

Instituto Tecnológico y de Estudios Superiores de Occidente

Reconocimiento de validez oficial de estudios de nivel superior según acuerdo secretarial 15018, publicado en el Diario Oficial de la Federación del 29 de noviembre de 1976.

Departamento de Economía, Administración y
Mercadología
**Especialidad en Gestión de la Cadena de
Suministro**



Análisis y Optimización del Abastecimiento, Demanda y su Impacto en los Inventarios de la Industria de Resinas Plásticas

TRABAJO RECEPCIONAL que para obtener el **GRADO** de
ESPECIALISTA EN GESTIÓN DE LA CADENA DE SUMINISTRO

Presenta: **JORGE ELOY LEÓN OROZCO**

Asesor **DR. SALVADOR CERVANTES CERVANTES**

Tlaquepaque, Jalisco. 26 de junio de 2020.

Contenido	
Palabras Clave	3
Capítulo 1 Diseño Metodológico, Contexto y Definición del Problema	4
1.1 Diseño metodológico.....	5
1.2 Introducción.....	5
1.3 Contexto	7
1.4 Definición del Problema de Intervención	10
1.4.1 Objetivo.....	12
Capítulo 2. Estado del Arte	15
.....	17
Capítulo 3. Propuestas de Mejora e Implementación	23
3.1 Obtención de datos, Análisis y Pronóstico.....	24
3.2 Economic Order Quantity.....	26
3.3 Modelo de Compra	30
3.4 Orange: Data Mining Software.....	32
3.5 Value Stream Mapping.....	36
Capítulo 4. Prospectiva de Implementación.....	39
Capítulo 5. Conclusión y Recomendaciones.....	42
4.1 Conclusión.....	43
4.2 Recomendación	43
Bibliografía.....	45
Índice de Figuras	48
Glosario	50

Abstract

El objetivo del siguiente trabajo de obtención de grado (TOG) expone la importancia del vínculo entre el abastecimiento y la demanda. Cómo estas afectan los inventarios que a su vez impactan el flujo de efectivo, retorno de inversión y utilidad neta de las organizaciones. Se genera una solución mediante un modelo donde se calcula la cantidad económica óptima para realizar compra de materiales. Haciendo énfasis en las metodologías Lean, respaldadas por Sakichi y Kiichiro Toyoda. Tomando en cuenta herramientas como *machine learning* para generar niveles óptimos de inventario en cuestión de costos sin sacrificar niveles de servicio ni la satisfacción al cliente.

Por lo tanto, parte también del objetivo del siguiente proyecto es implementar herramientas y modelos propios de la Industria 4.0. Las cuales están revolucionando la forma en cómo operan y toman decisiones las compañías actuales con base en la información que generan los procesos de esta.

Palabras Clave

Abastecimiento, Demanda, Pronósticos, Optimización de Inventarios, Economic Order Quantity, Resinas Plásticas, Machine Learning, Lean Manufacturing, Industria 4.0

Capítulo 1 Diseño Metodológico, Contexto y Definición del Problema

1.1 Diseño metodológico

La investigación realizada en el siguiente trabajo de obtención de grado está basada en el aprendizaje de aplicación en el cual se emplea el conocimiento.

Se realizará una estrategia de intervención fundada en la experiencia de acuerdo con el modelo intervención de Cummings (Cummings, 2010). Esto debido a que se obtendrán datos de los inventarios de la compañía para posteriormente analizarlos y crear un modelo que se recomendará para optimizar las compras, el nivel de inventario, nivel de servicio y disminuir costos de operación.

		Modos de entrega	
		Estudiar y recomendar	Facilitar y aprender
Enfoque de contenido	Sistema técnico	Estrategia basada en la experiencia	Estrategia basada en la enseñanza
	Sistemas sociales	Estrategia basada en la organización	Estrategia basada en procesos

Ilustración 1 Modelo de intervención Fuente: (Cummings, 2010, pág. 282)

1.2 Introducción

En la actualidad vivimos una etapa de cambio constante en el mundo de los negocios. Las empresas con mayor adaptabilidad a los drásticos cambios y que cuenten con ventajas competitivas serán quienes tengan oportunidad de continuar creciendo. Nos encontramos en una época en la que las tecnologías de la información nos permiten obtener mayores resultados,

optimizar procesos, inventarios y recursos. Sin duda existe una gran brecha entre las pequeñas, medianas y grandes empresas en cuestión de capacidad económica, capital humano capacitado e inversión de recursos para desarrollar y obtener el mayor beneficio de estas herramientas tecnológicas.

Es por eso por lo que se decide realizar esta intervención en la empresa. Con base en la necesidad que experimentamos en la brecha existente entre el abastecimiento y la demanda. Los inventarios son los primeros en sufrir esta desincronización. Ya sea comprometiendo el nivel de servicio al cliente o contando con un amplio nivel de *stock*. Que posteriormente generan altos costos operativos. Para una empresa que maneja una gran variedad de materiales, hasta 450 SKU (Fuente propia: obtenido de Resinas de Occidente). Los altos volúmenes de material no son la excepción.

Siendo esta una empresa en constante crecimiento, mejora continua, en proceso de institucionalización, es indispensable implementar modelos que ayuden a trabajar el área operativa de manera más eficiente y rápida para que seamos los colaboradores los encargados de pensar, analizar, tomar decisiones con base en los datos y escenarios generados por los sistemas de inteligencia artificial y modelos matemáticos ya existentes.

Una de las herramientas que se desarrollará a lo largo de este proyecto es un modelo de *machine learning*. Donde el objetivo es que con base en datos históricos de la demanda genere pronósticos acerca de la demanda futura y por medio de un modelo establecido se solicite a compras el nivel de inventario óptimo según las características y necesidades específicas de la compañía. Este es sin duda un reto complejo, con muchas variables por medir, datos por reunir y analizar para construir un modelo que sea fidedigno para ser utilizado en la toma de decisiones del abastecimiento y nivel de inventario óptimo. Sin embargo, los

resultados pueden tener un impacto importante en la reducción de costos y *lead times* haciendo de nuestra cadena de suministro más esbelta o *lean*.




Ilustración 2 Gastos por Manejo de Stock Fuente: Propia

1.3 Contexto

Resinas de Occidente es una empresa con más de 30 años de experiencia en el sector. Con una inversión muy importante en tecnología de ensacado, almacenamiento, distribución e infraestructura ferroviaria.

Más del 80% del material es importado por ferrocarril proveniente de Estados Unidos, por lo que se manejan grandes volúmenes por cada unidad (Fuente propia: obtenido de Resinas de Occidente). Las unidades son también conocidas como HC o *Hopper Cars*. Cada HC tiene una capacidad máxima aproximada de 85 toneladas de material a granel.



Ilustración 3 Importaciones Fuente Secundaria El Financiero: (Sánchez, 2018) Fuente Primaria: Secretaría de Energía y Braskem Idesa

Los materiales mayormente distribuidos se clasifican en las siguientes familias: PE-Polietilenos, PP-Polipropilenos, PET, PVC, PS-Poliestirenos, PC-Policarbonatos. Los materiales previamente mencionados forman parte de la división de los termoplásticos.

El material se compra también en otras presentaciones. Como en contenedores de 25 toneladas con el material ya ensacado que se importan vía marítima de Asia, Medio Oriente y Europa. En menor volumen nos abastecemos además de auto tolvas de 30 toneladas.

El mercado de las resinas plásticas es muy volátil ya que uno de sus compuestos más importantes de materia prima es el petróleo. Este, también conocido como oro negro, es un producto no renovable y motor de la economía moderna. Los precios de este recurso indispensable en nuestra época son variables debido a la oferta, demanda, movimientos y cambios en los mercados internacionales. Por lo tanto, los precios de las resinas plásticas cambian en relación con el precio del crudo. A esto se añade la variante de los cambios del precio del dólar, la principal moneda de cambio internacional.




Ilustración 4 Mapa de Producción de Plástico Fuente: (CamBioTec, 2018, pág. 16)

En México la industria del plástico tiene un crecimiento de 4% anual de acuerdo con datos de la Asociación Nacional de Industrias del Plástico. Sin embargo, para este año la misma asociación pronostica un decremento en su crecimiento a final del cuarto trimestre de 4.5% (Fermín, 2019). Esto de acuerdo con causas microeconómicas, así como también causas de tendencias externas en relación con el cuidado y preservación del medio ambiente. Dentro de estas medidas se incluye la disminución del uso del plástico de único uso y la tendencia hacia el uso de productos que generen menor impacto ambiental. Estas medidas son necesarias. Sin dejar de lado el fomentar la investigación científica en la que se tiene que revisar y estudiar de forma detallada los kilogramos totales de la huella de carbón de dichos productos “ecológicos” que serían el reemplazo de los actuales. Como también el ciclo de vida, su manejo y recolección al finalizar el mismo. Esta industria tiene mucho por trabajar para generar menor impacto al ecosistema y promover la economía circular. Para esto hay que pasar de la teoría de estas medidas a la práctica y desarrollo escalable en este sector.




Ilustración 5 Economía Circular Fuente: (Europe, 2018, pág. 7)

La industria plástica en México aporta más del 3% del PIB nacional en 2019. Generando más de 1 millón de empleos de forma directa e indirecta y concentrando inversiones por más de 30 mil millones de dólares (Torres, 2019).

De acuerdo con las previsiones, los precios del petróleo crudo promediarán los \$66 dólares por barril en 2019 y los 65 dólares por barril en 2020, lo que representa una revisión a la baja respecto de las previsiones de octubre, a raíz de las perspectivas de un crecimiento mundial menor que el esperado y la producción mayor que la prevista en Estados Unidos, dijo el Banco Mundial (Felsenthal, 2019).

Según información del periódico Business Korea, el precio del etileno, que es uno de los productos más utilizados en la industria petroquímica, ha tocado su precio más bajo en 4 años. En 2014 era de \$1,418 dólares y el pasado mes de junio de 2019 fue de \$810 dólares (Min-hee, 2019).

Estas caídas en los precios del crudo y a su vez del etileno provoca que el precio de las resinas plásticas baje considerablemente. Al ser este un *commodity*, no está exento de los precios, mercados internacionales, factores micro y macroeconómicos impactan también de manera directa este negocio.

1.4 Definición del Problema de Intervención

La problemática a la que se enfrenta esta empresa es la ausencia de indicadores y modelos para realizar una compra de inventario óptima de acuerdo con la demanda existente. Para con esto disminuir los niveles de inventario, que a su vez disminuyen los gastos de operación aumentando el flujo de efectivo. Siendo este vital para cualquier organización. Esto sin descuidar el nivel de servicio que se tiene ante el cliente el cual ha sido de más del 98% en lo que va del 2019.

En la actualidad existen HC que llegan a cumplir más de 80 días en espuela. Esto genera elevados gastos de almacenaje. Las tarifas van desde los 75 USD diarios a partir de los 30 días. Dando un total de hasta 3,750 USD. Estos costos innecesarios que además son por cada HC, se tienen que pagar por falta de planeación, indicadores, gestión de inventario y vinculación con la demanda previamente pronosticada. Cabe mencionar que hemos llegado a contar con hasta 60 HC en inventario. Si en cada uno de estos casos se pagan demoras por falta de planeación entre el vínculo de la demanda y el abastecimiento se puede llegar a ocasionar costos por demoras de hasta 4,500 USD diarios por todas las unidades (HC). Y costos adicionales de mucho menor impacto por movimientos de los HC en la espuela de ferrocarril de 54 pesos por unidad.

La Resina A que es de las que más tiene movimiento y que entra dentro del 20% de los materiales que generan el 80% de las ventas. Es un material con el que siempre debemos contar en almacén. Sin embargo, en ocasiones contamos con un exceso de este inventario y el punto de reorden no está definido ni el *safety stock* para contar con cierto nivel de servicio esperado. A inicios del mes de diciembre de 2019 contamos con solamente un remanente de un HC que es 1 tonelada en almacén ferroviario y no se cuenta con nada en tránsito. El mes de octubre de 2019 contábamos con 540 toneladas de las cuales 270 se encontraban en almacén ferroviario y 270 en tránsito.

Esto muestra claramente que no existe un *safety stock* definido y que las compras se realizan en lotes muy grandes pocas veces al año, a pesar de tener un costo administrativo por compra que no es tan representativo de: 250 USD por cada orden de compra realizada. Es preciso mencionar que la demanda tiene un comportamiento relativamente estable a lo largo del año. Esto puede permitir llevar una planeación y pronóstico más certero para realizar compras de

este material en más de una ocasión a lo largo del mes. Para contar un flujo continuo de material en tránsito, en almacén y disminuir el tiempo de ciclo de este que actualmente es mayor a los 30 días.

El problema que se tiene actualmente ocasiona almacenar grandes cantidades de inventario generando altos costos operativos. Sin embargo, en otras ocasiones se compromete el nivel de inventario de uno de los materiales clave para la compañía. (Fuente propia: obtenido de Resinas de Occidente).

1.4.1 Objetivo

El objetivo de este trabajo de obtención de grado es crear un modelo de *machine learning* basado en la metodología Bayesian Linear Regression, Boosted Decision Tree Regression, and Decision Forest Regression que sea capaz de arrojar información, al ir aprendiendo con el paso del tiempo la cantidad de inventario necesario y cuando comprarlo para cumplir con cierta demanda, sin caer en excesos de inventario ni disminuir el nivel de servicio el cual actualmente es de más del 98%. Esto con el propósito de disminuir los gastos operativos relacionados con la gestión de inventario, que a su vez impacta el flujo de efectivo de la organización y la rentabilidad de esta.

En caso de no ser exitoso o necesario el modelo de *machine learning* se trabajará en la realización de un pronóstico en una hoja de cálculo de Excel automatizado en el que se estudiará la demanda futura. Se diseñará y creará un modelo para realizar compras óptimas en relación con una demanda previamente presentada en el pronóstico. Por lo tanto, sería una plantilla ejecutiva donde se podrá visualizar los costos de la compra de inventario, inventario

en tránsito, costos operativos, demanda, rotación del inventario, que cantidad, materiales y fecha óptima para realizar el siguiente pedido de resina.

El propósito de utilizar la metodología de Lean Manufacturing es disminuir el lead time de la cadena de suministro, para concentrar en los recursos en las actividades que generan valor a la organización, el material y el cliente. Esto mediante un mapa de cadena de valor. El cuál será la principal herramienta para detectar áreas de oportunidad y generar eventos Kaizen de alto impacto dentro de los procesos primarios y secundarios de la empresa.

Como lo muestra Chopra y Meindl claramente en la siguiente gráfica, para contar una Cadena de Suministro eficiente se debe buscar el equilibrio entre una cadena flexible vs. una cadena eficiente. Al igual que tener bien identificado el nivel de incertidumbre de la demanda. Lo anterior sirve para que podamos encontrar el equilibrio y entrar a la zona de estratégica óptima.




Ilustración 6 Zone Stretegic Fit Fuente: (Sunil Chopra, 2016, pág. 28)

Sin duda es un reto mayor y bastante complejo, por lo que se irá paso a paso mostrando los avances que se fueron teniendo a lo largo de este proyecto de alto impacto de intervención profesional.

Capítulo 2. Estado del Arte

Cabe mencionar que existen ya importantes teorías, herramientas utilizadas en diversas industrias y casos de éxito. Estos sirven como estrategia para llevar a cabo una buena gestión de inventario. Es por eso que a continuación se presenta parte fundamental de este trabajo de obtención de grado. Que es la investigación de casos, fuentes y autores que cuentan con vasta experiencia en el tema. Se tomarán como referencia para sustentar este trabajo, investigación e intervención. En este proceso será clave la adaptación de estas herramientas e ideologías al sector industrial del que deriva la problemática.

Para acotar la brecha que existe entre el abastecimiento y la demanda un punto relevante es el canal de comunicación entre los proveedores, la compañía y los clientes. Existen empresas como Toyota y Honda que han sido capaces de llegar a un nivel superior de *networking* en el que las tres partes involucradas conocen la visión, incluso la demanda uno de otro.

De acuerdo con los autores Jeffrey K. Linker y Thomas Y. Choi. Para tener éxito una compañía que practica *lean manufacturing* debe tener fuertes alianzas estratégicas con sus proveedores, clientes y partes interesadas. Esto con el fin de crear una cultura de mejora continua, aprender uno del otro, hacer *networking* y practicar el famoso término japonés llamado *Keiretsu* (Building Deep Supplier Relationships, 2004, pág. 10).

Haciendo mención de la definición de *Keiretsu* por parte de Jeffrey K. Linker y Thomas Y. Choi “Close-knit networks of vendors that continuously learn, improve, and prosper along with their parent companies” (Building Deep Supplier Relationships, 2004, pág. 3).

Inventarios

De acuerdo con Chopra, a mayor nivel de inventario, se facilita la reducción de costos en producción y transporte. Debido a las economías en escala. Sin embargo, los costos de

almacenaje aumentan. Bajos niveles de inventario mejoran el ciclo de inventario, pero pueden ocasionar pérdidas en ventas por no contar con el producto. (Sunil Chopra, 2016, págs. 49-50)

Con base con Production and Operations Management Society “In the context of inventory management, demand is the key uncertainty affecting decisions and such works suggest a potential opportunity to leverage large-scale web data to improve inventory decisions” (Dimitris Bertsimas, 2016, pág. 1).

Un tema importante relacionado al inventario y que se estará desarrollando en el presente proyecto es el inventario de seguridad. El cual Chopra define como: “Safety inventory is inventory carried to satisfy demand that exceeds the amount forecast. Safety inventory is required because demand is uncertain, and a product shortage may result if actual demand exceeds the forecast demand” (Sunil Chopra, 2016, pág. 314).




Ilustración 7 Inventario de Seguridad Fuente: (Sunil Chopra, 2016, pág. 315)

Lean Manufacturing

Lean manufacturing es un concepto que tiene origen japonés. Puede ser comprendido como:

“El nivel óptimo para producir bienes mediante la eliminación del desperdicio e implementando el flujo de procesamiento por lotes. Es una filosofía de la administración de

procesos desarrollada por Toyota enfocada en eliminar los siete desperdicios (sobreproducción, tiempos de espera, transporte, retrabajos, **inventarios innecesarios**, defectos, movimientos innecesarios)” (Philip Kosky, 2006).

Inventarios innecesarios es el punto específico que se estudiará durante este proyecto de intervención.

Industria 4.0

El vínculo entre la industria 4.0 y *lean manufacturing* es una relación que en pocas ocasiones se toma en cuenta. Con base en el Diario Internacional de Producción e Investigación, Sven-Vegard Buera, Jan Ola Strandhagen y Felix T. S. Chan argumentan que la metodología *lean manufacturing* puede ser utilizada como principio para construir e implementar la Industria 4.0. Esto debido a la filosofía de cero desperdicios promovida por *lean* y cómo esta simplifica la automatización y digitalización de procesos (Sven-Vegard Buera, 2017, pág. 8).

Acorde a Fisher, que expresa en el caso Harvard, mediante un complejo desarrollo computarizado matemático lograron obtener el nivel óptimo de producción y abastecimiento. Con esto al finalizar el pronóstico inicial con la información de la demanda previa, se puede determinar con mayor eficacia el programa de producción futuro (Making Supply Meet Demand in a Uncertain World, 1994).

Otra de las razones que motiva la realización de este proyecto, se puede describir mediante la siguiente frase del libro de La Carrera “No debemos buscar una mejora, sino la implementación de un proceso de mejora continua” (Goldratt, 1997, pág. 127). Implementar una cultura de mejora de procesos y mejora continua traerá muchos cambios e impactos

positivos en la organización. Parte de esos cambios es la toma de decisiones con sustento en datos duros.

Por lo tanto, parte de la implementación es generar ese cambio de filosofía en el cual nos debemos acostumbrar como compañía a que “nuestros procesos hablen” (Placencia, 2019) y a partir de esto analizar los datos obtenidos para realizar una toma de decisiones con mayor sustento e impacto.

En referencia a los cambios tecnológicos que existen y se siguen transformando de manera exponencial, Klaus Schwab fundador del Foro Económico Mundial y autor del libro La Cuarta Revolución Industrial, hace alusión en su libro las diferencias entre los países de primer mundo con el resto. Cómo algunos países y sectores de la sociedad aún no están viviendo los efectos de la segunda revolución industrial, ya que no cuentan con acceso a la electricidad cerca de 17% de la población mundial. La tercera revolución industrial tampoco es la excepción siendo que más del 50% de la población mundial aún no cuenta con acceso a internet (Schwab, 2016). Es por lo que México siendo un país de tercer mundo requiere de especialización del capital humano e inversión de las organizaciones en desarrollo y tecnología. Esto para no quedarse detrás en esta nueva revolución de la cual ya comenzamos rezagados contra las grandes potencias mundiales.

Los cambios, implementaciones y propuestas en este proyecto no solo pretenden optimizar el inventario para disminuir costos, subrayan la importancia del uso de herramientas de *machine learning* para comenzar a utilizar las nuevas tecnologías disponibles y no sólo quedarnos con la tecnología que brindan los ERP actuales. Es fundamental la actualización de herramientas tecnológicas en cualquier sector industrial para no quedar fuera de posibilidades de competir contra las grandes corporaciones. Y el caso de esta organización no es la excepción.

Machine Learning

Machine learning es uno de los conceptos de mayor desarrollo tecnológico en la actualidad. Algunos autores como la periodista Miriam Prieto Madrid la mencionan incluso como el “motor de la inteligencia artificial” (Madrid, 2017, pág. 1). Por lo tanto, el utilizar las herramientas que son los motores de la mayor parte de las compañías de negocios y tecnología, brinda sin duda una ventaja competitiva ante los competidores de nuestro sector. Quien realice mayor desarrollo e inversión en estos modelos de análisis de datos para toma de decisiones tendrá una cadena de suministro más eficiente, disminuyendo costos y aumentando el crecimiento de su cadena de valor.

Sin embargo, aún existen muchas incógnitas en relación con los modelos que podrán ser creados en el futuro. Ya que no se sabe qué tanto poder requerirán las computadoras para generar la confiabilidad deseada. Lo único seguro es que se requerirá de modelos y plataformas flexibles y escalables para ser utilizadas por la mayoría como hoy lo es el internet (Roddy, 2019).

De acuerdo con el artículo de Demand Forecasting in Restaurants Using Machine Learning and Statistical Analysis, el error que obtuvieron en su pronóstico fue relativamente bajo. Su conclusión fue que planean mejorar aún más la eficiencia de su pronóstico, así como también automatizar el abastecimiento de ingredientes y trabajar en el programa de los colaboradores con base en los resultados obtenidos del modelo de pronóstico por medio de *machine learning* (Takashi Tanizakia, 2018, pág. 5).




Ilustración 8 Ejemplo Forecast Fuente: (Takashi Tanizakia, 2018)

In this research, the number of customers is forecasted using machine learning and statistical analysis method with internal data and external data in the ubiquitous environment. Bayesian Linear Regression, Boosted Decision Tree Regression, and Decision Forest Regression are used for machine learning, Stepwise method is used for statistical analysis method. We used Azure Machine Learning tool and SPSS as a statistical analysis tool (Takashi Tanizakia, 2018, pág. 1).

Después de analizar la implementación de modelos de *machine learning* para estudiar y pronosticar demanda por parte de autores de varias industrias, se encuentra el estudio previo mencionado el cual fue realizado en Japón. Se decide implementar la metodología utilizada por Takashi, ya que la solución al problema del análisis de la demanda de restaurantes cumple con las características del problema que tenemos en Resinas de Occidente entre la optimización del vínculo de la demanda y el abastecimiento.

Tomando como referencia las herramientas utilizadas por Takashi, dentro del pronóstico de *machine learning* y el análisis estadístico. Se utilizarán: Bayesian Linear Regression, Boosted Decision Tree Regression y Decision Forest Regression (Takashi Tanizakia, 2018). Para esto será utilizado el *software* de inteligencia artificial Orange.

Capítulo 3. Propuestas de Mejora e Implementación

3.1 Obtención de datos, Análisis y Pronóstico

De acuerdo con las necesidades y problemática detectadas en Resinas de Occidente se toma la decisión de implementar lo siguiente:

1. Obtención de datos de ventas del ERP SAP Business One por medio de un *query*.

El material “A” que representa el 5.81% de las ventas totales de la compañía. Con un crecimiento en ventas del 76.90% del año 2019 contra 2018.




Ilustración 9 Datos Ventas Resina A (Fuente Propia)

2. Revisión de estacionalidad de las ventas de la resina “A”. En este proceso se observa que sí existe cierto comportamiento que puede llegar a ser predecible con cierto nivel de confianza lo cual más adelante se revisará más a fondo.




Ilustración 10 Ventas Por Año Resina A (Fuente Propia)




Ilustración 11 Ventas Promedio Por Mes Resina A (Fuente Propia)

3. Se realizan los siguientes pronósticos buscando el alfa y beta óptimas con ayuda de un modelo de *solver* y se obtienen los siguientes resultados:

MÉTODO DE PRONÓSTICO	VENTAS ENERO 2020	MEAN SQUARED ERROR	VENTAS PRONÓSTICO ENERO VS VENTAS ENERO 2020
Cumulative	390,052.92	35,955,662,997.31	240,392.00
Naive	797,280.00	30,960,088,038.30	166,835.00
Weighted Moving Average	695,596.43	22,901,079,681.82	65,151.00
Moving Average	773,829.62	19,621,164,385.66	143,385.00
Seasonal	1,697,731.86	155,347,032,941.70	1,067,287.00
Holt-Winters	673,175.90	23,507,483,359.32	42,731.00
Holt Linear Trend	763,600.52	20,464,318,679.01	133,156.00
Simple Exponential Smoothing	682,420.75	18,727,251,193.83	51,976.00

Ilustración 12 Pronósticos Resina A (Fuente Propia)




Ilustración 13 Simple Exponential Smoothing Resina A (Fuente Propia)

Se observa que el menor error para el pronóstico de ventas lo arrojó el método Simple Exponential Smoothing.

3.2 Economic Order Quantity

1. Lo primero fue realizar la definición y el cálculo de las variables para obtener EOQ.

$$\text{Costo/Transacción } Ct = (\$80,000.00_{\text{(sueldo compras)}} / 20_{\text{(días laborales al mes)}} / 480_{\text{(min laborados al día)}})$$

$$*20_{\text{(min de proceso/OC)}} = \$167.00/ \text{ orden}$$

$$\text{Demanda } D = (682,420.75 \text{ kg} * 12)_{\text{(demanda anual material "A")}} / (85,000 \text{ kg})_{\text{(peso/HC)}} = 96.34$$

HC/año

$$\text{Costo Materia Prima } C = (\$23.5_{\text{(pesos mexicanos)}} * .71_{\text{(USD/kg)}} * (85,000 \text{ kg})_{\text{(peso/HC)}} = \$1,409,236.25_{\text{(costo/HC)}}$$

$$Ce = 66.46\% * \$1,409,236.25_{\text{(costo/HC)}} = \$936,595.00$$

Inventario de Seguridad SS = $(96.34 \text{ (demanda HC anual)} / 360 \text{ (días al año)}) * (1.25 \text{ (máximo crecimiento de demanda esperada)}) * (25 \text{ (max lead time)}) - (96.34 \text{ (demanda HC anual)} / 360) * (16 \text{ (promedio lead time)}) = 4$

Los tiempos de *lead times* se obtuvieron de una tabla con más de 358 ciudades que juntas brindan información relevante y exacta en cuestión de tiempos promedio de tránsito de los HC al almacén en territorio mexicano.

Promedio de DÍAS DE TRAYECTO	BUSCAR					
ESPUELA DESTINO	ADDIS,LA	ALEXANDRIA,LA	AVONDALE,LA	BATON ROUGE,LA	BERWICK,LA	BRIMSTONE STOR,LA
ALMACÉN	8.00	13.89	16.33	15.78	13.00	18.75
Total general	8.00	13.89	16.33	15.78	13.00	18.75
	MAX LEAD TIME	25				
	PROMEDIO LEAD TIME	16				

Ilustración 14 Lead Time Histórico (Fuente Propia)

Costo de Almacenamiento anual de 1 Hopper Car:

	DÍA	COSTO
RECEPCIÓN HC	1	\$ 3,105.00
BÁSCULA	1	\$ 1,500.00
COSTOS ESTADÍAS	21	\$ 10,032.00
	45	
	45	\$ 10,725.00
	60	
	61	\$ 319,033.00
	360	
COSTO DEMORAS PROVEEDOR	45	\$ 592,200.00
	360	
		\$ 936,595.00

Ilustración 15 Costos Almacenamiento por HC (Fuente Propia)

Costo de Almacenamiento CH = \$936,595.00 (costo almacenaje anual) / \$1,409,236.25 (costo/HC) =

66.46%

Ct	\$167.00	por orden	\$23.50	DÓLAR
CH	66.46%	costo/año	\$0.71	PRECIO USD POR KG
D	96.34	unidad/año		
c	\$1,409,236.25	costo/unidad		
ce	\$936,595.00			
SS	4			

Ilustración 16 Datos Para Calcular EOQ (Fuente Propia)

En la mayor parte de las ocasiones se realizan las compras de la resina “A” en cantidades de 3 hasta 7 HC por cada orden de compra.

Q (HC)	Costo de Órdenes de Compra Anual	Costo Inventario Anual	Costo Total
0.1	\$ 160,569.59	\$ 46,829.75	\$ 207,399.34
0.19	\$ 86,714.67	\$ 86,714.67	\$ 173,429.34
0.5	\$ 32,113.92	\$ 234,148.75	\$ 266,262.67
1	\$ 16,056.96	\$ 468,297.50	\$ 484,354.46
2	\$ 8,028.48	\$ 936,595.00	\$ 944,623.48
3	\$ 5,352.32	\$ 1,404,892.50	\$ 1,410,244.82
4	\$ 4,014.24	\$ 1,873,190.00	\$ 1,877,204.24
5	\$ 3,211.39	\$ 2,341,487.50	\$ 2,344,698.89
6	\$ 2,676.16	\$ 2,809,785.00	\$ 2,812,461.16
7	\$ 2,293.85	\$ 3,278,082.50	\$ 3,280,376.35

Ilustración 17 Economic Order Quantity (Fuente Propia)

Aquí se puede observar que la cantidad óptima para comprar material “A” es .19 HC. Lo cual no es posible ya que el mínimo de compra es de 1 HC. Por lo tanto, obtenemos que EOQ es 1 HC. Con un costo total de \$484,354.46.




Ilustración 18 Gráfica EOQ (Fuente Propia)

Días de tránsito =	16 días
Pedidos al año =	96.34 OC
Stock de seguridad =	4 HC
Pedidos cada =	3.74 días
<i>Re-order point</i> =	8 HC
Demanda diaria =	0.27 HC

De la siguiente manera se comportarían de forma óptima las compras de materia prima:




Ilustración 19 Comportamiento Inventario (Fuente Propia)

Cabe mencionar que en la línea de pedidos cada que se encuentra en el número 1 del eje Y significa que se realiza el pedido y cuando está en 0 no se realiza acción alguna.

La línea azul es la cantidad de inventario con el que se cuenta en espuela. Este inventario está representado por HC de 85 toneladas cada uno.

3.3 Modelo de Compra

Posterior a la obtención del cálculo de EOQ, es importante hacer mención que existen 3 tipos de presentaciones de compra de materiales.

- 85 toneladas en presentación granel por ferrocarril de importación.
- 29 toneladas en presentación granel en tolva.

- 25 ton en presentación de sacos de 25 kg transportado por trailer.

El objetivo del modelo de compra es posterior a la obtención del cálculo de EOQ. Tener la herramienta que pueda brindar información acerca de cuál proveedor es el indicado dependiendo su costo en el momento en el que se requiera realizar la compra. Ya que siendo un *commodity* con una estrecha relación con los precios del petróleo y los cambios en el tipo de cambio. Y contar con todas las 3 diferentes opciones de presentación de material. Esto se logra a partir de un modelo de programación lineal que cuenta con las siguientes restricciones:

Parámetros de Solver ✕

Establecer objetivo: ↑

Para: ☐ Máx ☒ Mín ☐ Valor de:

Cambiando las celdas de variables: ↑

Sujeto a las restricciones:

\$D\$6:\$D\$12 = entero

\$F\$14 >= \$B\$2

↑

Agregar

Cambiar

Eliminar

Restablecer todo

Cargar/Guardar

↓

☒ Convertir variables sin restricciones en no negativas

Método de resolución: v

Ilustración 20 Modelo de Programación Lineal (Fuente Propia)

Así es como luce el modelo, en el cual solamente hay que ingresar la demanda requerida y los precios de cada uno de los proveedores.

		INGRESAR				
DEMANDA KG	85,000.00					
TIPO DE						
CAMBIO USD	\$	23.50				
MATERIAL	PROVEEDOR	PRECIO/KG	CANTIDAD HC, TOLVA, CAJA	MOQ KG	ORDEN	COSTO MP
A	1	\$ 18.80	0	85,000	0	\$ -
	2	\$ 18.33	1	85,000	85,000	\$ 1,558,050.00
	3	\$ 18.57	0	85,000	0	\$ -
	4	\$ 18.33	0	85,000	0	\$ -
	5	\$ 18.33	0	85,000	0	\$ -
	CAJA	\$ 20.68	0	25,000	0	\$ -
	TOLVA	\$ 19.74	0	29,000	0	\$ -
			COMPRA DE UNIDADES	ORDENAR KG		
			1.00	85,000.00		\$1,558,050.00

Ilustración 21 Resultado Modelo de Programación Lineal (Fuente Propia)

3.4 Orange: Data Mining Software

Debido a que los datos con los que cuenta la compañía son dos variables: tiempo y ventas. No fue posible realizar un modelo de regresión y *machine learning* por la poca cantidad de variables entre los datos que se cuenta la compañía. Sin embargo, se utilizó el *software* Orange como apoyo para comparar los modelos de pronóstico realizados previamente. En donde el que obtuvo menor error fue el método Simple Exponential Smoothing con un *mean squared error* de 18,727,251,193.83.

En Orange se utilizó un modelo de pronóstico que pertenece a las series de tiempo, el cual será presentado a continuación. Cabe mencionar que este modelo puede predecir más de un solo periodo por lo tanto es sumamente útil.

El primer modelo utilizado fue el VAR llamado Vectores Autorregresivos, es un modelo de ecuaciones simultáneas.

El área punteada es el área pronosticada y en el área sombreada de verde hay un 95% de confiabilidad de que el resultado se encuentre entre ese rango.




Ilustración 23 Pronóstico Gráfica VAR (Software Orange Data Mining)

En el recuadro rojo se muestran los valores de los 5 meses pronosticados y en azul los valores mínimos y máximos del rango con el 95% de confianza.

Data Table

Sat Apr 25 20, 17:48:55

Data instances: 5

Features: 6

Meta attributes: None

	HD (forecast)	FECHA (forecast)	HD (95%CI low)	FECHA (95%CI low)	HD (95%CI high)	FECHA (95%CI high)
1	630445	1.57786e+09	342220	1.57771e+09	918669	1.578e+09
2	674780	1.58047e+09	375612	1.58029e+09	973949	1.58065e+09
3	611930	1.58314e+09	274529	1.58289e+09	949330	1.58339e+09
4	613138	1.58579e+09	265704	1.58549e+09	960571	1.58609e+09
5	585628	1.58847e+09	225382	1.58811e+09	945875	1.58884e+09

Ilustración 24 Resultados Pronóstico VAR (Software Orange Data Mining)

De forma adicional el siguiente gráfico se interpreta de forma visual la posible estacionalidad de las ventas del material A.

En el caso de este material en específico no se encontraron patrones estacionales. La conclusión en este caso es que el mes de febrero y junio son los dos meses con menores ventas en comparación de los demás meses del año.




Ilustración 25 Estacionalidad (Software Orange Data Mining)

El modelo VAR fue comparado con los datos de ventas reales de los meses de enero a mayo de 2020. Y el resultado fue el siguiente:

Mes	Ventas Kg	Pronóstico Kg		
oct-19	924,210	924,210		
nov-19	600,000	600,000		
dic-19	797,280	797,280	e	e^2
ene-20	754,641	630,445	124,195.50	15,424,522,220.25
feb-20	897,902	674,780	223,121.96	49,783,409,034.24
mar-20	844,104	611,930	232,173.85	53,904,696,623.82
abr-20	485,795	613,138	127,343.00	16,216,239,649.00
may-20		585,628	585,628.00	342,960,154,384.00

MAE	MSE
176,708.58	33,832,216,881.83

Ilustración 26 Resultado Pronóstico VAR (Fuente Propia)




Ilustración 28 Gráfica Pronóstico VAR (Fuente Propia)

El error obtenido en el modelo VAR fue de 33,832,216,881.83 el cuál es mayor al error obtenido con el método Simple Exponential Smoothing con un mean squared error de 18,727,251,193.83.

3.5 Value Stream Mapping

Parte del análisis realizado en el proyecto fue el utilizar una herramienta de Lean Manufacturing como lo es VSM. Se tomó la decisión de la utilización de este método de mapeo de procesos, flujo de información y materiales. Con el objetivo de optimizar los procesos actuales de la compañía y poder operar de forma más eficiente aprovechando los recursos con los que se cuenta en la actualidad sin realizar inversiones importantes.

La recomendación es implementar los siguientes puntos:

1. Negociación de pagos a 60 días o más de 30: con esta mejora aumentamos el flujo de efectivo. El pilar estratégico al cual abona es a Rentabilidad.
2. Implementación de análisis estadísticos y EOQ para compra de materiales (cuánto y cuándo): tiene como objetivo disminuir el inventario de los productos que menos se mueven y aumentar el nivel de servicio. El pilar estratégico al cual abona es Rentabilidad y Satisfacción al cliente.
3. Super mercado de materiales de insumos: con esto mejora el flujo de efectivo, haciendo una cadena de suministro apegada a la metodología *lean*. El pilar estratégico al cual abona es rentabilidad.
4. Implementación de MRP: el pilar estratégico al cual abona es rentabilidad
5. SMED: este pilar abona a la rentabilidad y la satisfacción de empleados, porque los operadores ganan a destajo.

6. Envío de información electrónica: abona a entrega y confiabilidad porque disminuyen los tiempos de flujo de información.
7. Contratación de tercera persona en servicio al cliente: abona a entrega ya que se cuenta con mayor capacidad de tomar pedidos.
8. Envío de autorización electrónica: abona a entrega y confiabilidad porque disminuyen los tiempos de flujo de información.
9. Negociación de cobro a 30 días: el pilar estratégico al cual abona es rentabilidad y liquidez.

Ilustración 29 VSM Futuro ((Eloy León, Ruriko Aragaki, Lucero Mercado, Emir Martinez, Victor Prado, ITESO 2019)

Capítulo 4. Prospectiva de Implementación

Debido a situaciones ajenas a la compañía no se ha podido presentar de manera formal el proyecto, por lo tanto, aún no se comienza con la implementación de este. Sin embargo, lo que se presenta a continuación es el escenario esperado posterior a su implementación en cuestión financiera, operativa y de servicio.

El siguiente escenario toma en cuenta que la demanda de la resina A sea constante de .27 HC diarios. La mayor diferencia entre el escenario actual y el propuesto es que en el actual se tienen 62.5 días de estadías promedio versus 16 días de estadías promedio del escenario propuesto, en la opción propuesta se cuenta con 48% mayor inventario a la mano ya que se llevó a cabo el cálculo de *safety stock*. Esto genera una mayor rotación de inventario lo cual es vital para el flujo de efectivo en empresas de comercialización de *commodities* donde los márgenes son reducidos.

Esto cambia de manera importante los costos de almacenaje los cuales se le pagan tanto a la terminal ferroviaria como al productor de la resina que son los dueños de los HC. Ahí está la gran diferencia que al final de cuentas en este escenario en específico si continuara el mismo patrón durante el año se lograría obtener un ahorro de 2,613,244.76 pesos. Cabe mencionar que este es el ejemplo de 1 sólo material de los 24 restantes que conforman el 80% de las ventas de la compañía.

Es importante mencionar que el ahorro de la fotografía tomada es estimado dando por hecho que la demanda durante el año permanezca constante y que las compras de inventario que actualmente se realizan de forma empírica se continúen comprando lotes de 3 HC e incluso más por cada orden de compra. Sin embargo, el ahorro se ve de manera muy clara después de conocer la demanda diaria, calcular EOQ, conocer el lead time de manera confiable usando estadísticas históricas y desglosando los costos de almacenaje por HC en espuela.

	09/05/2020	
	ESCENARIO ACTUAL	ESCENARIO PROPUESTO
KGS EN TRÁNSITO	255,000	85,000
KGS EN ESPUELA	170,000	340,000
DÍAS PROMEDIO EN ESPUELA	62.5	16
KGS ENSACADOS	59,456	0
KGS DISPONIBLES	229,456	340,000
DÍAS PROMEDIO MATERIAL EN ALMACÉN	102	0
DÍAS PROMEDIO ALMACENAJE	165	16
COSTO ALMACENAJE	\$63,459.48	\$18,420.00
COSTO ALMACENAJE ANUAL (SI CONTINUA LA MISMA TENDENCIA)	\$3,056,898.53	\$443,653.77

AHORRO ANUAL	\$	2,613,244.76
---------------------	-----------	---------------------

Ilustración 30 Prospectiva de Implementación (Fuente Propia)

Capítulo 5. Conclusión y Recomendaciones

4.1 Conclusión

Al término de este trabajo de obtención de grado se llegó al objetivo. El cual fue la obtención de datos para transformar en información, análisis y comprensión de estos, para posteriormente generar una propuesta de mejora que se recomienda a la organización.

Un paso fundamental que se tiene que llevar en un principio es el detectar con qué tipo de datos se cuenta. Porque esto dará pie a lo que se pueda o no analizar, manejar y modelar. En el caso de este proyecto los datos obtenidos no permitían el realizar regresiones y análisis más robustos para poder llevar a cabo un modelo de *machine learning*. Sin embargo, se pudo hacer uso de modelos de pronósticos de series de tiempo como el Simple Exponential Smoothing y el modelo VAR.

Uno de los objetivos principales de este proyecto fue el poder mostrar cómo el uso de la tecnología, los modelos matemáticos y el tomar decisiones basadas en datos da mejores resultados que hacerlo de forma empírica y sin la información suficiente.

Cabe mencionar que el presente trabajo de obtención de grado es el análisis de uno de los materiales más importantes para la empresa. Pero el mismo proceso se está llevando a cabo con el 20% de los materiales que generan el 80% de las ventas. Los cuales son 25 materiales. Queda pendiente la revisión y autorización del proyecto por parte de dirección para poder iniciar con la implementación de manera formal.

4.2 Recomendación

Las recomendaciones a la empresa Resinas de Occidente son: cambiar el método de compra de materia prima. Utilizar pronósticos de mayor complejidad que generen un menor error como los previamente mencionados. Hacer uso del modelo de compra por medio de EOQ y mediante el modelo de programación lineal encontrar al proveedor óptimo dependiendo la

cantidad y el costo de la resina. Este nuevo método permitirá reducir los costos de almacenaje y compra sin reducir el nivel de servicio.

Se recomienda también hacer uso del MRP con el que actualmente se cuenta. Ya que con la base de información y modelos de este proyecto sumado al uso del MRP cambiará totalmente el método de suministro de la organización.

La manera de implementarlo y basar las mejoras con métricos e indicadores claros y objetivos es mediante el VSM. Al utilizar esta herramienta de *lean manufacturing* se detectaron claramente las áreas de oportunidad y como atacar cada una de ellas.

Por último, se recomienda a la empresa, para que la implementación sea exitosa, se reúna un equipo de trabajo donde se designen responsables; se vaya dando seguimiento al tema de cerca para ir conociendo los avances obtenidos y de ser necesario hacer ajustes en la implementación.

Bibliografía

Building Deep Supplier Relationships, R0412G (Harvard Business Review Diciembre 2004).

CamBioTec. (2018, 01 01). www.cambiotec.org.mx. Retrieved from www.cambiotec.org.mx:
http://comecyt.edomex.gob.mx/files/competitividad_sector_plasticos.pdf

Cummings, T. (2010). Management Consulting Today and Tomorrow. In T. Cummings,
Management Consulting Today and Tomorrow. New York; London: Routledge.

Dimitris Bertsimas, N. K. (2016). Inventory Management in the Era of Big Data. *Production and Operations Management*, 4.

Eisner, E. W. (2000). Benjamin Bloom. *Perspectivas: Revista Trimestral de Educación*, 423-432.

Europe, P. (2018). <https://www.plasticseurope.org/es>. Retrieved from
<https://www.plasticseurope.org/es>:
https://www.plasticseurope.org/application/files/6315/4510/9658/Plastics_the_facts_2018_AF_web.pdf

Felsenthal, M. (2019, Abril 23). *Banco Mundial*. Retrieved from
<https://www.bancomundial.org/>: <https://www.bancomundial.org/es/news/press-release/2019/04/23/oil-prices-to-be-lower-in-2019-on-slower-than-expected-global-growth-rising-non-opec-supply>

Fermín, S. S. (2019, Junio 25). ¿Llegó el fin de la hora del plástico? *Expansión*, p. 1.

Goldratt, E. M. (1997). La Carrera. In E. M. Goldratt, *La Carrera* (p. 197). Buenos Aires: Granica.

Madrid, M. P. (2017, Abril 19). Machine Learning, el motor de la inteligencia artificial de Google. *Expansión*, p. 1.

Making Supply Meet Demand in a Uncertain World, 94302 (Harvard Business Review Mayo-Junio 1994).

Min-hee, J. (2019, Junio 12). *Business Korea*. Retrieved from
<http://www.businesskorea.co.kr/>:
<http://www.businesskorea.co.kr/news/articleView.html?idxno=32779>

Philip Kosky, R. B. (2006). Exploring Engineering. In R. B. Philip Kosky, *Exploring Engineering* (p. 486). Canada: AP.

Placencia, I. Á. (2019, Noviembre). Gestión Sustentable en la Cadena de Suministro. Tlaquepaque, Jalisco, México.

Roddy, S. (2019, Noviembre 14). *MIT Technology Review*. Retrieved from
<https://www.technologyreview.com/>:
<https://www.technologyreview.com/s/614660/the-success-of-machine-learning-rests-on-scalability/>

Sánchez, A. (2018, 12 26). Entra más resina plástica a México, pese a que Etileno XXI fabrica este material. *El Financiero*, p. 1.

Schwab, K. (2016). *The Fourth Industrial Revolution*. UK: Debate.

Sunil Chopra, P. M. (2016). *Supply Chain Management*. USA: Pearson.

Sven-Vegard Buera, J. O. (2017). The link between Industry 4.0 and lean manufacturing: mapping current research and. *International Journal of Production Research*, 18.

Takashi Tanizakia, T. H. (2018, Julio 18-20). <https://www.sciencedirect.com/>. Retrieved from Demand forecasting in restaurants using machine learning and statistical analysis:
<https://reader.elsevier.com/reader/sd/pii/S2212827119301568?token=04986A3475201EC70D5BDBFEAC25EF83AB392E022FA0525C42A73480A8F3A29D3ACC02F0960745D060614DE9072036DA>

Torres, A. (2019). Representa la industria del plástico más del 3% del PIB Nacional. *Revista Vector*, 1. Retrieved from Revista Vector.

Índice de Figuras

Ilustración 1 Modelo de intervención Fuente: (Cummings, 2010, pág. 282)	5
Ilustración 2 Gastos por Manejo de Stock Fuente: Propia.....	7
Ilustración 3 Importaciones Fuente Secundaria El Financiero: (Sánchez, 2018) Fuente Primaria: Secretaría de Energía y Braskem Idesa.....	7
Ilustración 4 Mapa de Producción de Plástico Fuente: (CamBioTec, 2018, pág. 16)	8
Ilustración 5 Economía Circular Fuente: (Europe, 2018, pág. 7)	9
Ilustración 6 Zone Strategic Fit Fuente: (Sunil Chopra, 2016, pág. 28).....	13
Ilustración 7 Inventario de Seguridad Fuente: (Sunil Chopra, 2016, pág. 315)	17
Ilustración 8 Ejemplo Forecast Fuente: (Takashi Tanizakia, 2018)	21
Ilustración 9 Datos Ventas Resina A (Fuente Propia)	24
Ilustración 10 Ventas Por Año Resina A (Fuente Propia)	24
Ilustración 11 Ventas Promedio Por Mes Resina A (Fuente Propia).....	25
Ilustración 12 Pronósticos Resina A (Fuente Propia)	25
Ilustración 13 Simple Exponential Smoothing Resina A (Fuente Propia)	26
Ilustración 14 Lead Time Histórico (Fuente Propia)	27
Ilustración 15 Costos Almacenamiento por HC (Fuente Propia)	27
Ilustración 16 Datos Para Calcular EOQ (Fuente Propia)	28
Ilustración 17 Economic Order Quantity (Fuente Propia).....	28
Ilustración 18 Gráfica EOQ (Fuente Propia)	29
Ilustración 19 Comportamiento Inventario (Fuente Propia).....	30
Ilustración 20 Modelo de Programación Lineal (Fuente Propia).....	31

Ilustración 21 Resultado Modelo de Programación Lineal (Fuente Propia).....	32
Ilustración 22 Progóstico Gráfica VAR (Fuente Propia).....	33
Ilustración 23 Progóstico Gráfica VAR (Software Orange Data Mining).....	33
Ilustración 24 Resultados Pronóstico VAR (Software Orange Data Mining)	33
Ilustración 25 Estacionalidad (Software Orange Data Mining).....	34
Ilustración 26 Resultado Pronóstico VAR (Fuente Propia).....	35
Ilustración 27 Gráfica Pronóstico VAR.....	35
Ilustración 28 Gráfica Pronóstico VAR (Fuente Propia).....	35
Ilustración 29 VSM Futuro ((Eloy León, Ruriko Aragaki, Lucero Mercado, Emir Martinez, Victor Prado, ITESO 2019)	38
Ilustración 30 Prospectiva de Implementación (Fuente Propia).....	41

Glosario

Resinas Plásticas: Polímeros de origen químico y orgánico que son materia prima de cualquier producto plástico. Se clasifican en termoplásticos y termo rígidos.

HC: Hopper Car, vagón de tren para ferrotolva de capacidad de 90 toneladas usada generalmente para transportar resinas plásticas a granel entre otros polímeros.

EOQ: Economic Order Quantity, cantidad de económica de orden.

Inventario: Bienes y materiales o productos de valor que pertenecen a una persona física o moral.

Abastecimiento: En el caso de la industria, se refiere al proceso de compra de materia prima, insumos, equipo y bienes para la transformación, para posteriormente ser vendidos.

Demanda: La cantidad de un bien o servicio solicitado por la población.

Optimización: Proceso en el cual se busca llegar al punto de mayor rendimiento en cuanto a costo, tiempo y productividad.

Inteligencia artificial: Es el desarrollo de los sistemas computacionales en el que estos adquieren capacidades de inteligencia humana, como el reconocimiento y la toma de decisiones.

Machine Learning: Motor de la inteligencia artificial, es el aprendizaje de los sistemas digitales mediante modelos y código que generan criterio y cierto nivel de inteligencia.

Industria 4.0: Es la etapa por la cual estamos pasando actualmente. Representada principalmente por la inteligencia artificial y la ciencia de datos, entre otros.

Forecasting: Es el proceso mediante el cual se reúnen datos pasados y presentes. Se crean modelos para pronosticar cierto valor en un tiempo futuro. Es un proceso fundamental en los negocios y la industria.

Lean Manufacturing: Es la manufactura esbelta, una filosofía japonesa que expresa principalmente la importancia de eliminar los *muda* (7 tipos de desperdicios).

VSM: Es el mapeo de procesos, flujos de información y materiales de cierta organización. Donde se detectan mejoras para hacer más eficiente el proceso e impactar de manera directa los pilares (rentabilidad, flujo de efectivo, margen de utilidad) de la compañía.

VAR: Auto Regresión Vectorial es un modelo estocástico para encontrar relaciones lineales entre series de tiempo.