023) mencionan que se deben manejar los productos de forma que salga primero el producto que tenga menos vida útil quitando el enfoque de primero que entra, primero que sale o First In First Out (FIFO); porque estos productos se pueden dañar dependiendo de las condiciones ambientales, donde la temperatura es el factor que más afecta a la vida útil de productos naturales. Este comportamiento es similar en la industria de las flores, ya que aquellas flores cortadas solo pueden guardarse 3 días en un cuarto frío para asegurar que la flor tenga el periodo de vida útil acordado con el cliente, se empaacan las flores en cajas previamente enfriadas.

Dentro de la literatura usada para predecir series de tiempo, en el artículo de Haselbeck et al. (2022) menciona que se sigue utilizando métodos tradicionales de predicción como suavizamiento exponencial o el modelo Auto regresivo Integrado de Promedio Móvil, más conocida como ARIMA; los cuales resultan, en algunos casos, ser competitivos frente a modelos de Machine Learning y redes neuronales. Por otro lado, dentro del artículo de Bharti et al. (2023) mencionan que, para la predicción de su modelo, los métodos tradicionales presentaban baja certeza mientras que los algoritmos desarrollados con redes neuronales se desempeñaban mejor para predecir la demanda.

## **5.2 Metodología DMADV**

### **5.2.1 Definir**

Al identificar la falta de implementación de un método matemático para la predicción de demanda de rosas, se va a comparar el desempeño de metodologías tradicionales de predicción ARIMA, SARIMA, Holt-Winters frente a modelos de redes neuronales recurrentes de Long Short – Term Memory de Deep Learning y series de Fourier de Machine Learning. Con la comparación de estos modelos se busca determinar que método es más preciso para pronosticar las ventas de rosas en base a los datos proporcionados en el Anexo 4.

Los datos obtenidos se encuentran desde la semana 1 de 2021 hasta la semana 40 de 2023, debido a políticas de privacidad de la empresa no se envió la fecha en la que solicita la entrega del producto el cliente, pero se conoce que a partir de la fecha de pedido se tiene 3 semanas para producir y entregar al cliente.

Con estos datos, se va a realizar un pronóstico de la cantidad de rosas que van a solicitar los clientes de la empresa 4 semanas adelante. El software definido para realizarlo es Python debido a la facilidad y potencia que tiene para trabajar con grandes cantidades de datos, del mismo modo que tiene las bibliotecas necesarias para realizar los entrenamientos de modelos de Machine Learning, Deep Learning y métodos tradicionales.

### **5.2.2 Medir**

Con el fin de obtener los datos de la demanda de flores, se coordinó una reunión virtual con el agente de cartera de uno de los clientes de la empresa en Miami. Durante la reunión, el agente explicó el proceso de recepción de pedidos, el cual se detalla a continuación.

1. Cliente de Estados Unidos envía orden de compra por correo electrónico al agente de cartera encargado.
2. Agente envía orden de compra a consolidarse al encargado de revisión de pedidos.

3. Encargado de revisión de pedidos consolida información y envía pedidos de producción por correo electrónico a las personas de Ecuador y Colombia para que distribuyan entre las fincas.

El agente también indicó que los datos de la demanda de flores de todos los clientes se encuentran en la base de datos del agente de consolidación de pedidos, ya que el agente de cartera solo tiene información sobre un cliente específico.

Al terminar la reunión con el agente de cartera, se procedió a coordinar la reunión con el agente de consolidación de pedidos. Este explicó el mismo proceso de recepción de pedidos mencionado antes y aceptó proporcionar los datos necesarios para el desarrollo del estudio.

### **5.2.3 Analizar**

Durante el análisis exploratorio de datos con el set de demanda filtrado por rosas rojas y de colores, se observó que se repiten picos altos de demanda en las semanas correspondientes al día de San Valentín y día de las madres (Anexo 5). Con esto se determina que la demanda es estacional debido a que tiene un patrón que se repite cada año (Nahmias, 2007). Se debe notar que si se elimina la estacionalidad de los datos se puede dejar una serie de tiempo que tenga media y varianzas constantes transformando los datos a una serie de tiempo estacionaria.

Al realizar un diagrama de caja y bigotes tanto para Rosa Roja como para Rosa Color, se observa que los datos están dentro del mismo rango durante los 3 años que se tiene datos, además que también se observa que tiene un pequeño decrecimiento en la demanda, además de confirmar que los datos atípicos pertenecen a las fechas de San Valentín y de día de las madres. Con este entendimiento de los datos se procede a realizar los algoritmos para la predicción de la demanda.

#### 5.2.4 Diseñar

El software donde se desarrolló las predicciones fue en Python, en el cual se preparó y modificó los datos para realizar las predicciones. En la preparación de los datos, se eliminaron las columnas que solo eran informativas sobre el proceso de colocación de órdenes y se agrupó por familia de flor y por fecha de colocación de orden como está en el Anexo 7; debido a que la información de tiempo que se tiene es el año y el número de semana, se transformó este campo a que muestre la fecha de cada lunes de cada semana del año. Al agrupar el set de datos de esta manera se obtuvo la tabla del Anexo 6 que contiene 144 registros tanto para Rosa Roja como para Rosa Color. Con esta tabla resultante se procedió a dividir en 130 datos para el set de entrenamiento que es el 90% de los datos, y los 14 registros restantes se pasó como set de pruebas.

Dentro de los métodos para comparar series de tiempo estacionales se plantea usar SARIMA, en donde sus siglas en inglés son Seasonal Autoregressive Integrated Moving Average y en español significan Modelo Auto Regresivo Integrado de Promedios Móviles con Estacionalidad (SARIMA), también se puede utilizar el método de suavizamiento exponencial triple o también llamado método de Holt-Winters que también es útil para predecir este tipo de datos. Por último, con una transformación de datos se plantea quitar la estacionalidad de la serie de tiempo y aplicar ARIMA.

ARIMA y SARIMA son métodos de predicción que están basados en el supuesto de que los valores futuros de una serie de tiempo se pueden predecir a partir de los valores pasados de la serie. El modelo ARIMA necesita que los datos sean estacionarios ya que este no considera estacionalidad, este se compone de 3 partes las cuales son la parte auto regresiva (p) que determina el número de muestras anteriores que explican la muestra presente, la parte de diferencia (d) es el número de diferencias que se deben aplicar para que los datos se vuelvan estacionarios, y por último el promedio móvil (q) es el promedio móvil de la serie

estacionaria, mientras que SARIMA tiene los mismos componentes estacionarios y añade 4 componentes estacionales en los cuales la parte auto regresiva estacional (P) es el número de muestras estacionales, la diferencia estacional (D), el promedio móvil estacional (Q) y por último el periodo cada cuanto se repite el ciclo (s). Así se tiene que ARIMA se representa como  $ARIMA(p,d,q)$  y  $SARIMA(p,d,q)(P,D,Q)_s$ .

El método de suavizamiento exponencial triple o de Holt–Winters es un método de pronóstico que utiliza un único modelo de suavizado exponencial, en donde un valor de  $\alpha$  alto indica que los valores pasados tienen más importancia que los valores actuales y un valor bajo indica que los valores actuales de la serie de tiempo tienen más importancia que los valores pasados. Esta metodología se utiliza cuando se tiene una serie de tiempo con estacionalidad y tendencia, además de tener 2 métodos. El método aditivo representa una estacionalidad y tendencia que no aumentan en el tiempo mientras que el modelo multiplicativo trata de representar los aumentos o disminuciones de la estacionalidad y de la tendencia.

Las series de Fourier son una idea del matemático francés Fourier que explica que con un conjunto de funciones base se puede formar cualquier función, en este caso las funciones base son seno y coseno (Guo et al., 2020). Esta idea al traspasarla a series de tiempo, lo que implica es utilizar las funciones mencionadas para que se ajuste a la tendencia y estacionalidad de los datos como se menciona en el artículo de Danbatta y Varol (2021) en el cuál utilizan esta técnica en conjunto con redes neuronales para modelar la demanda del turismo.

Por último, el método de Long-Short Term Memory de redes neuronales es una metodología que amplía la memoria para que se aprenda de experiencias importantes que pasaron en el tiempo y dentro de cada red neuronal pueden mantener esta información

durante largo tiempo y decide si se guarda o elimina esa información dependiendo de la importancia que se asigne a esa información. Esta metodología es utilizada para la predicción de tráfico en los siguientes años en el artículo de Baskar y Hariharan (2020). En el artículo también se explica la forma en la que funcionan las redes neuronales de LSTM, que en resumen cada neurona tiene tres puertas: puerta de entrada, puerta de olvido y puerta de salida lo que representa la memoria de cada neurona y determina que información guardar a medida que va aprendiendo.

### **5.2.5 Verificar**

Para validar los pronósticos se va a utilizar la métrica del Error Porcentual Absoluto Medio o Mean Absolute Percentage Error (MAPE). Con esta métrica se va a evaluar el error porcentual que presentan los pronósticos frente a los valores reales. Con ello, se obtuvo que el método tradicional de Holt–Winters entregó mejores resultados al arrojar un MAPE de 12% y 11% para Rosa Color y Rosa Roja respectivamente. Por otro lado, con los algoritmos de Machine Learning y Deep Learning se obtuvo un MAPE del 13% para Fourier en Rosa Roja y del 6% para LSTM para Rosa Color. Un resumen de los resultados se puede ver en el Anexo 8.

Debido a la corta cantidad de datos para poder realizar un pronóstico más certero, se recomienda no usar por el momento algoritmos de Machine Learning o Deep Learning hasta tener mayor cantidad de datos para poder entrenar los modelos y poder obtener un modelo que pueda entregar un resultado que responda a la pregunta de cuántos tallos va a pedir un cliente de una presentación específica en una semana del año. Por el momento, el uso de metodologías tradicionales es una buena opción para poder tener una visibilidad de la demanda de rosas en Ecuador.

## 7. ASIGNACIÓN DE PRODUCCIÓN

### 7.1 Revisión de literatura

En la búsqueda constante por la mejora de la eficiencia y la toma de decisiones en la gestión de recursos limitados, la programación lineal emerge como una herramienta matemática práctica. Como lo expresó George Dantzig en 1963, "If the system exhibits a structure which can be represented by a mathematical equivalent, called a mathematical model, and if the objective can also be so quantified, then some computational method may be evolved for choosing the best schedule of actions among alternatives. Such use of mathematical models is termed mathematical programming." Esta definición establece el marco conceptual que ha dirigido la aplicación de la programación lineal en la optimización y asignación de recursos a lo largo de las décadas.

Basándose en las definiciones y algoritmos establecidos por Dantzig en su libro "Linear Programming and Extensions", Mahak Bhatia y Anil Rana en su publicación del 2020 sobre el enfoque matemático para optimizar la asignación de cultivos utilizando programación lineal, mencionan el acercamiento matemático utilizando una función multiobjetivo, también conocido como optimización Pareto, este acercamiento es utilizado cuando las soluciones no pueden mejorarse en ninguno de los objetivos sin degradar al menos uno de los otros objetivos. Dado a esta distinción entre una función objetivo y multiobjetivo, Bathia, M y Rana, A recomiendan el uso de una función multiobjetivo si se van a involucrar ingresos en la formulación del problema, ya que el objetivo sería maximizar los ingresos y minimizar los costos asociados.

Como se menciona en el texto de Galindo et al. (2021), las industrias o empresas usan la programación lineal para asignar recursos limitados y tareas de forma óptima. Por ello, los autores proponen un modelo de minimización de costos en donde en la función objetivo toman en cuenta lo siguiente: costo de compra de materia prima, costo de producción y costo

de transporte. En las restricciones, toman en cuenta la cantidad que puede brindar cada proveedor, formulando de esta manera restricciones lineales simples. Dentro del contexto de la empresa, se menciona que la asignación se la realizaba de forma manual y al comparar los resultados finales del modelo utilizando programación lineal, se obtuvo un ahorro del 7.09% en los costos totales. Este es un ejemplo de los beneficios que ofrece utilizar la programación lineal para optimizar los recursos y así lograr minimizar los costos mientras se cumple con la demanda.

En la revisión literaria realizada por Nguyen et al. (2021), se menciona la complejidad e importancia de realizar un modelo de optimización para productos que tienen una vida útil corta, la revisión se enfoca en la optimización de la cadena de suministros de la fruta fresca, sin embargo, se mencionan investigaciones como la de Lowe y Preckel et al. (2004) donde se considera solamente la producción y distribución de cultivos, tomado así un enfoque en la localización de los centros de producción agrícola, con bodegas y plantas de procesamiento.

Adicionalmente, para ampliar el modelo a parámetros más complejos, se lo hace en un mercado donde la planeación de producción es incierta y cambiante, y este escenario es muy similar al mercado de rosas donde la producción reacciona a la demanda a último momento debido a la incertidumbre del mercado. En combinación a esta investigación, Ahumada y Villalobos et al. (2019) demuestran que un acercamiento como la programación lineal y la programación entera mixta son los métodos más aplicables para la cadena de suministros de la fruta fresca, sin embargo, los métodos de programación más complejos como: programación no línea, dinámica, estocástica y heurística pueden ser menos comunes, pero igualmente relevantes en sus resultados.

Volviendo a la revisión literaria de Nguyen et al. (2021), se mencionan las bases utilizadas para la realización del modelo de optimización de la cadena de suministro de la

fruta fresca, las cuales son: encontrar y definir las restricciones y retos que presenta esta cadena de suministros, la necesidad de modelar matemáticamente esta cadena, definir los conceptos comunes y los acercamientos dominantes, las fortalezas y debilidades para los modelos existentes y finalmente las perspectivas futuras del modelo.

## **7.2 Metodología DMAV**

### **7.2.1 Definir**

Para la primera fase, se define inicialmente el proceso de asignación actual dentro de la empresa, se identificó que la asignación de órdenes de producción de flores se realiza a través de un software, donde cada vez que se registra un pedido en el sistema, se asigna automáticamente a cada finca un porcentaje de ese pedido. Este porcentaje de asignación depende de las hectáreas de las fincas y se encuentra en el Anexo 9.

Mientras más capacidad para producir tenga una finca se le asigna un mayor porcentaje de manera proporcional, esta asignación es equitativa cuando todas las fincas tienen disponibilidad de flor en esa semana; por lo tanto, cuando una finca no tiene flor disponible no se le asigna y se reparte la asignación entre las fincas restantes. Esta política se aplica dentro de la empresa para asignar de la manera más justa entre las fincas, sin embargo, no se toman en consideración otros factores claves que afectan los costos de la empresa como: las notas de crédito, nivel de cumplimiento, capacidades de producción y costos de producción, estos factores se los va a detallar en la siguiente fase. Finalmente, existen semanas donde la demanda es mayor a la capacidad total de todas las fincas, en estos casos es donde se compra el faltante en el mercado de Miami.

### **7.2.2 Medir**

Para la siguiente fase, en la empresa se recopiló la información de entrada necesaria para el funcionamiento de los modelos, esta información es del año 2023 hasta la semana 30, se

consideró este rango de tiempo ya que son las primeras semanas del año donde existe una producción mayor en comparación con el resto del año.

Comenzando por el detalle de los factores mencionados en la fase anterior, se tiene el primer set de datos, las notas de crédito presentados en el Anexo 10. Las notas de crédito ocurren cuando un pedido que llega a Miami no cumple con los estándares de calidad del cliente, este porcentaje es obtenido dividiendo las ventas por la cantidad de notas crédito y va variando a lo largo del año dependiendo de cada finca.

Para el siguiente set de datos presentados en el Anexo 11, se tienen los valores del cumplimiento por cada finca y tipo de rosa a lo largo del año, este porcentaje indica que tanto de lo asignado será entregado a tiempo por las fincas, el restante que no se logró producir a tiempo tendrá que ser comprado en el mercado de Miami, este porcentaje es obtenido dividiendo la cantidad entregada por la cantidad solicitada de cada finca.

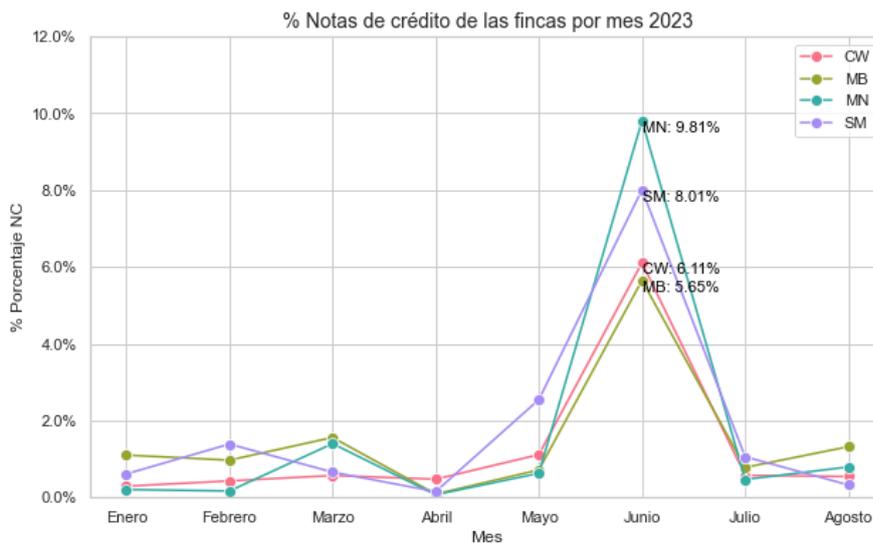
Los costos de producción se encuentran en el Anexo 12, estos costos de producción fueron proporcionados por la empresa, donde se calculan los costos unitarios por metro cuadrado de las hectáreas de las fincas. A continuación, los precios unitarios de comprar en Miami en el Anexo 13, el precio de las rosas en Miami es más caro que producir en cualquiera de las fincas en Ecuador, por lo que se espera con el modelo reducir la cantidad de rosas compradas en el exterior.

Finalmente, se tienen los datos de las capacidades en el Anexo 14, las restricciones de producción dependen del tipo de rosa y la finca, de acuerdo con la información proporcionada por la empresa, se decidió distribuir las hectáreas de las fincas en un 60% para Rosa Color y el restante para Rosa Roja, por lo que estas capacidades se dividen por estos porcentajes de producción.

### 7.2.3 Analizar

Para la fase analizar, se graficó el comportamiento de los datos recopilados en la anterior fase para poder visualizar su comportamiento y analizar las causas. Comenzando por el comportamiento de las notas de crédito a lo largo del año 2023 hasta el mes de Agosto:

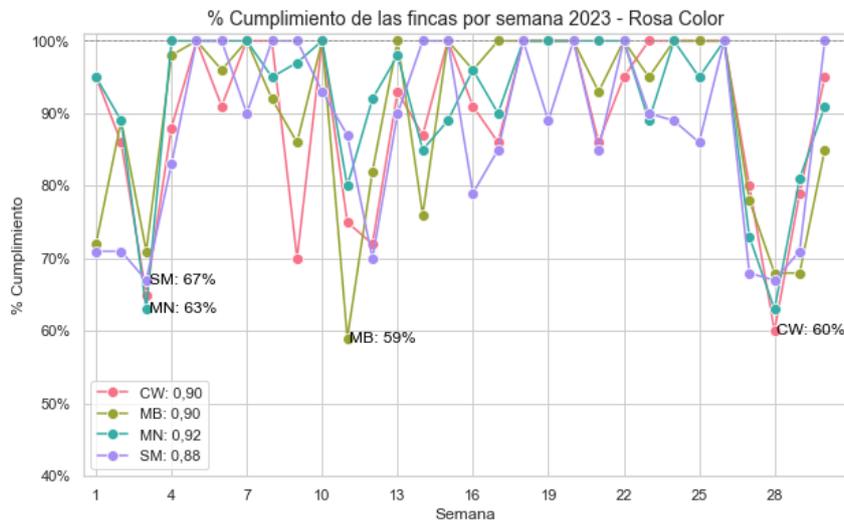
**Gráfico 2:** % Notas de crédito de las fincas por mes del año 2023.



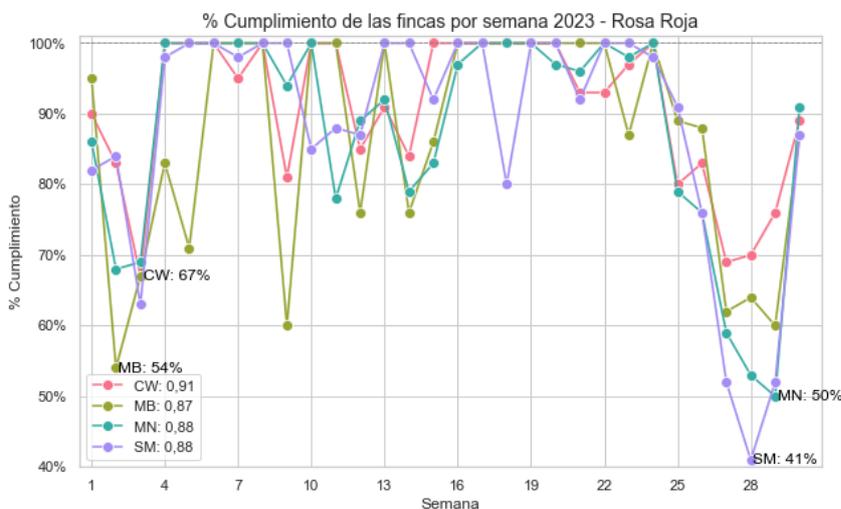
Como se puede observar que existe un pico elevado en el mes de junio, donde todas las fincas siguen este comportamiento, alcanzando valores de hasta un 10% en notas de crédito en el caso de la finca MN, estos valores generan una gran pérdida monetaria para la empresa. La causa de este pico es el aumento de temperatura que llega en el verano, las altas temperaturas afectan el tiempo de vida de las rosas, lo que genera defectos cuando llegan a Miami y necesitan ser devueltas en notas de crédito.

A continuación, el comportamiento del cumplimiento de las fincas hasta la semana 30 del año 2023 de Rosa Color y de la Rosa Roja:

**Gráfico 3:** % Cumplimiento de las fincas por semana del año 2023 de Rosa Color.



**Gráfico 4:** % Cumplimiento de las fincas por semana del año 2023 de Rosa Roja.



Analizando los gráficos de cumplimiento se puede notar tres picos de incumplimiento dentro de las 30 semanas, estos picos están asociados con la demanda del mercado, ya que el pico de la semana 9 a la 11 es por la festividad del día de San Valentín, adicionalmente el otro pico presentado en la semana 28 es por el verano, así como sucedió con las notas de crédito.

A continuación, se presentan los gráficos donde se encuentra la variación de los precios por semana en el año junto con el costo de producción y comprar en Miami de la Rosa Roja y Rosa Color respectivamente:

**Gráfico 5:** % Precio y Costos de Rosa Roja por semana del año 2023.



**Gráfico 6:** % Precio y Costos de Rosa Color por semana del año 2023.



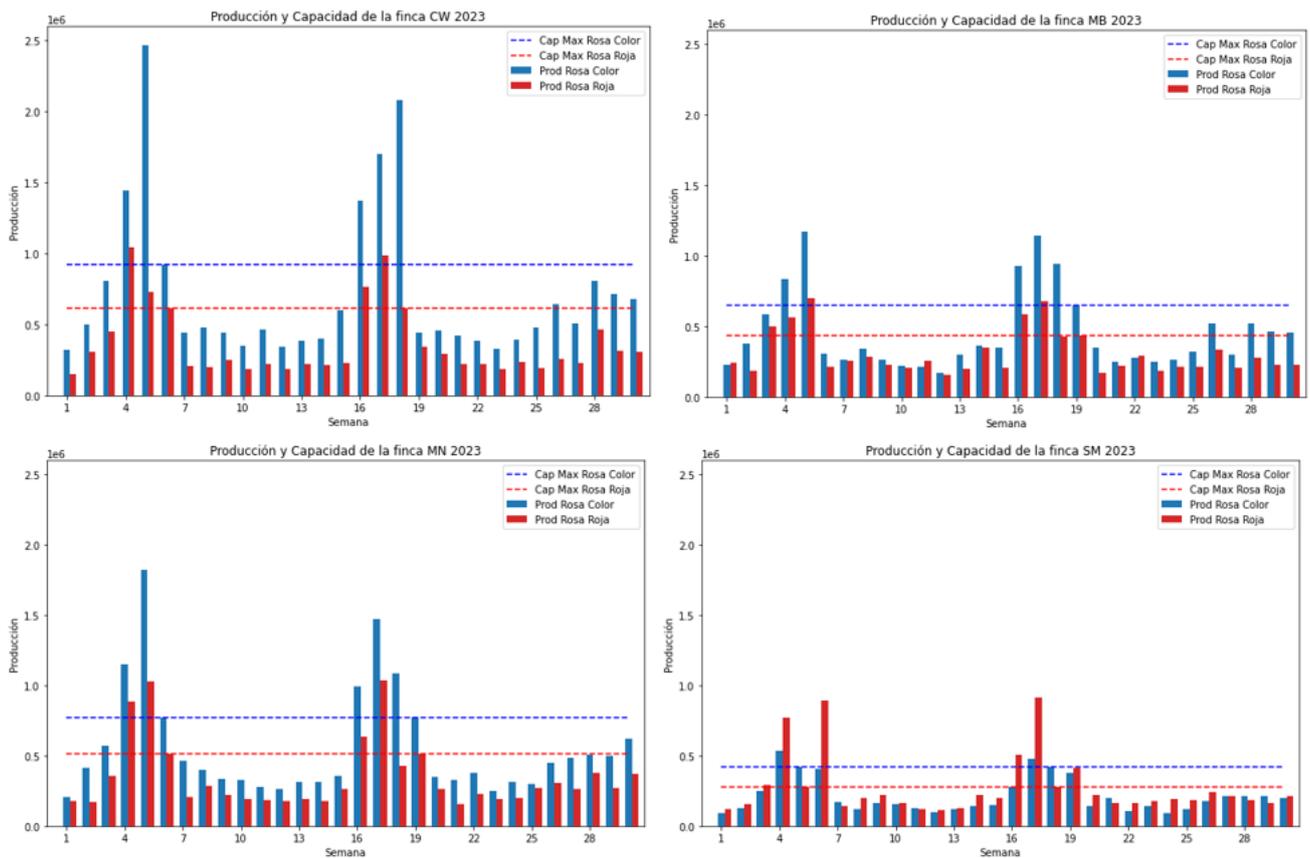
En el Gráfico 5 se presenta un fuerte pico en el precio de venta en las semanas de San Valentín, en este periodo de tiempo es donde se va a obtener la mayor ganancia, por lo contrario, también existen ciertas semanas donde la ganancia es mínima o incluso negativa,

en cambio, cuando las rosas se compran en el mercado de Miami siempre se tiene una pérdida monetaria a excepción de las semanas de San Valentín.

En el Gráfico 6, se observa que Rosa Color tiene un margen de ganancia mínimo, en este tipo de rosa igualmente se presenta un aumento en el precio de venta en las semanas de Valentín sin embargo no logra superar el costo de comprar este tipo de rosa en el mercado de Miami, por lo que para este tipo de rosa el incumplimiento de las fincas penaliza de mayor manera a las ganancias de la empresa.

Finalmente, se presenta la comparación entre las capacidades de las fincas con la asignación realizada:

**Gráfico 7:** Comparación capacidad vs asignación por semana del año 2023.



Como se observa en el Gráfico 7, en las semanas de alta demanda no se logra satisfacer con la producción máxima de las fincas, por lo que se debe tercerizar, los porcentajes de tercerización se encuentran más a detalle en el Anexo 15 para Rosa Roja y en el Anexo 16 para Rosa Color, donde el valor más alto para la Rosa Roja es de 25,47% de la finca SM y para Rosa Color es de 20,53% de la finca CW.

#### **7.2.4 Diseñar**

En la fase de diseñar, se construye la estructura del modelo de asignación basándose en el proceso actual de la empresa establecido en la fase definir, donde también se utiliza como datos de entrada la información recolectada en la fase medir, y tomando en consideración el análisis de los datos de la fase analizar, para lograr incluir estos factores dentro de la estructura de los modelos. En base a las necesidades de la empresa se desarrolló un modelo de asignación de la producción semanal, que está definido de la siguiente manera:

#### **Modelo 1: Optimización de la asignación de la producción semanal**

El propósito de este modelo es minimizar el total de los costos asociados con la producción de la empresa cubriendo la demanda para los dos tipos de rosas. Se basó en los conceptos generales de Briend et al. (2003) sobre la programación lineal y en el artículo “Cost Optimization of Multiunit Construction” (Podolski et al. 2019) para la creación de las restricciones de capacidad. Los parámetros para el modelo se muestran a continuación:

#### ***Parámetros***

$F =$  Conjunto de fincas,      donde  $i = \{CW, MB, MN, SM\}$

$R =$  Conjunto de tipos de rosas,      donde  $k = \{Rosa Color, Rosa Roja\}$

$S =$  Conjunto de número de semanas del año,      donde  $s = \{1,2,3, \dots, 30\}$

$CP_{ik} =$  costo de producir una rosa tipo  $k$  en la finca  $i$

$NS_{is}$  = nivel de cumplimiento de la finca  $i$  en la semana  $s$

$CCE_k$  = costo de comprar en Miami una rosa tipo  $k$

$D_{si}$  = porcentaje de las notas credito por finca  $i$  en la semana  $s$

$Min_{sk}$  = mínimo de producción de rosa tipo  $k$  en la semana  $s$

$CapMax_{sk}$  = capacidad máxima de producción de rosa tipo  $k$  en la semana  $s$

$Demanda_{sk}$  = Demanda de la semana  $s$  de la rosa tipo  $k$

**Variables de decisión:**

$X_{sik}$  = cantidad de tallos de rosa  $k$  asignados a la finca  $i$  en la semana  $s$

$E_{sik}$  = cantidad faltante de tallos de rosa  $k$  asignados a la finca  $i$  en la semana  $s$

$M_{sk}$  = cantidad de tallos de rosa  $k$  tercerizada en la semana  $s$

$CN_{sik}$  = capacidad sobrante en la semana  $s$  en la finca  $i$  para la rosa  $k$

**Función Objetivo:**

$Min Z = 1) \text{ Costos Totales Producción} + 2) \text{ Costos Totales Notas Crédito}$   
 $+ 3) \text{ Costos Totales Incumplimiento} + 4) \text{ Costos Totales Miami}$

***Función Objetivo explicada por términos:***

$1. \sum_s \sum_i \sum_k CP_{ik} * NS_{si} * (X_{sik} + E_{sik})$	<p>Este término se refiere al costo de producir la cantidad asignada en esa semana en las fincas. Se multiplica por el nivel de cumplimiento para tomar en cuenta que hay fincas las cuales a veces no logran cumplir con el 100% del pedido asignado.</p>
$2. \sum_s \sum_i \sum_k PV_{sk} * D_{si} * (X_{sik} + E_{sik})$	<p>Este término se multiplica el costo de venta de la rosa por el porcentaje de notas de crédito que tiene cada finca por la cantidad de rosa asignada. De esta manera se estima la cantidad de dinero que la empresa tendrá que devolver a los clientes por rosas devueltas por no cumplir con el estándar de calidad.</p>
$3. \sum_s \sum_i \sum_k CCE_k * (1 - NS_{si}) * (X_{sik} + E_{sik}) +$	<p>Se multiplica el costo de comprar la rosa en Miami por (1- el nivel de cumplimiento) lo que es traducido al porcentaje de rosas que no logra producir la finca en dicho pedido por la cantidad de rosa asignada. Este término representa lo que se compra en Miami por el incumplimiento de las fincas.</p>
$4. \sum_s \sum_k CCE_k * M_{sk}$	<p>Este término es el costo de tercerizar rosas por la cantidad que se terceriza debido a la falta de capacidad en las fincas.</p>

**Sujeto a las restricciones:**

<p>1. <math>\sum_i X_{sik} + \sum_i E_{(s+1)ik} + M_{sk}</math>  <math>= Demanda_{sk}</math> para todo <math>s</math>  <math>= \{1, \dots, 29\}, k = \{1, 2\}</math></p> <p>2. <math>\sum_i X_{sik} + M_{sk} = Demanda_{sk}</math> para todo <math>s</math>  <math>= \{30\}, k = \{1, 2\}</math></p>	<p>Esta restricción indica que la producción asignada a esa semana, más la producción faltante que va a ser producida la siguiente semana, más la cantidad comprada en Miami tiene que ser igual a la demanda, excepto para la última semana donde no se tiene la producción de la siguiente semana.</p>
<p>3. <math>CN_{sik} + X_{sik} + E_{sik}</math>  <math>= CapMax_{ik}</math> para todo <math>s</math>  <math>= \{1, \dots, 30\}, i = \{1, \dots, 5\}, k</math>  <math>= \{1, 2\}</math></p>	<p>Esta restricción indica que no se puede sobrepasar la capacidad máxima de producción de la semana, y la capacidad restante es lo que sobra cuando lo producido no sobrepasa la capacidad máxima en esa semana.</p>
<p>4. <math>X_{sik} + E_{sik} \geq Min_{ik}</math> para todo <math>s</math>  <math>= \{1, \dots, 30\}, i = \{1, \dots, 5\}, k</math>  <math>= \{1, 2\}</math></p>	<p>La cantidad producida en la semana tiene que ser mayor o igual a los mínimos de producción requeridos.</p>
<p>5. <math>X_{sik}, E_{sik}, M_{sk} \in N</math></p>	<p>Las variables de decisión necesitan ser números enteros no negativos.</p>

El modelo 1 ofrece una vista general de la producción consolidada por semana. Sin embargo, el proceso real de la empresa funciona de la siguiente manera: la asignación de ordenes actualmente se la hace en un software el cual se asigna por cada orden de pedido de cada cliente. Debido a que el modelo 1 tiene como datos de entrada la demanda consolidada por semana sin tener en cuenta los clientes no se lo podría aplicar al proceso real de la empresa. Es debido a eso que se planteó un segundo modelo de asignación donde se asigna la producción a las fincas por órdenes de pedido, con lo cual se puede realizar un rastreo de la información, a continuación, se muestra el diseño del segundo modelo:

### **Modelo 2: Optimización de asignación de la producción por órdenes de compra**

Para el modelo 2 se realizará la asignación por órdenes de compra, así se visualizan los resultados de manera más detallada en comparación con el modelo 1. Para lo cual se basó en las definiciones establecidas por Bathia et al. (2020) sobre las funciones multiobjetivo, de esta manera se introdujo los ingresos en el modelo y también, se utilizaron los conceptos del artículo “Introduction de max-linear programming” (Butkovimc et al., 2008) donde se utiliza la función Max para obtener el máximo de un grupo de variables. La estructura del modelo se muestra a continuación, comenzando por los parámetros adicionales al Modelo 1:

#### ***Parámetros adicionales***

$O =$  Conjunto de órdenes de compra      donde  $j = \{1,2,3, \dots, 30000\}$

$Demanda_{jk} =$  Demanda de la orden de compra  $j$  de la rosa tipo  $k$

#### ***Variables de decisión:***

$X_{jik} =$  cantidad de la orden de compra  $j$  asignada a la finca  $i$  del tipo de rosa  $k$

$E_{jik} =$  cantidad faltante de la orden de compra  $j$  asignada a la finca  $i$  de rosa  $k$

$M_{jsk} =$  cantidad de tallos de rosa tercerizada de la orden  $j$  en la semana  $s$  del tipo  $k$

$CN_{sik}$  = capacidad actualizada en la semana  $s$  en la finca  $i$  para el tipo de rosa  $k$ .

***Función Objetivo:***

$Max Z = 1) Ingresos - [ 2) Costos Totales Producción + 3) Costos Totales Incumplimiento$   
 $+ 4) Costos Totales Notas Crédito + 5) Costos Totales Miami]$

***Función Objetivo explicada por términos:***

$1. \sum_{s=1}^S \sum_{j=1}^O \sum_{i=1}^F \sum_{k=1}^R (X_{jsik} + E_{jsik} + M_{jsk})$ <p style="text-align: center;">* <math>PV_{ks}</math></p>	<p>Este término indica los ingresos de la empresa, tomando en cuenta la producción en Ecuador como lo vendido que se compra en Miami.</p>
$2. \sum_{s=1}^S \sum_{j=1}^O \sum_{i=1}^F \sum_{k=1}^R X_{jsik} * NS_{is} * CP_{ik}$ $+ \sum_{s=1}^S \sum_{j=1}^O \sum_{i=1}^F \sum_{k=1}^R E_{jsik}$ <p style="text-align: center;">* <math>NS_{i(s+1)} * CP_{ik}</math></p>	<p>Este término indica el costo de producir lo asignado en Ecuador donde solo se considera lo que, si alcanzó la finca a producir a tiempo, lo mismo aplica para el faltante que se produce la siguiente semana, por lo que el índice se le suma +1.</p>
$3. \sum_{s=1}^S \sum_{j=1}^O \sum_{i=1}^F \sum_{k=1}^R X_{jsik} * (1 - NS_{is})$ <p style="text-align: center;">* <math>CCE_k</math></p> $+ \sum_{s=1}^S \sum_{j=1}^O \sum_{i=1}^F \sum_{k=1}^R E_{jsik}$ <p style="text-align: center;">* <math>(1 - NS_{i(s+1)}) * CCE_k</math></p>	<p>Este término representa el costo de incumplimiento, es decir lo que las fincas no lograron cumplir a tiempo y por lo tanto se tiene que comprar en Miami a último momento, para el faltante se le suma +1 al índice porque se lo produce la siguiente semana.</p>
$4. \sum_{s=1}^S \sum_{j=1}^O \sum_{i=1}^F \sum_{k=1}^R X_{jsik} * D_{is} * PV_{ks}$ $+ \sum_{s=1}^S \sum_{j=1}^O \sum_{i=1}^F \sum_{k=1}^R E_{jsik} * D_{i(s+1)}$ <p style="text-align: center;">* <math>PV_{ks}</math></p>	<p>Este término representa las devoluciones en notas crédito de lo entregado a los clientes, para el faltante igualmente se suma +1 en el índice de notas crédito, pero se mantiene el índice en el precio porque se vende al mismo precio de la factura.</p>
$5. \sum_{s=1}^S \sum_{j=1}^O \sum_{k=1}^R CCE_k * M_{jsk}$	<p>Este último término representa los costos de comprar en Miami el faltante debido a la capacidad de las fincas.</p>

**Sujeto a las restricciones:**

$1. \sum_{j=1}^O \sum_{i=1}^F (E_{jsik} + X_{ijk}) + \sum_{j=1}^O M_{jsk}$ $= \sum_{j=1}^O Demanda_{jsk} \text{ para todo } s$ $= \{1,2, \dots, 29\}, k = \{1,2\}$ $2. \sum_{j=1}^O \sum_{i=1}^F X_{ijk} + \sum_{j=1}^O M_{jsk} = \sum_{j=1}^O Demanda_{jsk} \text{ para todo } s$ $= \{30\}, k = \{1,2\}$	<p>Estas restricciones indican que la producción tiene que satisfacer la demanda de cada orden de compra, la segunda restricción indica que para la última semana se tiene que satisfacer solo con la producción de 1 semana y la compra en Miami.</p>
$3. e_{sk} = \max \left( \sum_{j=1}^O Demanda_{jsk} - \sum_{i=1}^F CapMax_{ik}, 0 \right) \text{ para todo } s$ $= \{1,2, \dots, 30\}, k = \{1,2\}$ $4. \sum_{j=1}^O \sum_{i=1}^F E_{jsik} = e_{sk} - \sum_{j=1}^O M_{jsk} \text{ para todo } s$ $= \{30\}, k = \{1,2\}$	<p>Estas restricciones indican que existe faltante cuando la demanda es mayor que la capacidad de esa semana, la segunda restricción resta lo que se va a comprar en Miami por lo tanto la variable E es igual a lo que se va a producir la siguiente semana para satisfacer la demanda.</p>
$5. \sum_{j=1}^O X_{jsk} \geq Min_{ik} \text{ para todo } s = \{30\}, i$ $= \{1, \dots, 5\}, k = \{1,2\}$	<p>Esta restricción indica que la producción semanal tiene que ser mayor a los mínimos de producción.</p>
$6. CN_{sik} = CapMax_{ik} - \sum_{j=1}^O E_{jsk} \text{ para todo } s = \{30\}, i$ $= \{1, \dots, 5\}, k = \{1,2\}$	<p>Esta restricción indica que la nueva capacidad de la semana es la original menos el exceso.</p>

### 7.2.5 Verificar

Para la última etapa de la metodología se va a verificar y comparar los resultados, primero se presenta la comparación de asignaciones entre la asignación actual y la de los modelos utilizando programación lineal:

**Tabla 2:** Comparación resultados cantidad asignada a cada finca 2023.

	<b>CW</b>	<b>MB</b>	<b>MN</b>	<b>SM</b>	<b>Miami</b>
Actual	27,033,839	20,273,411	23,067,693	12,423,689	14,608,335
Modelo 1	22,916,948	23,036,280	24,273,356	12,349,183	14,831,198
Modelo 2	28,223,262	23,343,912	24,808,377	13,666,942	7,364,474

Como se puede notar el cambio significativo es con la cantidad tercerizada en Miami, bajando para el modelo 2 aproximadamente 7 millones de rosas lo cual influye en la reducción de costos. Finalmente, para observar esta asignación en valor monetario se tiene la siguiente información:

**Tabla 3:** Comparación costos asociados con la producción 2023 (Modelo 1).

	<b>Costo Producción</b>	<b>Costo Incumplimiento</b>	<b>Costo Notas Crédito</b>	<b>Costo Miami</b>	<b>Costo Total</b>
Actual	14,662,178	2,570,422	284,086	4,492,369	22,009,057
Modelo 1	16,232,376	2,036,861	142,671	4,564,456	21,846,517

**Tabla 4:** Comparación ganancias en la producción 2023 (Modelo 2).

	<b>Costo Producción</b>	<b>Costo Incumplimiento</b>	<b>Costo Notas Crédito</b>	<b>Costo Miami</b>	<b>Ingresos</b>	<b>Ganancia</b>
Actual	14,662,178	2,570,422	284,086	4,492,369	27,278,225	5,269,168
Modelo 2	16,290,120	2,223,362	284,861	2,264,615	27,278,225	6,215,265

En la tabla 3, se muestra que el modelo 1 presentó resultados favorables en comparación con el costo total de la asignación actual del 2023, se logró reducir principalmente los costos de producción y se generó un ahorro total de \$ 162,540 dólares.

En la tabla 4, se presenta la misma comparación, pero incluyendo los ingresos y la ganancia bruta, con los resultados del modelo 2 se puede observar que el mayor ahorro es generado en los costos Miami ya que comparando igualmente la información en la tabla 2 se tiene que se asigna mucho menos a Miami por lo tanto se obtiene un incremento en la ganancia bruta de \$946,096 dólares, concluyendo que ambos modelos presentan resultados favorables comparando con la asignación actual de la empresa.

## 8. CONCLUSIONES Y RECOMENDACIONES

Durante esta investigación se ha estudiado el negocio floricultor de una empresa ubicada en Ecuador con 4 fincas productoras de flores con enfoque a las rosas de colores y rojas. Este estudio se ha enfocado en ambas familias de rosas ya que estas componen en el 80% de todas las ventas de la empresa en Ecuador. Solamente en el año 2022 la empresa desechó 7 millones de tallos lo cual representa \$1.5 millones de dólares en pérdidas de potenciales ventas. Este desecho se produce debido a factores como son las variaciones de temperatura, tiempo de vida corto y falta de un pronóstico adecuado de la demanda y de una metodología de asignación de pedidos inadecuada. Sin embargo, se ha aplacado el problema del desecho de flor mediante dos frentes, pronosticar la demanda y optimizar la asignación de los pedidos.

En ambas soluciones se tiene el objetivo de presentar a la empresa herramientas para reducir el impacto económico de dichos factores que causan el desperdicio de flor.

La demanda del negocio floricultor es estacional, siendo las mejores temporadas el Día de la Madre y San Valentín. El resto del año la empresa, sobre todo en verano, incurre en desperdicios de flor debido a esta demanda estacional y variable. La empresa debería tener un pronóstico adecuado del comportamiento de la demanda para así tomar mejores decisiones de producción y reducir el desecho de la flor por falta de mercado. Es por esto que se ha comparado modelos de predicción tradicionales frente a modelos de Machine Learning. En el frente de los métodos tradicionales, Holt-Winters ha dado un mejor resultado con un MAPE del 12% para predecir la demanda de Rosa Color y 11% para predicción de demanda de Rosa Roja.

Por otro lado, Machine Learning se ha determinado que los modelos de Fourier tienen un mejor desempeño para predecir la demanda de la Rosa Roja con un MAPE del 13% y LSTM tiene un 6% de MAPE para predecir la demanda de Rosa Color. Sin embargo, debido a la falta de datos históricos que tiene la empresa se recomienda el uso de los métodos tradicionales frente a Machine Learning. Una vez que se tiene una visión de la demanda futura es necesario planificar correctamente la asignación de las órdenes para así maximizar los costos y minimizar los desechos de flor por temas de calidad.

Para la segunda problemática se sabe que cada una de las fincas de la empresa tiene un diferente costo de producción, calidad de flor, capacidades de producción y nivel de cumplimiento. Actualmente el modelo de asignación de la empresa asigna sus pedidos de acuerdo con la cantidad de flor plantada que tiene cada finca. No se tiene en cuenta los parámetros anteriormente mencionados. Las flores que no cumplen con la calidad del

mercado internacional se tienen que desechar. Es por lo que este es un factor importante por tomar en cuenta al momento de asignar un pedido.

Para minimizar el costo operativo, maximizar la ganancia, la satisfacción del cliente y la calidad de la flor, se han creado dos problemas de programación lineal donde el modelo uno minimiza el costo operativo usando de input un consolidado semanal de las ordenes de clientes. Este modelo ha logrado un ahorro potencial en el costo operativo de \$162,540. Por otro lado, el modelo dos usa de input cada orden de los clientes. En este modelo se toma en cuenta el precio de venta para así tener maximizar la ganancia obtenida. Dicho modelo ha logrado incrementar la ganancia en \$940,096. Estas herramientas matemáticas son de suma importancia para tener una visión adecuada del negocio, minimizar las pérdidas y maximizar las ganancias.

De esta manera se ha proporcionado a la empresa varias herramientas para que así puedan tener una visión a futuro de cómo se va a comportar la demanda de flor y así logren planear de mejor manera la producción durante el año. Por otro lado, se proporcionó una nueva metodología de asignación para que se logre distribuir la demanda entre las diferentes fincas de manera que se maximicen las ganancias y calidad de la flor entregada al cliente final.

## **9. LECCIONES APRENDIDAS Y SIGUIENTES PASOS**

Lean Six Sigma es una metodología enfocada a la mejora continua de los procesos en cualquier tipo y escala de negocio. Es por lo que se ha optado por la metodología DMADV donde se ha aprendido que este proceso de mejora continua es estandarizado hacia el éxito del proyecto. En las empresas grandes, es habitual que los empleados y altos mandos no tengan claro el proceso detallado que existe para que el cliente disfrute del producto final. Para cualquier proyecto de mejora es importante entrevistar desde los operarios hasta los gerentes para saber las dolencias que existen en toda la cadena de procesos. Es en dicho

detalle de los procesos donde se encuentran las posibles fallas, errores y espacios a la mejora continua. Si es que la empresa no tiene un manual de procesos detallado, es de suma importancia crearlo.

Otro error de muchos empleados recién llegados y de antigüedad, es que no cuestionan el porqué de dichos procesos. Muchas veces los empleados llevan realizando una tarea de cierta manera por años sin saber que existen otras maneras más efectivas para realizarla. Es por eso, que siempre se tiene que cuestionar los procesos y usar herramientas como diagramas de causas y efectos y la herramienta de los “cinco porqués” para encontrar los problemas y atacarlos. Esa fue la filosofía que se llevó a cabo para encontrar el problema de la empresa y resolverlo.

Para definir el problema hay que analizarlo en todos los frentes posibles y verificar la factibilidad y el alcance que tendrá el proyecto. Es mucho más beneficioso darse cuenta de que un proyecto no es factible en la fase de planeación y definición del problema, que haber gastado recursos y al finalizar las fases de mejora continua darse cuenta de que el problema o sus causas no eran las correctas. Por otro lado, uno de los mayores retos en los proyectos de mejora continua es la medición de los datos. Una ventaja de realizar proyectos en empresas grandes y establecidas es que muchas veces tienen una base de datos extensa. Sin embargo, siempre hay que verificar como se están midiendo dichos datos y ver si estos en verdad son los que afectan a mi problema. Si no se lleva a cabo esa tarea, es posible que se tengan que incurrir en reprocesos durante las diferentes fases de mejora continua.

Por otro lado, una vez culminado con la fase de la medición de datos, hay que procurar diseñar una solución que sea compatible con la empresa y sus trabajadores. Por ejemplo, en este proyecto se ha diseñado el modelo número 2 de asignación de pedidos, el cual es compatible con el sistema actual de la empresa. En este caso si se cambia de sistema,

los costos serían más altos que los de diseñar una solución compatible con la empresa y sus recursos actuales.

El siguiente paso en la trayectoria de este proyecto, es presentarlo a los gerentes de la empresa. Con los datos de ahorros y ganancias obtenidas durante este proyecto, se espera que los altos mandos de la empresa estén interesados a disrumpir los procesos y políticas actuales de la empresa. Así, empezar con planes piloto para implementar estas nuevas herramientas aprobadas por el gremio ingenieril y obtener la ganancia esperada.

## 10. REFERENCIAS

- Ahumada, O.; Villalobos, J.R. Application of planning models in the agri-food supply chain: A review. *Eur. J. Oper. Res.* 2009, 196, 1–20.
- Baskar, P. K., & Hariharan, K. (2020). Multivariate time series traffic forecast with long short term memory based deep learning model. *2020 International Conference on Power, Instrumentation, Control and Computing (PICC)*.  
<https://doi.org/10.1109/picc51425.2020.9362455>
- Bharti, Redhu, P., & Kumar, K. (2023). Short-term traffic flow prediction based on optimized Deep Learning neural network: PSO-BI-LSTM. *Physica A: Statistical Mechanics and its Applications*, 625, 129001. <https://doi.org/10.1016/j.physa.2023.129001>
- Bhatia, M., & Rana, A. (2020). A mathematical approach to optimize crop allocation—A linear programming model. *Int. J. Des. Nat. Ecodynamics*, 15(2), 245-252.
- Chen, Q., Li, J., Yang, H., & Qian, J. (2023). A dynamic shelf-life prediction method considering actual uncertainty: application to fresh fruits in long-term cold storage. *Journal of Food Engineering*, 349, 111471.  
<https://doi.org/10.1016/j.jfoodeng.2023.111471>
- Conefrey, M. (2015, Abril 11). Ecuador's growth story. *Financial Times*  
<https://www.proquest.com/newspapers/ecuadors-growth-story/docview/1680025445/se-2>
- d'Ambrosio, C., Martello, S., & Monaci, M. (2020). Lower and upper bounds for the non-linear generalized assignment problem. *Computers & Operations Research*, 120, 104933. <https://doi.org/10.1016/j.cor.2020.104933>
- Danbatta, S. J., & Varol, A. (2021). Modeling and Forecasting of Tourism Time Series Data using ANN-Fourier Series Model and Monte Carlo Simulation. *IEEE*.  
<https://doi.org/10.1109/isdfs52919.2021.9486325>

- Dantzig, G. (1963). *Linear programming and extensions*. Princeton university press.
- Galindo, A. M. O., Dadios, E. P., Billones, R. K. C., & Valenzuela, I. C. (2021). Cost optimization for the allocation, production, and distribution of a plastic manufacturing company using integer linear programming. *2021 IEEE 13th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment, and Management (HNICEM)*.  
<https://doi.org/10.1109/hnicem54116.2021.9731804>
- Guaita-Pradas, I., Mañay, L. O. R., & Marques-Pérez, I. (2023). Competitiveness of Ecuador's flower industry in the global market in the period 2016–2020. *Sustainability*, 15(7), 5821. <https://doi.org/10.3390/su15075821>
- Guo, S., Li, J., & Ning, Z. (2020). Graphical Representation of Fourier Series from Fourier Transformation. *IEEE*, <https://ieeexplore.ieee.org/document/9182503>.  
<https://doi.org/10.1109/icaica50127.2020.9182503>
- Hair, C. (2019). Roses Along the Equator: Situating Ecuador and Colombia Within the Global Cut-Flower Market. *Southern Quarterly*, 57(1), 50-67,115.  
<https://www.proquest.com/scholarly-journals/roses-along-equator-situating-ecuador-colombia/docview/2553031533/se-2>
- Haselbeck, F., Killinger, J., Menrad, K., Hannus, T., & Grimm, D. G. (2022). Machine learning outperforms classical forecasting on horticultural sales predictions. *Machine Learning with Applications*, 7, 100239. <https://doi.org/10.1016/j.mlwa.2021.100239>
- Lowe, T.J.; Preckel, P.V. Decision technologies for agribusiness problems: A brief review of selected literature and a call for research. *Manuf. Serv. Oper. Manag.* 2004, 6, 201–208.
- Montoya, R. A. G., & Rendón, S. B. (2012). Seis Sigma: un enfoque teórico y aplicado en el ámbito empresarial basándose en información científica. En *Corporación*

*Universitaria Lasallista eBooks.*

<http://repository.unilasallista.edu.co/dspace/bitstream/10567/515/1/13.%2020223-242.pdf>

Nahmias, S. (2007). Análisis de la producción y las operaciones.

Nguyen, T.-D.; Nguyen-Quang, T.; Venkatadri, U.; Diallo, C.; Adams, M. Mathematical Programming Models for Fresh Fruit Supply Chain Optimization: A Review of the Literature and Emerging Trends. *AgriEngineering* 2021, 3, 519–541

Punia, S., & Shankar, S. (2022). Predictive Analytics for Demand Forecasting: a deep learning-based decision support system. *Knowledge Based Systems*, 258, 109956. <https://doi.org/10.1016/j.knosys.2022.109956>

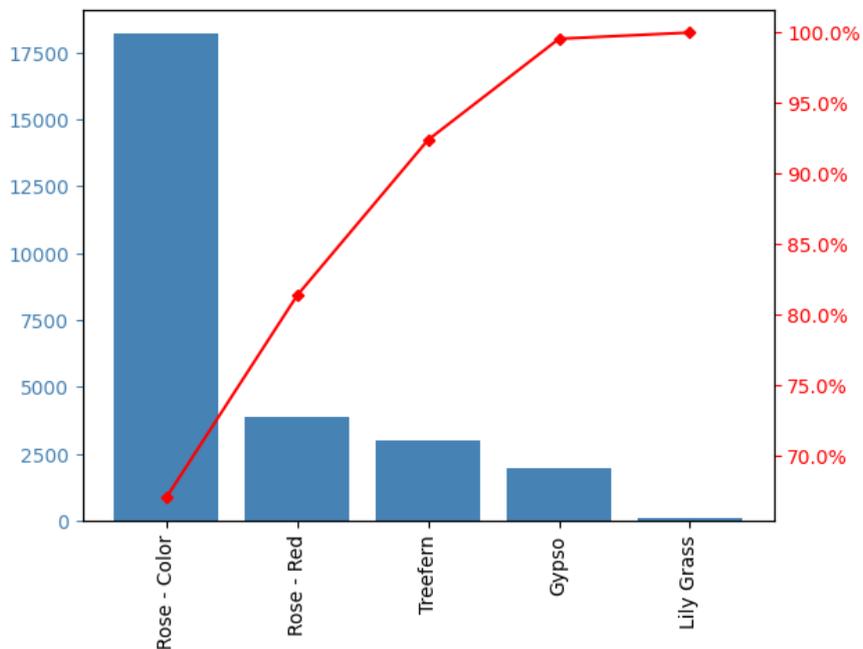
Rabe, M.; Bilan, Y.; Widera, K.; Vasa, L. Application of the Linear Programming Method in the Construction of a Mathematical Model of Optimization Distributed Energy. *Energies* 2022, 15, 1872. <https://doi.org/10.3390/en15051872>

UN/ECE STANDARD H-1 concerning the marketing and commercial quality control of CUT FLOWERS moving in international trade between and to UN/ECE member countries. (1995). *United Nations Economic Commission for Europe*, [https://unece.org/fileadmin/DAM/trade/agr/standard/flowers/flower\\_e/h1flower.pdf](https://unece.org/fileadmin/DAM/trade/agr/standard/flowers/flower_e/h1flower.pdf).

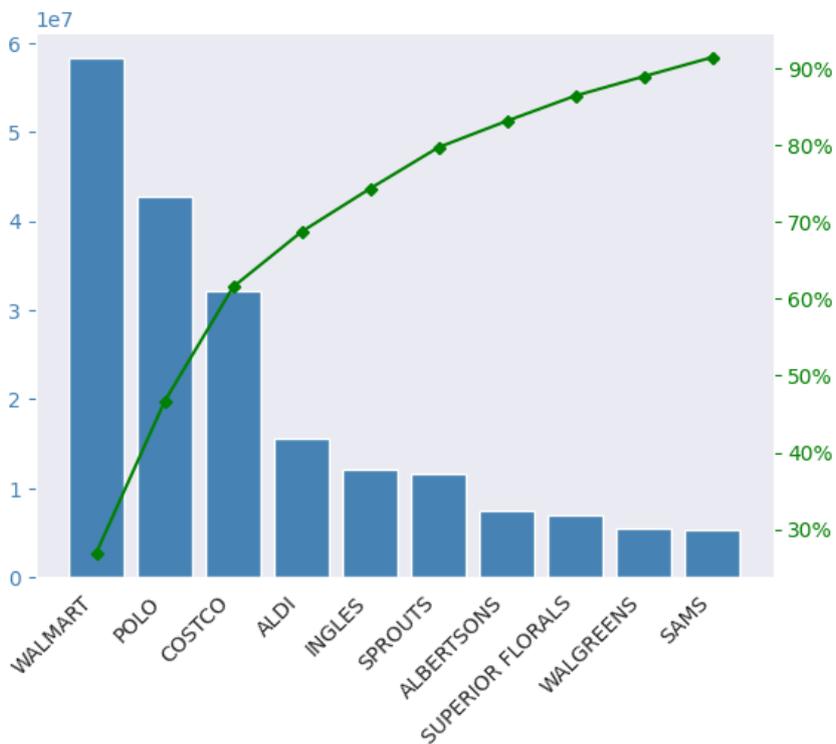
Hillier, F. S., & Lieberman, G. J. (1968). Introduction to Operations research. *Technometrics*, 10(2), 410. <https://doi.org/10.2307/1267061>

### 11. ANEXOS

**Anexo 1:** Pareto de producción por tipo de flor



**Anexo 2:** Pareto de demanda por cliente



**Anexo 3:** Modelo del problema de asignación

$$\text{Minizar } Z = \sum_{i=1}^n \sum_{j=1}^n c_{ij} x_{ij}$$

Sujeto a las restricciones

$$\sum_{j=1}^n x_{ij} = 1 \text{ para cada } i = \{1, \dots, n\}$$

$$\sum_{i=1}^n x_{ij} = 1 \text{ para cada } j = \{1, \dots, n\}$$

$$x_{ij} \geq 0 \text{ para toda } i \text{ y } j$$

*( $x_{ij}$  es binaria, para toda  $i$  y  $j$ )*

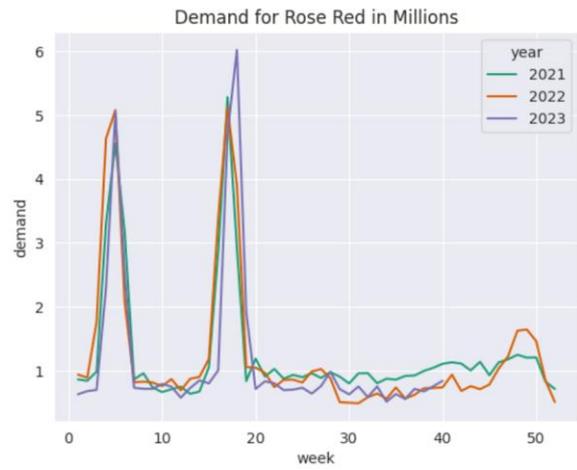
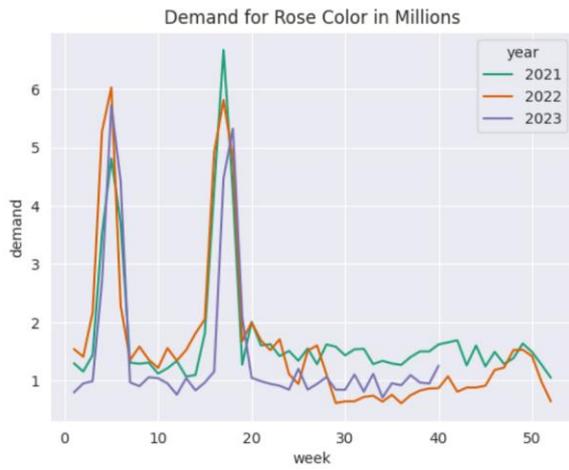
Donde  $x_{ij}$  es la variable de decisión que representa que se va a asignar al operador/recurso  $i$  la tarea  $j$ . Por otro lado,  $c_{ij}$  representa el costo de que el operador/recurso  $i$  realice la tarea  $j$ . Por lo tanto, la función objetivo  $Z$  lo que intenta hacer es minimizar el costo total de asignar una tarea a un operador/recurso.

La primera restricción se asegura que cada recurso asignado ejecute exactamente 1 sola tarea, mientras que la segunda restricción se asegura que cada tarea se ejecute por 1 solo recurso (Hillier & Lieberman, 1968).

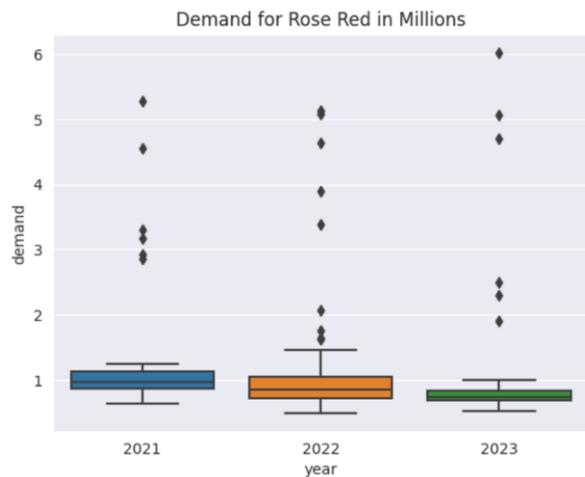
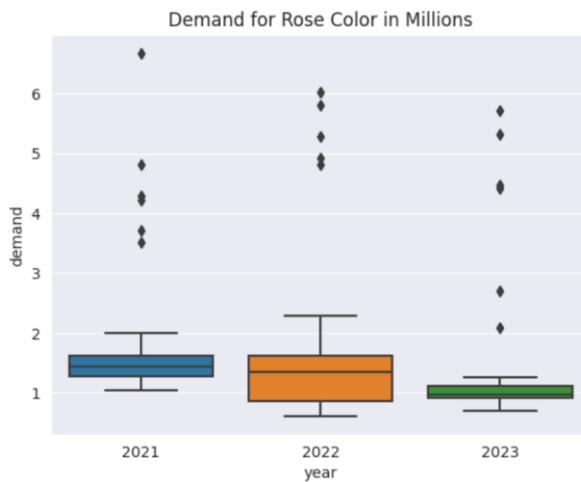
**Anexo 4:** Tabla con los campos de los datos obtenidos para predicción de demanda

<b>Campo</b>	<b>Descripción</b>
YYYYWW	Año y semana en la que se realizó la orden de compra
customeraccount	Número de cuenta de cada cliente
customername	Nombre de la empresa y de la sede que compra la flor
customerallocation	Nombre de la empresa cliente
customerallocation2	Nombre de la empresa con el nombre del estado que compra la flor
productcode	Código del producto que se vende
productgroup	Nombre de la presentación que se vende el producto. Ejemplo: Bouquet o flor individual
productcategory	Categoría a la que pertenece la presentación de cada producto
producttype	Tipo de producto que se vende
productgrade	Cuántas flores o la altura que va en cada producto entregado
flower	Tipo de flor que se vende
color	Color de la flor
grade	Clasificación de la flor
variety	Nombre científico a la variedad que pertenece cada flor
tallosdespachados	Tallos/productos entregados que fueron solicitados
tallosnominal	Tallos/productos solicitados por el cliente

### Anexo 5: Comportamiento de la demanda de Rosa Roja y Rosa Color por semana



### Anexo 6: Boxplot de los datos de demanda por año



**Anexo 7:** tabla con los resultados de la limpieza y agrupación de datos para la demanda.

Se muestran los 5 primeros registros para Rosa Color.

tallosnominal	
date	
2021-01-04	1293951.0
2021-01-11	1152544.0
2021-01-18	1436548.0
2021-01-25	3509859.0
2021-02-01	4808533.0

**Anexo 8:** Tabla con resumen de los MAPE obtenidos para cada metodología y rosa.

	Metodología	Rosa Color	Rosa Roja
Métodos Tradicionales	ARIMA	534%	915%
	SARIMA	31%	16%
	Holt-Winters	12%	11%
Machine Learning Deep Learning	Series de Fourier	26%	13%
	LSTM	6%	60%

**Anexo 9:** Cantidad de hectáreas por cada finca en Ecuador.

<b>Finca</b>	<b>Hectáreas</b>	<b>Porcentaje</b>
SM	25.5	21.22%
MN	30.5	25.37%
CW	37.9	31.53%
MB	26.3	21.88%
<b>Total</b>	120.2	100%

**Anexo 10:** Porcentaje de notas crédito de las fincas por mes en el año 2023

<b>Mes</b>	<b>CW</b>	<b>MB</b>	<b>MN</b>	<b>SM</b>
1	0.29%	1.10%	0.21%	0.61%
2	0.43%	0.97%	0.17%	1.39%
3	0.57%	1.56%	1.40%	0.66%
4	0.47%	0.09%	0.07%	0.15%
5	1.11%	0.72%	0.63%	2.54%
6	6.11%	5.65%	9.81%	8.01%
7	0.58%	0.78%	0.47%	1.06%
8	0.54%	1.32%	0.79%	0.33%

**Anexo 11:** Porcentaje de cumplimiento de las fincas por semana en el año 2023

<b>Rosa:</b>	Rosa Color				Rosa Roja			
<b>Semana</b>	<b>CW</b>	<b>MB</b>	<b>MN</b>	<b>SM</b>	<b>CW</b>	<b>MB</b>	<b>MN</b>	<b>SM</b>
1	0.95	0.72	0.95	0.71	0.9	0.95	0.86	0.82
2	0.86	0.89	0.89	0.71	0.83	0.54	0.68	0.84
3	0.65	0.71	0.63	0.67	0.67	0.67	0.69	0.63
4	0.88	0.98	1	0.83	1	0.83	1	0.98
5	1	1	1	1	1	0.71	1	1
6	0.91	0.96	1	1	1	1	1	1
7	1	1	1	0.9	0.95	1	1	0.98
8	1	0.92	0.95	1	1	1	1	1
9	0.7	0.86	0.97	1	0.81	0.6	0.94	1
10	1	1	1	0.93	1	1	1	0.85
11	0.75	0.59	0.8	0.87	1	1	0.78	0.88
12	0.72	0.82	0.92	0.7	0.85	0.76	0.89	0.87
13	0.93	1	0.98	0.9	0.91	1	0.92	1
14	0.87	0.76	0.85	1	0.84	0.76	0.79	1
15	1	1	0.89	1	1	0.86	0.83	0.92
16	0.91	0.96	0.96	0.79	1	1	0.97	1
17	0.86	1	0.9	0.85	1	1	1	1
18	1	1	1	1	1	1	1	0.8
19	1	1	1	0.89	1	1	1	1
20	1	1	1	1	1	1	0.97	1
21	0.86	0.93	1	0.85	0.93	1	0.96	0.92
22	0.95	1	1	1	0.93	1	1	1
23	1	0.95	0.89	0.9	0.97	0.87	0.98	1
24	1	1	1	0.89	1	1	1	0.98
25	1	1	0.95	0.86	0.8	0.89	0.79	0.91
26	1	1	1	1	0.83	0.88	0.76	0.76
27	0.8	0.78	0.73	0.68	0.69	0.62	0.59	0.52
28	0.6	0.68	0.63	0.67	0.7	0.64	0.53	0.41
29	0.79	0.68	0.81	0.71	0.76	0.6	0.5	0.52
30	0.95	0.85	0.91	1	0.89	0.87	0.91	0.87

**Anexo 12:** Tabla costos de producción de las rosas en las fincas en dólares.

<b>Tipo</b>	<b>CW</b>	<b>MB</b>	<b>MN</b>	<b>SM</b>
Rosa - Color	0.197	0.193	0.194	0.191
Rosa - Roja	0.203	0.200	0.196	0.204

**Anexo 13:** Tabla precio de las rosas en el mercado de Miami en dólares.

<b>Tipo Flor</b>	<b>Precio</b>
Rosa – Color	0.387
Rosa - Roja	0.402

**Anexo 14:** Tabla capacidad máxima y mínima de producción de tallos por día de las fincas.

<b>Restricciones de producción</b>	<b>SM</b>	<b>MB</b>	<b>CW</b>	<b>MN</b>
Capacidad Max Tallos/Día	99,987	154,332	218,927	182,891
Mínimo Diario	27,000	26,667	31,500	29,167

**Anexo 15:** Tabla producción y capacidad de Rosa Roja con porcentaje de tercerización 2023.

<b>Rosa Roja</b>	<b>CW</b>	<b>MB</b>	<b>MN</b>	<b>SM</b>
Capacidad Max	612,995	432,129	512,094	279,963
Total Producción	10,792,462	9,241,540	10,514,501	8,250,267
Total Miami	1,061,811	797,589	1,533,054	2,101,014
% Tercerizado	9.84%	8.63%	14.58%	25.47%

**Anexo 16:** Tabla producción y capacidad de Rosa Color con porcentaje de tercerización  
2023.

<b>Rosa Color</b>	<b>CW</b>	<b>MB</b>	<b>MN</b>	<b>SM</b>
Capacidad Max	919,493	648,194	768,142	419,945
Total				
Producción	21,773,063	13,612,032	16,773,625	6,449,477
Total Miami	4,469,875	1,782,572	2,687,379	175,041
% Tercerizado	20.53%	13.10%	16.02%	2.71%