

PONTIFICIA UNIVERSIDAD CATÓLICA DEL PERÚ

FACULTAD DE CIENCIAS E INGENIERIA



Propuesta de mejora en el planeamiento de la producción de botellas aplicando un MPS y pronósticos basados en Deep Learning en una empresa productiva y envasadora de agua en el Callao

TESIS PARA OPTAR EL TÍTULO INGENIERO INDUSTRIAL

AUTOR:

Jose Alberto Tupayachi Silva

ASESOR:

Eduardo Carbajal López

Lima, marzo de 2021

RESUMEN

En los últimos tres años el nivel de venta de agua embotellada para consumo humano en el Perú muestra un crecimiento en las ventas realizadas por las empresas productoras a los supermercados, bodegas, mercados y tiendas de conveniencias, esto se evidencia en el incremento del 3.9% de este sector productivo al cierre del 2017. La facturación de las grandes cadenas de supermercados a nivel nacional ha alcanzado los 14,000 000 PEN con un crecimiento del 5.3% respecto al año 2016. Esto demuestra que este sector económico está en crecimiento por el alto consumo de agua embotellada.

La presente empresa a analizar se dedica a la producción de agua embotellada de marca propia y de maquila para sus principales clientes: Cencosud Retail S.A. y Supermercados Peruanos S.A., empresa joven y mediana con 43 trabajadores en planilla presente en el ámbito nacional, de importante participación en el mercado, que a partir del 2017 ha experimentado un fuerte crecimiento tras la priorización de la producción del cliente Supermercados Peruanos S.A en la presente empresa. Sus productos cuentan con 69% de participación a nivel supermercados y en el 2018 presenta un posicionamiento en el mercado que se encuentra dentro del 10.4%, compartiendo el mercado nacional con grandes embotelladoras como AB InBev, CBC Perú, Arca Continental e ISM, cabe resaltar que su portafolio de productos en primer trimestre del 2019 presenta la siguiente composición: Bells 48.04%, Wong 12.32%, Metro 28.11%, Selfie 11.53%. Lo cual representa un crecimiento en ventas respecto al trimestre anterior del 8%, el cual se provee ser mantenido. El aumento de pedidos de la presentación de 2.5L Bells, ha ocasionado que la falta de una planeación en la demanda y el incorrecto manejo de almacenes comiencen a generar problemas incumplimiento de pedidos, en promedio 17% entre los cuales se encuentran el abastecimiento incompleto a clientes, penalidades por entrega tardía, roturas en el stock de producto terminado, baja calidad del producto entre otros.

El proceso crítico de la empresa se presenta en las áreas de producción y logística. En primer lugar, actualmente se utilizan metodologías para el cálculo de la demanda que no corresponden a la realidad, dado esto, la producción se basa en los pedidos actuales. No se mantiene ningún pronóstico de la demanda útil para producción y se carece de un sistema de inventarios. Como resultado se genera que se incurra en el incumplimiento de los pedidos, acrecentado por el incremento de las ventas en estos últimos años. Se puede observar, según datos del último trimestre del año 2019 la cantidad de agua tratada requerida en diferentes presentaciones ascendió a la cantidad de: 538312.2 L. En segundo lugar, se evidencia de que existe una cantidad considerable de mermas en distintas fases del proceso productivo, se observa que la utilización del agua tratada tiene una eficacia de aproximadamente el 40%, para las etapas de llenado, sellado y empaçado, existe un nivel de merma del 8.8% en promedio el cual comprende los recursos utilizados en cada etapa del proceso productivo respectivamente, dado al uso excesivo de las horas extras y de la utilización de los equipos hasta su falla . Se verifico que el número de horas extras por mes en el último trimestre del año 2019 alcanzo 628,5 horas extras en distintas posiciones, es decir se requiere de dichas horas adicionales para la culminación de los pedidos. Lo presente lleva a concluir que se debe plantear una reingeniería en la planificación, inventarios y ritmo de trabajo.

Se propondrá solucionar los problemas actuales de la empresa mediante la implementación de un MPS Master Production Schedule a partir del análisis de la demanda apoyado por la aplicación de herramientas de analítica de datos con el cual se pretende implementar un modelo de Deep Learning LTSM y consecuentemente desarrollar una correcta planificación de la producción, establecer un sistema de inventarios y aumentar la productividad a través del *TaktTime*.



DEDICATORIA

A mis padres y a mi hermano David, por todo el apoyo incondicional brindado a lo largo de estos años.

INDICE GENERAL

CAPITULO 1: MARCO TEORICO	1
1.1 Conceptos Básicos.	1
1.2 Herramientas para el análisis de mejora de procesos.	3
1.2.1 Los cinco porqués.	3
1.2.2 Diagrama de flujo.	4
1.2.3 Pareto.	5
1.2.4 Diagrama de pescado.	6
1.2.5 Matriz de multicriterio o Priorización.	6
1.2.7 Indicadores.	7
1.3 Metodología de mejora de procesos.	8
1.3.1 Takt Time.	8
1.3.2 Trabajo Estandarizado.	9
1.3.3 Características y Ventajas de los modelos de predicción de series de tiempo.	10
1.3.4 LSTM (<i>Long Short-Term Memory</i>).	11
1.3.5 Series de Tiempo.	16
1.3.6 Métrica RMSE.	19
1.3.7 <i>Master Production Scheduling</i> (MPS).	19
1.3.8 Stock de Seguridad y punto de reposición.	20
1.4 Casos de Estudio.	21
1.4.1. Red LSTM Predicción averías de maquinas.	21
1.4.2. Takt Time el corazón de la producción.	22
1.4.3 Análisis predictivo de actividades utilizando LSTM.	23
1.4.4 Análisis del punto de reorden en compañía XYZ.	26
CAPITULO 2: DESCRIPCION Y DIAGNOSTICO DE LA EMPRESA	28
2.1. Descripción de la empresa.	28
2.1.1. Unidades de Negocio.	28
2.1.2 Sector y actividad económica.	30
2.1.3 Perfil Organizacional.	30
2.1.5 Producto.	32

2.1.6 Clientes.	33
2.1.7 Proveedores.	34
2.1.8 Panorama y ventas actuales.	35
2.2. Diagnóstico de la situación actual.	35
2.2.1. Mapeo de Procesos.	36
2.2.2 Gestión de indicadores.	47
2.3 Diagrama de Pareto principales problemas:	56
2.2.4 Análisis Causa y Efecto.	57
2.2.5. Contramedidas.	64
CAPÍTULO 3. PROPUESTA DE MEJORA	66
3.1 Calendario desarrollo del proyecto.	66
3.2 Análisis Descriptivo.	68
3.2.1 Medidas de tendencia central.	69
3.2.2 Medidas dispersión.	69
3.3 Análisis Exploratorio Grafico.	70
3.3.1 Gráficos unidimensionales.	70
3.3.2 Boxplot, DotPlot e Histogramas.	71
3.4 Análisis series de tiempo.	73
3.4.1 Descomposición.	74
3.4.2 Estacionalidad.	74
3.5 Preparación de datos.	76
3.6 Modelado y Validación.	77
3.6.1 Arima.	78
3.6.2 Prophet.	84
3.6.3 LSTM.	88
3.7 Comparación de resultados.	96
3.8 Objetivos de la solución.	97
3.9 Diseño de la Solución.	98
3.10 Funcionamiento y utilización.	107
Capítulo 4: Evaluación técnica y económica	112
4.1 Evaluación técnica.	112
4.1.1 Evaluación técnica para el planificador de la demanda.	112
4.1.2 Evaluación técnica para establecimiento del modelo de pronósticos LSTM.	118
4.1.3 Evaluación técnica para establecimiento del sistema de inventarios.	119

4.2 Evaluación económica.	120
4.2.1 Evaluación económica para el desarrollo e implementación de la solución planteada.	120
4.3 Análisis Sensibilidad.	126
CONCLUSIONES	130
RECOMENDACIONES	132
BIBLIOGRAFÍA	133



INDICE ILUSTRACIONES:

Ilustración 1: Comparativa NN.....	3
Ilustración 2: Los 5 porqués	4
Ilustración 3: Simbología según norma ANSI.....	5
Ilustración 4: Ejemplo de diagrama de Pareto	5
Ilustración 5: Diagrama de Ishikawa	6
Ilustración 6: Indicador.....	8
Ilustración 7: RNN	11
Ilustración 8: Ejemplo de falla de las RNN	12
Ilustración 9: Modelo RNN	13
Ilustración 10: Modelo LSTM.....	13
Ilustración 11: Nomenclatura Usada en Modelo	13
Ilustración 12: LSTM célula.....	14
Ilustración 13: LSTM célula.....	14
Ilustración 14: LSTM célula.....	15
Ilustración 15: LSTM célula.....	15
Ilustración 16: Series de tiempo	18
Ilustración 17: MPS	19
Ilustración 18: Rotura de la demanda	20
Ilustración 19: Esquema de Trabajo	26
Ilustración 20: Centro de distribución Cencosud Santa Anita.....	29
Ilustración 21: Centro distribución SP.....	29
Ilustración 22: Logotipo marca.....	30
Ilustración 23: Organigrama.....	32
Ilustración 24: Paletizado de 20L Wong	33
Ilustración 25: Zona de Paletizado	34
Ilustración 26: Cartonería Cartones del Pacifico	35
Ilustración 27: Composición de ventas.....	35
Ilustración 28: Matriz macroproceso	37
Ilustración 29: Matriz de priorización	38
Ilustración 30: Nivel 1	39
Ilustración 31: Matriz nivel 3	40
Ilustración 32: Etiquetado de Metro 7 l.....	43
Ilustración 33: Línea 2 de llenado	46
Ilustración 34: Flujograma	47
Ilustración 35: Indicadores gráficos	48
Ilustración 36: Indicador 1.....	49
Ilustración 37: Utilización de los almacenes	49
Ilustración 38: Indicador 2.....	50
Ilustración 39: Indicador 3.....	53
Ilustración 40: Indicador 4.....	54
Ilustración 41: Indicador 5.....	55
Ilustración 42: Indicador 6.....	56
Ilustración 43: Diagrama de Pareto	57
Ilustración 44: Diagrama de relación.....	58
Ilustración 45: Diagrama de Ishikawa 1	59
Ilustración 46: Diagrama de Ishikawa 2	60
Ilustración 47: Diagramas de Ishikawa 3	61
Ilustración 48: Calendario Proyecto	67
Ilustración 49: Observaciones y Productos	68

Ilustración 50: Medidas de Tendencia central	69
Ilustración 51: Medidas de dispersión	69
Ilustración 52: Gráficos Unidimensionales	70
Ilustración 53: Boxplot	72
Ilustración 54: Histogramas	73
Ilustración 55: Descomposición Series de Tiempo	74
Ilustración 56: Criterios Estacionalidad	75
Ilustración 57: Preparación de datos	76
Ilustración 58: Reemplazo de datos	76
Ilustración 59: Datos Preparados	77
Ilustración 60: Corrida de datos	78
Ilustración 61: Lectura de datos-Arima	79
Ilustración 62: Separación de datos-Arima	79
Ilustración 63: Partición Testeo Entreno-Arima	79
Ilustración 64: Verificación partición-Arima	80
Ilustración 65: Modelo-Arima	80
Ilustración 66: Predicción-Arima	81
Ilustración 67: Calculo RMSE-Arima	81
Ilustración 68: Ploteo-Arima	81
Ilustración 69: Summary-Arima	82
Ilustración 70: Correlograma-Arima	83
Ilustración 71: Grafica Predicción-Arima	84
Ilustración 72: Librerías-Prophet	85
Ilustración 73: Verificación-Prophet	85
Ilustración 74: Preparación-Prophet	86
Ilustración 75: Configuración modelo - Prophet	86
Ilustración 76: Predicción - Prophet	86
Ilustración 77: Almacenamiento predicción - Prophet	87
Ilustración 78: RMSE - Prophet	87
Ilustración 79: Ploteo-Prophet	87
Ilustración 80: Grafica Predicción	88
Ilustración 81: Lectura de observaciones - LSTM	88
Ilustración 82: Partición de datos - LSTM	89
Ilustración 83: Transformación a Supervised - LSTM	89
Ilustración 84: Demostración transformación - LSTM	90
Ilustración 85: Diferenciación - LSTM	90
Ilustración 86: Invertir diferenciación - LSTM	90
Ilustración 87: Escalado - LSTM	91
Ilustración 88: Invertir Escalado - LSTM	91
Ilustración 89: Carga de modelo - LSTM	92
Ilustración 90: Dimensión modelo	92
Ilustración 91: Predicción y forma - LSTM	93
Ilustración 92: Transformación y partición - LSTM	93
Ilustración 93: Escalado de la diferenciación - LSTM	94
Ilustración 94: Almacenado de respuesta y RMSE - LSTM	94
Ilustración 95: Ploteo - LSTM	95
Ilustración 96: Corrida por días - LSTM	95
Ilustración 97: Grafica predicción - LSTM	96
Ilustración 98: Resultados	97
Ilustración 99: Situación actual	98
Ilustración 100: Mapa de proceso planteado	99
Ilustración 101: Arquitectura solución	99

Ilustración 102: Ventanas	100
Ilustración 103: Cuadros de control.....	100
Ilustración 104: Esquema planificador	102
Ilustración 105: Paletizado de botella 2.5L Bells	103
Ilustración 106: Takt Time	104
Ilustración 107: Esquema planificador	105
Ilustración 108: Ventana de configuración.....	107
Ilustración 109: Interfaz Planificador	108
Ilustración 110: Interfaz Materiales.....	109
Ilustración 111: Interfaz de configuración.....	110
Ilustración 112: Propuesta de flujo de trabajo	110
Ilustración 113: Sobre trabajo.....	115
Ilustración 114: Bells 2.5 l.....	120
Ilustración 115: Formula CAMP	122
Ilustración 116: Estimación beta rubro embotelladoras	122
Ilustración 117: Flujo de Caja económico	125
Ilustración 118: Graficas tornado	127
Ilustración 119: Simulacion Montecarlo	128
Ilustración 120:Correlacion sensibilidad Fuente: Elaboración propia.....	128
Ilustración 121:Variacion explicada	129



INDICE DE TABLAS:

Tabla 1:Matriz FACTIS	7
Tabla 2: Comparativa modelos.....	11
Tabla 3: Datos otorgados como Inputs.....	25
Tabla 4: Datos obtenidos.....	26
Tabla 5:Productos representativos y presentación.....	32
Tabla 6:Tabla de ponderaciones	38
Tabla 7: Tabla de indicadores.....	48
Tabla 8:Valores Calculados según costos y PV	57
Tabla 9:Confrontacion de factores	63
Tabla 10:Confrontación de factores	63
Tabla 11:5 porqués	63
Tabla 12:Listado propuestas.....	64
Tabla 13:Criterios de selección	65
Tabla 14:Matriz FACTIS	65
Tabla 15:FACTIS prioridades	65
Tabla 16: Stock de seguridad.....	103
Tabla 17: Calculo de Punto de Pedido.....	106
Tabla 18: Resumen evaluación. técnica	112
Tabla 19:Horas extras pre-mejora	113
Tabla 20:Horas extras post-mejora.....	114
Tabla 21: HE Comparativa	114
Tabla 22: Mermas comparativa	116
Tabla 23: Incidencia pre-mejora.....	117
Tabla 24: Incidencias post-mejora.....	117
Tabla 25: Comparativas Incidencias.....	118
Tabla 26: Comparativa pronostico	118
Tabla 27: Inventarios mejora comparativa	119
Tabla 28: Precio venta y beneficios.....	119
Tabla 29: Costo mano obra.....	121
Tabla 30: Ahorro Mensual contramedidas	122
Tabla 31: CAMP Costo Capital.....	124
Tabla 32: Flujo Caja económico trimestral	124
Tabla 33:Indicadores Económicos.....	125
Tabla 34: Análisis de sensibilidad - parámetros.....	126
Tabla 35: Análisis tornado.....	127

INDICE DE ECUACIONES:

Ecuación 1:Takt time formula	9
Ecuación 2: Descomposición Aditiva.....	17
Ecuación 3: Descomposición Multiplicativa	17
Ecuación 4 Transformación.....	18
Ecuación 5 Descomposición Pseudo-aditiva	18
Ecuación 6: RMSE	19
Ecuación 7: Formulas SS.....	21
Ecuación 8: Modelo Matemático MPS.....	101
Ecuación 9: CAMP.....	122
Ecuación 10:Apalancamiento Beta.....	123



CAPITULO 1: MARCO TEORICO

Se definirán los distintos términos utilizados en la empresa en estudio, las herramientas de diagnóstico, casos de estudio, y las metodologías de mejora.

1.1 Conceptos Básicos.

En el presente acápite se definirá la terminología usada en la empresa y en la presente tesis.

a) Agua de Mesa embotellada: Este término hace referencia al agua potable al cual se le ha sustraído un porcentaje cercano a la totalidad de los minerales que se encuentran en el agua potable el cual posteriormente tras efectuarse el proceso productivo y convertirse en agua tratada es envasada en botellas/bidones/cajas (bolsa metálica) y agrupada en paquetes según su presentación. Es puesta en venta minoritariamente bajo la marca Selfie y maquilada para las cadenas de Supermercados Peruanos y Cencosud *Retail*.

b) Ozono: Es una molécula formada por 3 átomos de oxígeno, la cual se separa a través de la aplicación de una gran carga eléctrica generando que el doble enlace de oxígeno, forma estable O_2 , se destruya dando 2 átomos sueltos los cuales se recombinan en O_3 generando así ozono. Debido a que este compuesto es inestable es producido en planta a través del oxígeno en botellas de $10m^3$ que pasa mediante electrodos al cual es aplicado un voltaje establecido. Cabe resaltar que dicho compuesto es oxidante y cuenta con una alta toxicidad, dado esto, es controlado frecuentemente. Dicha característica oxidante contiene extraordinarias propiedades antimicrobianas, desodorantes y de eliminación de distritos compuestos o agentes químicos mediante la atracción de electrones de otras moléculas a las que oxida y desestabiliza hasta su destrucción, si se aplica la concentración y el tiempo necesario para dicho fin.

c) UV: La luz ultra violeta permite una inactivación rápida y eficiente de los patógenos. Las bacterias, virus y protozoarios son expuestos a longitudes de onda que funcionan como germicidas

evitando su reproducción. Se requiere de un tiempo de exposición breve el presente proceso no genera desechos y tiene como beneficio mantener la calidad del agua, tanto física como química después de dicho tratamiento.

d) Osmosis Inversa: Se define como osmosis inversa al proceso de purificación mediante el cual se utiliza una membrana semi-permeable con la finalidad de la eliminación de iones, moléculas y partículas del agua potable. Esto es posible tras vencer la presión osmótica, la cual se define como la propiedad coligativa que es generada por el delta de potencial químico del solvente, como resultado se tiene una disolución en el lado presurizado conocido como residuos y el solvente puro pasara a los tanques de acero inoxidable, siendo esta el agua tratada.

e) Machine Learning: Se define como machine Learning el conjunto de algoritmos que construyen un modelo matemático basado en la información conocida y observaciones de entreno, con la finalidad de realizar predicciones o decisiones sin estar explícitamente programado para realizar la tarea.

f) Deep Learning: Se define al Deep Learning (Red Neuronal) como una clase de algoritmos perteneciente al Machine Learning el cual usa múltiples capas para realizar la abstracción de la información, con la finalidad de asimilar los patrones de los datos y procesar la información logrando así la solución del modelo.

g) RNN: Red neuronal recurrente es una clase de red neuronal en el cual, las conexiones entre los nodos son dirigidos por un grafo junto a una secuencia temporal esto permite comportamientos individuales siguiendo una tendencia histórica.

h) Red neuronal recursiva: Red que cual se ajusta a problemas de clasificación, procesamiento de imágenes y pronósticos, este último será la aplicación a la empresa en estudio.

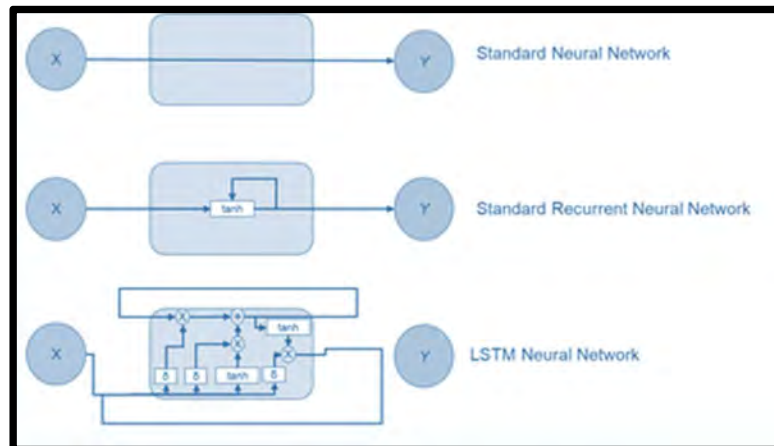


Ilustración 1: Comparativa NN

Fuente: Jose Ignacio Garzón

1.2 Herramientas para el análisis de mejora de procesos.

Con la finalidad del diagnóstico de la problemática actual de la empresa se ha elegido las siguientes herramientas.

1.2.1 Los cinco porqués.

Según distintos autores que analizan la técnica planteada por Sakichi Toyoda, requiere realizar hasta un numero de cinco veces la pregunta ¿Por qué? con la finalidad de encontrar la causa de la hipótesis planteada que luego se analizara, se requiere de experticia para resolver correctamente el problema y esto no es posible sin encontrar la causa raíz, con lo cual se podrá tomar planes futuros para evitar que estos se repitan.



Ilustración 2: Los 5 porqués

Fuente: Lean Manufacturing hoy

1.2.2 Diagrama de flujo.

Los diagramas de flujo requieren la utilización de símbolos con la finalidad de representar actividades con las conexiones que tiene los ingresos y salidas del proceso. Estos permiten conocer las falencias para lograr la optimización de procesos, los cuales serán utilizados como punto de partida para comprender la secuencia de los procesos. La norma que se utiliza para realizar los flujogramas es ANSI perteneciente a la *American National Standard Institute* que tiene como finalidad la estandarización de los gráficos y formas a utilizar. Para la presente tesis se utilizará dicha norma y la simbología que se observa en la presente ilustración.

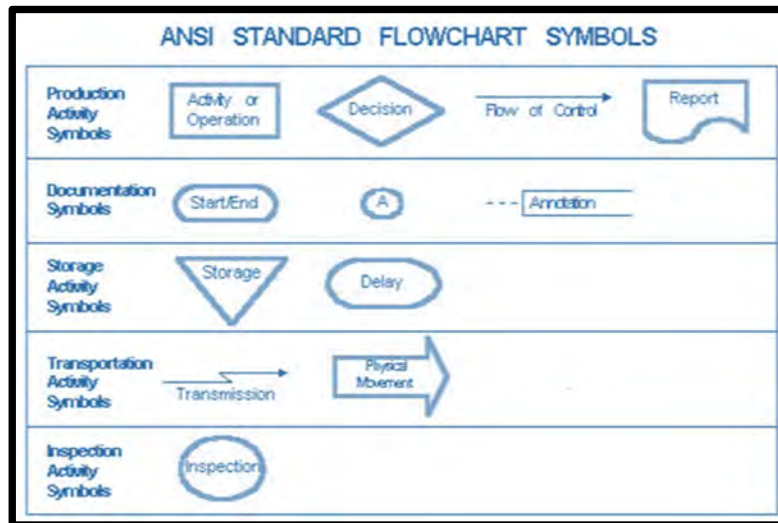


Ilustración 3: Simbología según norma ANSI

Fuente: American National Standards Institute

1.2.3 Pareto.

El diagrama de Pareto nos permite de una manera eficaz realizar un análisis de ocurrencia, en donde el 80% de los problemas totales se deben usualmente a tan solo el 20% de las causas, dado esto se debe comenzar por solucionar los pequeños detalles que puedan estar ligados a estos últimos. Se ordenarán las causas de mayor a menor según la cantidad de problemas y se debe elegir el grupo que constituya el porcentaje acumulado del 80% del total el cual será nombrado categoría A, sucesivamente B y C.




Ilustración 4: Ejemplo de diagrama de Pareto

Fuente: Minitab

1.2.4 Diagrama de pescado.

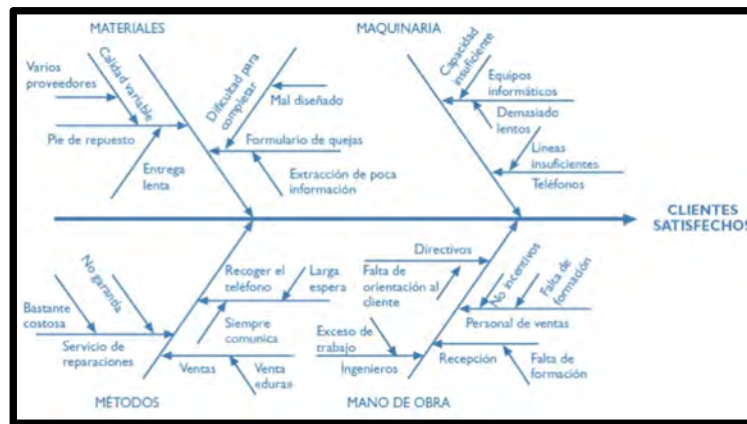


Ilustración 5: Diagrama de Ishikawa

Fuente: Ivan Martinez lima

Se definirá al diagrama de Ishikawa como un diagrama de causa efecto sistemático y organizado, el cual busca determinar el porqué del problema. Dado esto, se elige un número significativo de factores para cada problema, el cual parte del enunciado y esto otorga el inicio para mostrar las causas e identificar el origen del problema y eliminarlo. Las causas primarias mencionadas son las principales a utilizarse, pero dependiendo de la necesidad del diagnóstico se eliminará las que se consideren necesarias, es recomendable realizar dicho análisis con el personal operativo y jefes del proceso quienes se encuentran en el foco de la problemática dado que aportarán información relevante para el diagnóstico.

1.2.5 Matriz de multicriterio o Priorización.

La presente herramienta se usa para la toma de decisiones según distintos factores no homogenizados, los cuales intervienen en el proceso de fabricación del agua embotellada. Se definen los siguientes seis pasos para la elaboración de la matriz multicriterio o de priorización.

Paso 1: Listado de los factores que serán puestos a priorización

Paso 2: Identificar según qué criterio se priorizará.

Paso 3: Ponderar criterios según relevancia.

Paso 4: Construcción de matriz de bonificación.

Paso 5: Fijación de criterios de bonificación.

Paso 6: Valorización de factores y los que obtienen el orden de prioridad.

1.2.6 Matriz FACTIS.

Herramienta para tomar decisiones el cual utiliza condiciones y criterios de selección por cada posibilidad de solución potencial para un determinado problema, el nombre FACTIS proviene de los criterios de selección. Primero se bonificará según el criterio de selección para posteriormente sumar la cantidad de bonificación por el factor de ponderación previamente establecido, así multiplicar el ítem por el factor de ponderación.

	CRITERIOS DE SELECCION	FACTOR DE PONDERACION
F	Facilidad para solucionarlo 1.Muy difícil 2. Difícil 3. Fácil	6
A	Afecta a otras áreas su implementación 1.Si 2. Algo 3. Nada	1
C	Mejora la calidad 1.Poco 2. Medio 3. Mucho	3
T	Tiempo que implica solucionarlo 1.Largo 2. Medio 3. Corto	5
I	Requiere inversión 1.Alta 2. Media 3. Poca	4
S	Mejora la seguridad 1.Poco 2. Medio 3. Mucho	2

Tabla 1:Matriz FACTIS

Fuente: Juan Cruz

1.2.7 Indicadores.

La finalidad de los indicadores es describir el comportamiento de diferentes variables ya sea por cuantificación directa o comparación. Con la finalidad de tener una visión de la evolución del proceso. Con lo cual es necesario la buena selección, identificación y formulación debida de los indicadores que deben cumplir con las siguientes características:

-Representatividad: Debe representar la magnitud que se desea medir.

-Sensibilidad: Debe de ser sensible al cambio de magnitud de las variables.

-Rentabilidad: El beneficio del uso debe compensar su esfuerzo de elaboración.

-Fiabilidad: Debe de estar basado en datos obtenidos de mediciones objetivas.

-Relatividad en el tiempo: Debe determinarse en una escala de tiempo que permita realizar comparaciones.

Se manejará los siguientes colores, verde significa que se logró cumplir con la meta y anaranjado que esta fuera de la región cercana a la meta; sin embargo, no es un problema que requiere de inmediata corrección, finalmente rojo indica que no se cumplió con la meta.

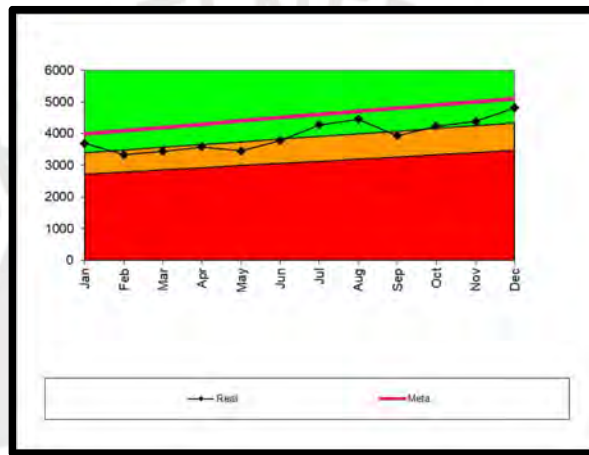


Ilustración 6: Indicador

Fuente: Elaboración propia

1.3 Metodología de mejora de procesos.

Las metodologías que se utilizarán para la mejora de procesos están basadas en las optimizaciones de los procesos y enfocadas en las actividades que agregan valor al producto, dado que se enfocan en eliminar el mal uso o desperdicio de recursos que no agregan valor al producto que el cliente final recibe.

1.3.1 Takt Time.

El tiempo *takt* es el ritmo o la rapidez con la cual el proceso debe realizarse con la finalidad de cumplir con la demanda. El beneficio es alinear los tiempos internos de producción con los tiempos de demanda del cliente.

$$\text{Tiempo Tack} = \frac{\text{Tiempo disponible de Prod.}}{\text{Demanda del cliente}}$$

Ecuación 1: Takt time formula

Fuente: SIP PUCP

1.3.2 Trabajo Estandarizado.

El estándar define una sucesión ordenada de pasos y tiempos establecidos para cada actividad del proceso con la finalidad de reducir la variabilidad de tiempos de trabajo. Los pasos para realizar el trabajo de manera estándar deberán ser visuales y entendible por el operario con la finalidad de acompañar su desempeño, que se verá reflejado en la reducción de las curvas de aprendizaje en un 75%, con un incremento de 10% a 25% de la efectividad y productividad, y principalmente la flexibilidad operativa para responder a la cambiante demanda. (Locher, 2008)

Se aplicará los siguientes pasos por cada proceso. La metodología que desarrollará será la siguiente:

- Paso 1. Identificación de las actividades principales de cada área.
- Paso 2. Priorización de las actividades.
- Paso 3. Identificación de los equipos/operarios que desarrollan el trabajo estándar.
- Paso 4. Mapeo los procesos.
- Paso 5. Obtención soluciones.
- Paso 6. Documentación en formato establecidos simples y visuales.
- Paso 7. Entrenamiento de los operarios en el trabajo estándar (Tiempos).
- Paso 8. Mantener las nuevas medidas establecidas y controlar la efectividad y mejora continua.

1.3.3 Características y Ventajas de los modelos de predicción de series de tiempo.

Se analizarán 3 modelos en la presente tesis el modelo Arima, el modelo Prophet y el modelo LSTM. Entre las cualidades del modelo Arima se encuentra que es de fácil entendimiento y es ampliamente conocido cuando se pronostica la demanda. Sin embargo, cuando se comienza a trabajar con una gran cantidad de datos (previsto en el futuro a corto plazo de la empresa) dicho modelo ya no se desempeñaría correctamente ya que han sido configurados para un periodo de tiempo específico. Dado que se pretende elaborar un aplicativo sería necesario la modificación y reajustes necesarios por una persona capacitada en temas estadísticos. La utilización del auto Arima nos permite eliminar hasta cierto punto dicha necesidad, pero la evaluación de dicho parámetro requiere un tiempo considerable y es importante resaltar, que no está exento a fallos y se requeriría de una supervisión continua y reajuste ya que es preferible para series de tiempo con un numero de observaciones moderadas.

Entre las cualidades del modelo Prophet para el pronóstico de series de tiempos se encuentran: Está basado en el modelo aditivos de series de tiempo, este puede incluir tendencias no lineares además de distintas estacionalidades. Dicho modelo se desempeña adecuadamente en series de tiempo que tengan fuerte estacionalidad y varias estacionalidades históricas, además de manejar los datos extremos adecuadamente. Además, entre una de sus ventajas se encuentra su facilidad de uso y ajuste, como también su rapidez de procesamiento y la garantía de estar implementado en Facebook para el planeamiento y aplicación de metas. En la presente empresa esto permitiría que los pronósticos sean obtenidos con facilidad y rapidez además de ser fácilmente automatizable para la utilización en aplicativos de planeamiento de la demanda.

Por último, nuestro tercer modelo en comparación es el modelo basado Deep Learning específicamente la red LSTM, dicho modelo posee una gran capacidad de predicción y facilidad de ser automatizable, además de ser bueno en el manejo de patrones no lineales como el que se puede observar en la tendencia de la demanda. Sin embargo, su funcionamiento interno es complicado de entender. Posiblemente este

se situó como una de las mejores opciones para la empresa debido a que el incremento de observaciones mejoré su funcionamiento. Esto deberá ser verificado tras el funcionamiento de los 3 modelos a tratar, con la finalidad de su implementación en el presente planificador de producción.

ARIMA	<ul style="list-style-type: none"> · Easy to understand · Fits historical data well · Forecasts unbiased 	<ul style="list-style-type: none"> · Sensitive to outliers · Small forecast range
Prophet	<ul style="list-style-type: none"> · Easy to understand · Analyst in the loop · Data efficient · Fast 	<ul style="list-style-type: none"> · Sensitive to compounding seasonality · Required data format
Deep Learning <i>Neural Networks</i> <i>LSTM</i> <i>Transfer Learning</i>	<ul style="list-style-type: none"> · Can take in many complex variables · Finds nonlinear patterns · Strong predictions · Easy to automate 	<ul style="list-style-type: none"> · Difficult to understand · Requires a lot of data

Tabla 2: Comparativa modelos

Fuente: Medium

1.3.4 LSTM (Long Short-Term Memory).

“Los seres humanos no empiezan a pensar de la nada cada segundo, es posible para las personas entender cada una de las palabras de esta tesis basandose en el entendimiento de las palabras previas, no se olvida todo para empezar a pensar de la nada de nuevo. los pensamientos tienen persistencia.” – (Colah, 2018). Se ha evidenciado que las redes neuronales “*Deep Learning*” carecen de las capacidades para aprender eventos pasado, debido a esto un subtipo de estas redes neuronales resuelven el problema las “redes neuronales recurrentes” o RNN en inglés.




Ilustración 7: RNN

Fuente: Christopher Olah

Es decir las RNN podrían permitir conectar información previa a la presente tarea, sin embargo existe situaciones en donde solo se necesita mirar la información reciente y no todo el conjunto de datos ,entiéndase reciente no solo a información anterior inmediata, sino a un conjunto de datos recientes los cuales podrían ser variables como por ejemplo la estacionalidad por temporadas o las tendencias en los precios de las acciones de la bolsa de valores para así realizar la presente tarea, se hondara más en el presente ejemplo. Considérese que se trata de predecir la última palabra en el texto “yo crecí en Francia...” yo hablo “.....” La reciente información sugiere que la siguiente palabra es probablemente es el nombre del lenguaje, pero si queremos acortar las posibilidades a que lenguaje necesitamos del contexto de Francia que está un poco más atrás. Es completamente posible que el espacio mediante el cual la información relevante y el punto donde esta necesariamente se convierta muy grande.




Ilustración 8: Ejemplo de falla de las RNN

Fuente: Christopher Olah

Desafortunadamente si este espacio aumenta las RNN no permiten aprender a conectar la información y es ahí su limitación. Aquí entran las “*LSTM's*” un tipo muy especial de RNN el cual trabaja de una mejor forma que la versión estándar las RNN. Capaz de aprender de dependencia de largo tiempo dando mayor peso a los eventos recientes. Las *LSTM's* están explícitamente diseñadas para evitar el problema de las dependencias de “*Long-Term*”. Recordar la información por largos periodos de tiempo es prácticamente su comportamiento por defecto y no algo que es difícil aprender. Todas las RNN tiene forma de una cadena de módulos repetitivos de la red neuronal. En resumen, las RNN tendrán una simple estructura la cual es una sola capa tanh como se observa en la ilustración.

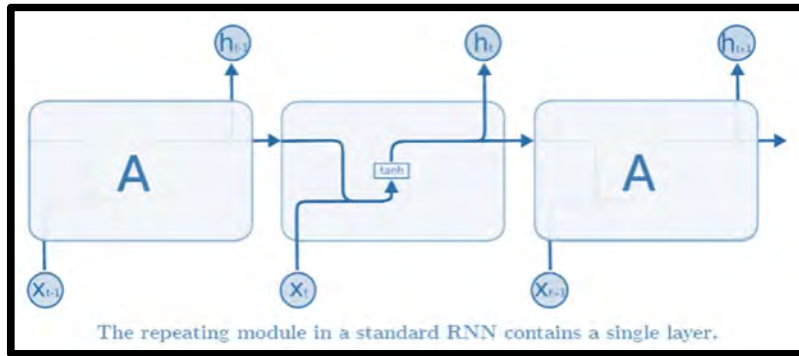


Ilustración 9: Modelo RNN

Fuente: Paper investigado

Las LSTM también tienen una estructura tipo cadena, pero el módulo repetitivo tiene una estructura diferente. En vez de estar compuesto por una sola capa neural tiene 4 interactuando de una manera especial.

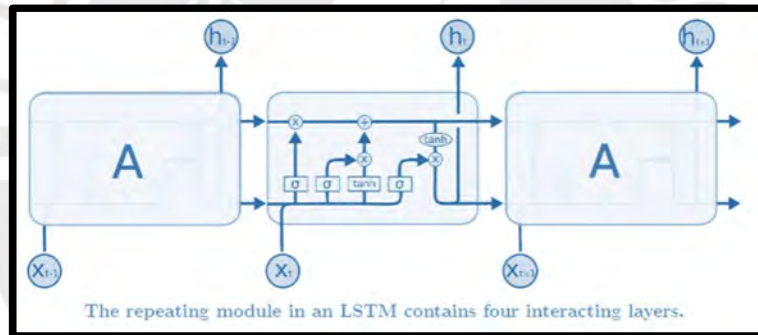


Ilustración 10: Modelo LSTM

Fuente: Paper Investigado




Ilustración 11: Nomenclatura Usada en Modelo

Fuente: Paper Investigado

En el presente diagrama cada línea alberga un vector entero desde el nodo de salida a un nodo a la entrada de los otros. Los círculos representan lo que ocurre en cada set, como por ejemplo la suma de vectores,

mientras que las cajas son capas de las redes neuronales aprendidas, las líneas que se juntan denotan concatenación mientras que la línea que se separa denota que su contenido está siendo copiado y las copias van a diferentes lugares. Se usará la siguiente notación:




Ilustración 12: LSTM célula

Fuente: Paper Investigado

El primer paso en la LSTM es decidir qué información se eliminará de la célula estado. Esta decisión es hecha por una capa sigmoide la cual es la capa de la “puerta de olvido” esto se ve en h_{t-1} , X_t y en las salidas un numero entre 0 y 1 para cada número en la célula estado C_{t-1} . Uno representa “completamente esto” mientras que un 0 “elimina completamente esto”. Se hace referencia al ejemplo del modelo de entreno del lenguaje el cual trata de predecir la siguiente palabra basada en todos los anteriores, en tal problema, la célula estado podría incluir el género del presente sujeto. Así el correcto sujeto aparecería, en el ejemplo del idioma, podrá ser usado, es decir según el género. Cuando veamos un nuevo sujeto queremos olvidar el género del anterior sujeto.




Ilustración 13: LSTM célula

Fuente: Paper Investigado

El siguiente paso es decidir que información iremos a almacenar en la “célula estado”. El cual se compone de 2 partes. Primero la capa sigmoide, el cual es la capa de “la puerta de ingreso” decide cual valor actualizara. Luego una capa tanh crea un vector de un nuevo conjunto de valores candidatos \tilde{C}_t lo cual podría ser adherido. En el siguiente paso se combinarán ambos para así actualizar dicho estado. En el ejemplo del lenguaje si quisiéramos adherir género del nuevo sujeto a la célula estado se debería remplazar el antiguo el cual estamos olvidando




Ilustración 14: LSTM célula

Fuente: Paper investigado

Ahora es tiempo de actualizar la antigua “Célula estado” C_{t-1} en una nueva “célula estado” C_t los previos pasos ya decidieron que hacer, solamente necesitamos realmente hacerlo. Se multiplica el “estado viejo” por f_t olvidando así las cosas que decidimos olvidar anteriormente, luego añadimos $i_t * \tilde{C}_t$, estos nuevos valores candidatos, escalados por cuanto más hemos decidido actualizar cada valor estado. En el caso del modelo del lenguaje, realmente eliminaríamos la información sobre el género del anterior sujeto y se añadiría la información tal como fue dictaminado en los pasos previos.




Ilustración 15: LSTM célula

Fuente: Paper investigado

Finalmente necesitamos decidir qué es lo que saldrá. Esta salida estará basada en nuestra “célula estado” pero será una versión filtrada. Primero, se correrá una capa sigmoide el cual decide que partes de la “célula estado” conformaran nuestra salida. Luego, se pondrá la “célula estado” a través de un tanh (para empujar los valores a ser entre -1 y 1) y multiplicarlos por la salida de la puerta sigmoide, con la finalidad de que solo sea nuestra salida las partes que sé decida que sean. Para el ejemplo del modelo del leguaje desde que solo vio un sujeto puede que quiera dar como salida la información relevante a un verbo, en caso que eso es lo que venga. Como ejemplo: El sujeto es singular o plural, con lo cual sabremos a que forma de verbo debería ser conjugada si es lo que continua.

1.3.5 Series de Tiempo.

Secuencia de puntos de datos organizados en orden de tiempo. Para ser considerada como tal la secuencia captura las observaciones en espacios de tiempos iguales. Estas son usadas mayormente en los pronósticos económicos, análisis de bolsa de valores, Detección de anomalías y Pronostico y planeamiento de la demanda lo cual se verá aplicado en la presente tesis. Específicamente en la realización del estudio exploratorio con los diferentes patrones detrás de la demanda de la empresa.

Componentes de las series de tiempo:

Una serie de tiempo cuenta con los siguientes 3 componentes:

a) Tendencia: Dirección de largo tiempo

Esta captura la dirección general de las series de tiempo como ejemplo se puede dar al crecimiento de trabajo año tras año sin tomar en cuenta las fluctuaciones estacionales. Esta tendencia puede ser incremental, decreciente o constante y de distintas maneras (lineal, exponencial, etc.)

b) Estacionalidad: Comportamiento Periódico

La estacionalidad captura el efecto que ocurre con una específica frecuencia que puede ser causada por distintos factores, como las fluctuaciones del clima causada por el tiempo del año, el comienzo o inicio temporada escolar, eventos de calendarios entre otros.

c) Residuales: Fluctuaciones irregulares

Los residuales son fluctuaciones aleatorias las cuales quedan tras la remoción de la tendencia y la estacionalidad, por lo cual no se debería observar ningún patrón de tendencia o temporalidad en el residual es decir fluctuaciones de corto tiempo tras la descomposición.

Modelos de descomposición:

a) Descomposición aditiva:

Los modelos aditivos se asumen que la serie de tiempo observada es la suma de sus componentes. Estos modelos son usados cuando las magnitudes de la estacionalidad y los valores residuales son independientes de la tendencia.

$$\textit{Observation} = \textit{Trend} + \textit{Seasonality} + \textit{Residual}$$

Ecuación 2: Descomposición Aditiva

Fuente: Estadística PUCP

b) Descomposición multiplicativa:

Los modelos multiplicativos asumen que la serie de tiempo observada es el producto de sus componentes

$$\textit{Observation} = \textit{Trend} * \textit{Seasonality} * \textit{Residual}$$

Ecuación 3: Descomposición Multiplicativa

Fuente: Estadística PUCP

Es posible la transformación de un modelo multiplicativo a aditivo aplicando la siguiente transformación

$$\log(\text{Time} * \text{Seasonality} * \text{Residual}) = \log(\text{Time}) + \log(\text{Seasonality}) + \log(\text{Residual})$$

Ecuación 4 Transformación

Fuente: Estadística PUCP

Los modelos multiplicativos son usados cuando las magnitudes de la estacionalidad y los valores residuales fluctúan con una tendencia.

c) Descomposición pseudoadditiva:

Los modelos pseudoadditivos combinan elementos de ambos de los modelos mencionados previamente. Son de gran utilidad cuándo los valores de las series de tiempo están cerca o son iguales al 0 y se requiere un modelo multiplicativo. Dichos modelos pueden ser escritos como

$$Qt = Tt + Tt(St - 1) + T(Rt - 1) = Tt(St + Rt - 1)$$

Ecuación 5 Descomposición Pseudo-aditiva

Fuente: Estadística PUCP

Serie estacionaria / No estacionaria:

Se define como una serie de tiempo estacionario cuando no se presentan cambios en la media es decir presenta una media constante (sin tendencia), Tiene varianza constante (no tiene heterocedasticidad), Tiene una estructura de autocorrelación constante y no tiene componente periódico (Sin estacionalidad)



Ilustración 16: Series de tiempo

Fuente: Curso Series de Tiempo

1.3.6 Métrica RMSE.

La presente métrica RMSE (Error cuadrático medio) permitirá conocer el error (diferencia) entre 2 conjuntos de datos. En los modelos a comparar para la presente tesis se comparará los datos reales contra a los predichos. Así se permitirá conocer la precisión de cada uno de los modelos frente a un mismo set de datos en este caso la demanda pronosticada de la empresa.

$$\sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2}$$

Ecuación 6: RMSE

Fuente: Planificación Curso PUCP

1.3.7 Master Production Scheduling (MPS).

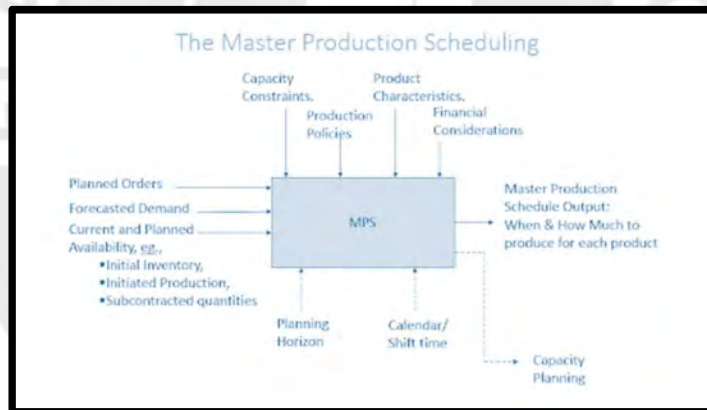


Ilustración 17: MPS

Fuente: OptiProERP

El Master Production Schedule o MPS por sus siglas en inglés es un plan de producción que toma en cuenta el periodo o lead time, el inventario, las capacidades de producción, la demanda pronosticada, y otros factores observables en la ilustración. El presente MPS es realizado en el área de producción con la finalidad de optimizar la cadena productiva e identificar cuellos de botellas, anticipar pedidos y productos terminados. El MPS es necesario ya que esta herramienta es el principal modelador de la

actividad de una empresa, su precisión y fiabilidad afecta principalmente los beneficios económicos de la empresa, comúnmente son presentados mediante un software, donde el responsable de producción optimiza ciertos parámetros para así realizar la programación de la información.

Cabe mencionar que el MPS no maneja cada aspecto de la producción sino componentes claves de esta. En resumen, el MPS transforma la demanda del cliente en un plan inteligente de ordenes de producción y esta herramienta permite al negocio evitar roturas de stock, costos imprevistos, programaciones de último minuto y uso-definición innecesaria de recursos.

1.3.8 Stock de Seguridad y punto de reposición.

La finalidad del stock de seguridad es mantener un nivel extra de inventario con la finalidad de enfrentar los cambios en la demanda, suministros y percances en producción. Esto permite reducir la incertidumbre que se produce en la demanda de los productos. Esto es de vital importancia ya que permite satisfacer al cliente a pesar de que la empresa se encuentre con percances en la producción o abastecimiento es decir permite contrarrestar las roturas de stock que pueden ser generadas por la imprevista evolución de la demanda.

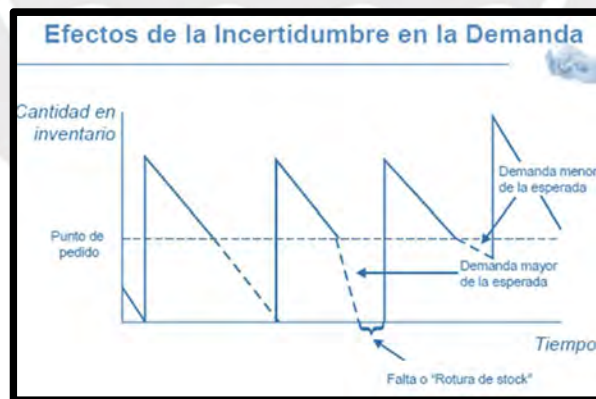


Ilustración 18: Rotura de la demanda

Fuente: Logística PUCP

Este presente calculo toma en consideración parámetros como el nivel de servicio del cliente NSC, el lead time de las ordenes de pedido, la varianza de la demanda, la demanda media y la varianza del lead time con la finalidad de calcular dicho valor.

$$NSC = 1 - \frac{\text{Cantidad unidades agotadas anualmente}}{\text{Demanda anual total}}$$

$$SS = k * \sigma'$$

$$\sigma'_d = \sqrt{LT * \sigma^2_{demandada} + DemandaMedia^2 * \sigma^2_{LT}}$$

Ecuación 7: Formulas SS

Fuente: Logística PUCP

Con la finalidad de hallar el punto de pedido, el cual será requerido para la mantención correcta de los insumos, se basará en los componentes hallados generando así la presente formula $PP = D * LT + SS$. En el cual “D” hará referencia a la demanda semanal el “LT” al *lead time*, tiempo el cual demorará dichas unidades para que lleguen a la empresa y el SS el stock de seguridad que la empresa deberá mantener en almacenes.

1.4 Casos de Estudio.

Se presentarán los siguientes casos de uso los cuales son relevantes para el desarrollo de la presente tesis

1.4.1. Red LSTM Predicción averías de máquinas.

Según (GARZÓN, 2018) se menciona que conceptos tales como el Deep Learning aplicados por parte de GFT Technologies SE empresa consultora en el rubro de IT enfocado en la administración y negocios demuestran que su aplicación no solo está en el clustering de imágenes, reconocimiento de artículos y apoyo al sector financiero (antifraudes, establecimiento de precios, desarrollo de líneas de negocio y minimización del riesgo) sino que dichos datos de serie cronológicos realizan un importante trabajo en estos problemas, lo que nos demuestra la efectividad y habilidad de estas redes neuronales para procesar información del tipo “series de tiempo” para el pronósticos de la demanda. Especialmente las redes

LSTM aprenden correctamente dichos patrones los que los hace ideales para dichas funciones. Los conceptos junto con las tecnologías emergentes como el internet de las cosas en donde el mantenimiento predictivo se basa en los datos de serie cronológicos. Entre los conceptos de mantenimiento de averías resalta la gestión de fallos: una correcta predicción, clustering y diagnóstico. Del cual se puede generar un esquema de planificación del tipo cuadro de fechas, una cronología de mantenimiento predictivo para un artefacto o aglomerado de artefactos (computadores, grupos electrógenos y maquinas fabriles) los cuales registran un conjunto de lecturas de datos a través del tiempo. La manera de operar de estos algoritmos es mediante el registro de una de un conglomerado de datos a través del tiempo y utiliza los datos con la finalidad de descubrir los patronos que permitan predecir las averías o comportamientos anómalos. En el caso de la empresa a la cual GFT realizo una consultoría, estudio e implementación de esta mejora sustancial. En el cual tras realizar las predicciones se utilizó dicha información para activar las medidas correctivas y así evitar fallas en los sistemas productivos. Dicho esto, se identifica a las redes LSTM como un tipo de redes recurrente que tiene como característica base las RNN, la información puede mantenerse introduciendo bucles en el diagrama de red, en resumen, se puede recordar estados anteriores y utilizar dicha data o información para predecir cual será el siguiente. Dado esto es una cualidad que hace de que estas redes las LSTM adecuadas para manejar series de tiempo. mientras las redes recurrentes estándares RNN pueden modelar dependencias de corto plazo (relaciones cercanas a la serie de tiempo), las LSTM permiten aprender de dependencias de largo plazo por lo que podría considerarse que cuentan con una memoria de largo y corto plazo.

1.4.2. Takt Time el corazón de la producción.

En el trabajo, la disciplina deberá otorgar motivación para mejorar la productividad de las empresas. Para lograr esto la herramienta conocida como el *Takt time*, la cual permite mejorar los procesos productivos convirtiéndose en una buena estrategia para controlar y gestionar la información de los ambientes de manufactura y fabriles con orientación a brindar lo necesario para alcanzar los tiempos de entrega al

mismo tiempo que optimiza los recursos productivos .Se verifico que la aplicación de estas herramientas en la empresa “X” permitió diseñar , construir y realizar validaciones en su planta. La herramienta utilizada genera resultados favorables en tiempo real de confección de ropa de mujeres, al verificar que el módulo de trabajo de 6 operarios tuvo una mayor eficiencia al implementar la herramientas que los módulos que no emplearon, y que la producción de los lotes paso de un 65% a un 85% siendo así más eficientes en la producción. Como consecuente se logró confeccionar un 85% de prendas dentro de lo programado para la producción mientras antes era de solo un 65%. Es decir, el *Takt Time* permite una rápida respuesta a las implicancias que se presenten en producción, debido a esto se convierte en una herramienta infalible para la programación de la producción (Alvarez, 2018).

1.4.3 Análisis predictivo de actividades utilizando LSTM.

En el presente mundo globalizado de hoy metodologías como machine Learning y las redes 5G permitirán la intercomunicación entre máquina y persona. Es en este contexto que el BPM *Business Process Management* es considerado un componente clave para manejar el ciclo de vida de la gestión de los distintos procesos que se requieren en las actividades realizadas. Más y más eventos son registrado debidos debido al gran número de dispositivos conectados a la red proveyendo detallada información sobre el historial del proceso de negocio. Por otro lado, se requiere cuando se necesita mejorar o brindar soporte al proceso de negocio en competitivos y rápidos ambientes de trabajo. Estas técnicas proveen nuevas maneras para descubrir monitorear y mejorar los procesos de negocio en una variedad de aplicaciones. La implementación de la LSTM para el descubrimiento de eventos o actividades de un proceso de negocio mediante el cual el análisis predictivo puede ser considerado una importante estrategia de innovación y éxito. Información que será obtenida a partir del log de eventos tomados de las herramientas tecnológicas como el IOT y la industria 4.0. El modelo predictivo LSTM será entrenado con los logs de eventos activando la predicción de las actividades con la finalidad de iniciar una actividad o set de actividades dados como ingresos. Con la finalidad de ordenar y validar el enfoque que muestra

la aplicabilidad se presentó los resultados con un base de datos de 255 observaciones. Los resultados entrenados por la red mostraron que tiene la capacidad para predecir las siguientes actividades en el modelo del proceso de negocio. Dando como resultado un efectivo y escalable modelo para el aprendizaje de problemas de información secuencial. La información contenida en la LSTM está fuera del flujo normal de una RNN. El ejemplo analizado en este ensayo está basado en un set de 255 ensayos y enfocado en el control de una planta para incrementa el performance global incluyendo el mantenimiento predictivo. La planta produce partes de metal como pernos discos y tubos. Para construir estas partes hay 28 máquina para hacer distintas operaciones como forjado, torneado, rebanado, impresión, cortado de cables, marcación mediante laser y degradado.

Este escenario es preciso para explotar los logs de eventos que proveen detallada información, un histórico del proceso de negocio el cual se realiza mediante registro de la información del sensor para predecir la siguiente actividad a ser ejecutada. En el proceso de negocio es importante proveer información valorable para planificar una correcta asignación como preparar una maquina o un recurso para estar listo y en tiempo para la producción.

La red LSTM fue entrenada con el log de eventos en el cual existen 56 diferentes actividades contenidas en el log y el número de secuencias identificadas durante el entrenamiento de la red fue de 4541. La red LSTM acepta ingreso de información y una actividad con la finalidad de predecir la siguiente actividad. En una secuencia la red neuronal fue configurada para predecir tres ingresos por instancia ordenados de mayor a menor probabilidad con la finalidad de conocer la siguiente actividad. Se realizo un resumen de los nombres de las actividades a acrónimos "CONTROL DE CALIDAD CONTORNEADO Y TORNEADO" (TMQC) y como se evidencia en la tabla presentada, se obtiene al otorgar la data de la primera columna como inputs es decir la segunda tabla es la "Target Activity" el cual es la actividad esperada o actividades para el input correspondiente, los cuales son las actividades que tiene la más alta probabilidad de predicción. Cada fila en la tabla muestra un caso de predicción de la siguiente actividad

a partir del input de cada una. El test llevado a cabo por la red LSTM entrenada muestra que tiene la capacidad de predecir la siguiente actividad del proceso de modelo de negocio. Para los casos 3,5,6 y finalmente 9 la red fue capaz de predecir la exacta siguiente actividad, es decir para la tercera, al recibir su input se predijo la salida esperada de la actividad de salida la cual, está incluida para los otros casos la mayoría de las actividades objetivas fueron identificadas dejando libre una que no fue predicha. Se obtuvo solamente una predicción incorrecta en el que para un se obtuvo las actividades LMM7 y LPM1 y no la TMM4, de cualquier manera, la siguiente actividad predicha es la que tiene gran posibilidad incluso más el caso número 9, en el cual, se obtuvo la actividad deseada en la predicción, pero uno de ellos no fue esperado en los objetivos. Finalmente, en el caso 10 el objetivo debió obtenerse FIQC pero la red LSTM predice 2 actividades que no concuerdan con la explicación. Como se presentó las redes neuronales tiene una gran capacidad de acierto cuando se trabaja con el tipo de datos cronológicos lo que nos lleva a concluir su efectividad en alrededor de un 85 % dándonos estos números nos permite tomar decisiones más acertadas frente a procesos que tiene bastante variabilidad sea por su tipo de negocio.

Activity name	Acronym
Turning&Milling-Machine	TMM
Turning&MillingQ.C.	TMQC
LaserMarking-Machine	LMM
RoundGrinding-Machine	RGM
RoundQ.C.	RQC
FinalInspectionQ.C.	FIQC
Packing	PACK
TurningQ.C.	TQC
GrindingRework-Machine	GRM
GrindingRework	GR
WireCut-Machine	WCM
Fix-Machine	FM
NitrationQ.C.	NQC

Tabla 3: Datos otorgados como Inputs

Fuente: Jorge Roa

No.	Input Activity	Target Activity	Output Activity 1	Output Activity 2
1	TMQC	LMM7 LPM1 TMM4	LMM7	LPM1
2	PACK	FIQC FM15	FIQC	
3	GRM27	FIQC	FIQC	
4	GR	LPM1 TMQC	LPM1	
5	WCM18	TQC	TQC	
6	RGM19	RGM12 FIQC	RGM12	
7	NQC	TMM5 TMQC	TMM5	TMQC
8	RQC	PACK FIQC	PACK	FIQC
9	FM15	PACK	PACK	TMQC
10	FGM26	FIQC	PACK	MM14

Tabla 4: Datos obtenidos

Fuente: Jorge Roa

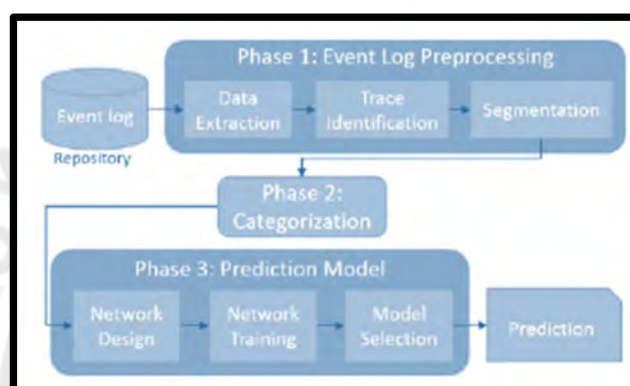


Ilustración 19: Esquema de Trabajo

Fuente: Jorge Roa

1.4.4 Análisis del punto de reorden en compañía XYZ.

El presente artículo menciona como las empresas mantienen grandes niveles de inventario con la finalidad de tener control sobre las ventas y estimular la demanda. En el cual la técnica del punto de reorden (ROP) y los inventarios de seguridad juegan un rol importante (Cheng, 2001) , la cantidad de el ROP refleja el nivel de inventario que activa la generación de una orden de unidades adicionales mientras que la cantidad asociada con el inventario de seguridad protege la compañía de roturas de stock o de pedidos incumplidos, esto se conoce como stock de seguridad o buffer, implementado con la finalidad de reducir la tasa de incumpliendo de pedidos. Tras la aplicación de dichas herramientas y de analizar los resultados, estos mostraron mejoras en los costos totales. Cabe resaltar que se requirió de un modelo

de pronósticos con la finalidad de determinar con mayor seguridad y mantenerse prevenido ante los abruptos de pedidos que se puedan presentar en las compras del cliente. Con esto la compañía aseguraría suficientes productos terminados y que estos encuentren en sus inventarios, como también insumos para la preparación de los mismos, dado esto se podría satisfacer la demanda de los clientes y mejorar los beneficios económicos. Se concluyó en la empresa XYZ, que estaba presentando problemas debido al pronóstico inefectivo que resulto en roturas del stock y por consiguiente incumplimiento de pedidos e insatisfacción de los clientes lo cual se refleja en perdidas monetarias. Con la finalidad de ayudar a reducir las roturas de stock, el modelo de pronósticos fue propuesto junto con el punto de reorden para los insumos de la producción, se patentó un modelo de pronósticos que permita un resultado preciso de pronósticos para cada diferente comportamiento de los productos y por ende permitió reducir sus costos en un \$8300 en sus 13 productos más vendidos. Finalmente, los problemas que presentaba la compañía serían reducidos implementando las mejoras recomendadas en el modelo. Esto asegurara que el producto este en stock, el cual mejoraría el manejo de las ventas de los productos y a su vez permitiría incrementar el beneficio, con solo la implementación de la mejora de los pronósticos e implementación de las medidas antes mencionadas. El análisis recomendado mostro que un simple y una técnica no tan compleja puede ser la clave para el éxito del negocio.

CAPITULO 2: DESCRIPCCION Y DIAGNOSTICO DE LA EMPRESA

A fin de poder realizar un diagnóstico apropiado, la presente tesis será sometida a siguiente análisis y será objeto de diagnóstico en la cual aplicarán diferentes herramientas de calidad como de mapeo de procesos, Flujogramas, matriz QFD, entre otras herramientas y se establecerán las contramedidas más efectivas para contrarrestar la problemática.

2.1. Descripción de la empresa.

La presente tesis fue realizada en una empresa productiva que pertenece al segmento B2B (*Bussines to Bussines*) en gran porcentaje de su totalidad. La cual es de capitales peruanos que lleva en el mercado nacional alrededor de 5 años. Cuenta con 1 planta localizada en la provincia del Callao la cual maquila agua de mesa para distintas empresas del rubro *retail*. Pertenece a grupo empresarial nacional y cuenta con 2 unidades de negocio elaborando una cantidad mayor a los 500000 litros, los cuales corresponden a la purificación y embotellado como valor en el presente mes de febrero del 2020. La empresa presenta 2 unidades de negocios las cuales serán descritas al lector:

2.1.1. Unidades de Negocio.

La empresa se especializa en las siguientes 2 líneas de productos:

a) **Productos maquila.**

Nos referimos a los productos de maquila al agua embotellada en las presentaciones de 7L, 20L, 2.5L, 625ML, 550ML, 380ML, los cuales conforman los pedidos de los principales clientes Cencosud Retail S.A y Supermercados Peruanos S.A. El proceso productivo, entiéndase como purificación del agua, es de similares características; sin embargo, este cambia en el momento del etiquetado. En el caso de las cajas de 20L, la caja varía según el producto a elaborar cabe resaltar que las etiquetas y las cajas ambas vienen en el mismo formato lo que cambia es la impresión dichos productos tras su envasado son enviados a los diferentes centros de distribución los cuales se encuentran ubicados en Lima. Para

Supermercados Peruanos se encuentra el centro de distribución de Punta Negra y para Cencosud en el distrito de Santa Anita.




Ilustración 20: Centro de distribución Cencosud Santa Anita

Fuente: Cencosud




Ilustración 21: Centro distribución SP

Fuente: Supermercados peruanos

b) Marca propia.

En la marca propia corresponde a Selfie, el cual es destinado para la venta minorista en las presentaciones de 625ML, 380ML, 2.5L, 7L, 20L. Se realizan múltiples salidas de inventariado constante, pero de proporciones menores frente a los grandes pedidos de Cencosud y Supermercados Peruanos S.A.



Ilustración 22: Logotipo marca

Fuente: Propia

2.1.2 Sector y actividad económica.

La empresa se dedica al rubro de la elaboración de bebidas no alcohólicas: producción de aguas minerales y otras aguas embotelladas. Su actividad principal es la purificación y embotellado de agua de mesa en su planta del Callao. De acuerdo con el giro de la empresa, se determina que el código de clasificación industrial internacional uniforme (CIIU4) es 1104 el cual corresponde a dicha actividad.

2.1.3 Perfil Organizacional.

Se presentarán las características que describen la empresa

a) Misión.

“Somos una empresa joven con 3 años en el mercado que producimos, comercializamos agua de mesa embotellada. Aseguramos la mejora continua, competitividad y eficiencia de nuestros procesos y servicios a través de nuestro sistema de gestión de calidad. Nos preocupamos por satisfacer las necesidades y los requerimientos de nuestros clientes. Desarrollamos nuestras actividades renovando continuamente nuestro compromiso con nuestros colaboradores, con el futuro del país incentivando los valores y deberes dentro de un marco de responsabilidad social y respeto al medio ambiente”.

b) Visión.

“Incrementar nuestra participación de mercado basándonos en la calidad y precios competitivos de nuestros productos. Creación de una imagen empresarial fundada en la confianza y el beneficio mutuo con nuestros asociados, colaboradores, clientes y proveedores, con la finalidad de consolidándonos como una empresa líder en el embotellado de agua de mesa que ofrece servicios y productos de buena calidad mediante las prácticas de responsabilidad social”.

c) Política de Calidad.

“Somos un equipo dedicado y comprometido con: Cumplir las normas nacionales e internacionales referidos a nuestros productos, Buenas Prácticas de Manufactura (BPM), Dirección General de Medicamentos, Insumos y Drogas (DIGEMID), Dirección regional de salud alimentaria (DIGESA) y los requisitos de nuestros clientes. Desarrollar la mejora continua de nuestro sistema de gestión de calidad (SGC) en el agua de mesa embotellada y en los servicios de atención al cliente (Post venta), realizando nuestros procesos en condiciones seguras de trabajo y preservando los recursos necesarios, manteniendo así nuestra presencia en el mercado. Fomentar el desarrollo personal, trabajo en equipo, respetando el medio ambiente y generando valor para los accionistas, colaboradores y a la sociedad”.

2.1.4 Organigrama.

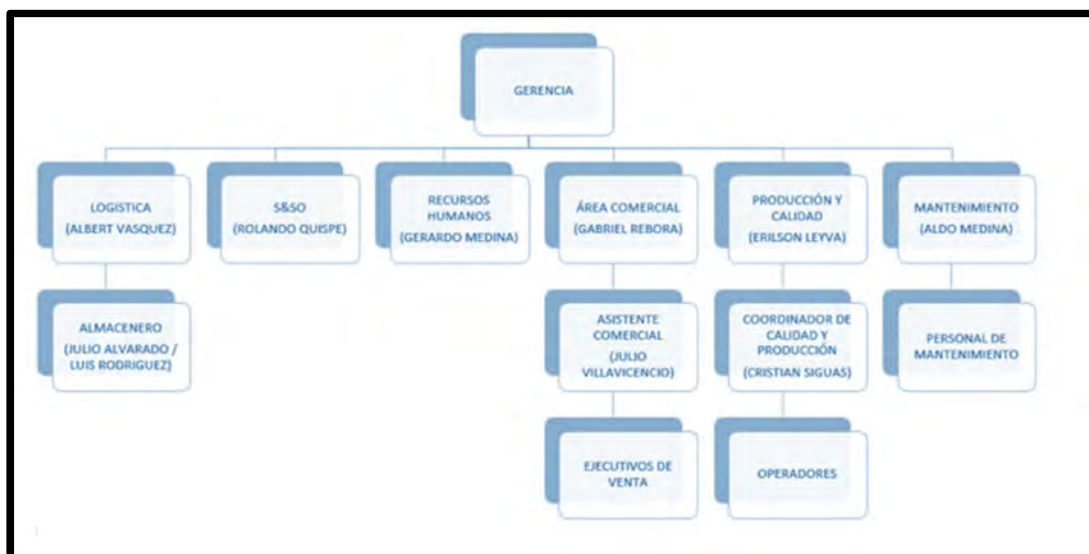


Ilustración 23: Organigrama

Fuente: Elaboración Propia

2.1.5 Producto.

Se definen los siguientes productos para la empresa los cuales se distribuyen en las siguientes presentaciones:

PRESENTACIONES BELLS				
	PAQUETE	NIVELES	CANTIDAD Paq. x CAMA	CANTIDAD Paq. X PALLET
625 mL	12 UNID	5	23	115
2.5 L	6 UNID	3	18	54
380 mL	20 UNID	7	15	105
550 mL	12 UNID	5	23	115
20 L	1 UNID	5	8	40
PRESENTACIONES SELFIE				
	PAQUETE	NIVELES	CANTIDAD Paq. x CAMA	CANTIDAD Paq. X PALLET
2.5 L	6 UNID	3	18	54
380 mL	24 UNID	7	13	91
550 mL	15 UNID	5	21	105
20 L	1 UNID	5	8	40
7 L	2 UNID	3	18	54
PRESENTACIONES METRO				
	PAQUETE	NIVELES	CANTIDAD Paq. x CAMA	CANTIDAD Paq. X PALLET
625 mL	12 UNID	5	23	115
2.5 L	6 UNID	3	18	54
7 L	2 UNID	3	18	54
20 L	1 UNID	5	8	40
PRESENTACIONES WONG				
	PAQUETE	NIVELES	CANTIDAD Paq. x CAMA	CANTIDAD Paq. X PALLET
625 mL	12 UNID	5	23	115
2.5 L	6 UNID	3	18	54
7 L	2 UNID	3	18	54
20 L	1 UNID	5	8	40

Tabla 5: Productos representativos y presentación

Fuente: Elaboración propia

Como se observó: Se muestra los distintos productos que la empresa fabrica, así como también su paletización respectiva.



Ilustración 24: Paletizado de 20L Wong

Fuente: Imagen propia

2.1.6 Clientes.

Cumpliendo con los más altos estándares de calidad (Certificación ISO 9001), entre sus principales clientes se encuentran:

- Supermercados Peruanos S.A (Maquila)
- Cencosud Retail S.A (Maquila)
- Clientes Minoristas (Bajo Marca Selfie)
- Clientes por pedido (Maquila): Rico Soy



Ilustración 25: Zona de Paletizado

Fuente: Imagen propia

2.1.7 Proveedores.

La empresa tiene como principales proveedores las siguientes empresas:

- Plastiqueria: Global Plastic SA
- Caja de Cartón 20 L: Cartones Del Pacifico S.A
- Envases Metálicos: FlexBag empaques SAC
- Oxígeno: Criogas E.I.R.L
- Preformas 15g: Weifang Greatland Machinery Co Ltd
- Preformas 17.5g: Industrias San Miguel
- Preformas de 20g: Weifang Greatland Machinery Co Ltd
- Preformas de 42.5g: Industrias San Miguel
- Insumos Químicos: SgQuimicos, Pfluker e Hijos, Quimex
- Estos son algunos de los proveedores que la empresa trabaja frecuentemente



Ilustración 26: Cartonería Cartones del Pacífico

Fuente: imagen propia

2.1.8 Panorama y ventas actuales.




Ilustración 27: Composición de ventas

Fuente: Elaboración propia

Se puede apreciar la composición de ventas en paquetes del mes de febrero 2020 verificando el producto con mayor nivel de ventas de la empresa, el cual asciende a un 20% del total de las ventas.

2.2. Diagnóstico de la situación actual.

Con la finalidad de proponer una fiable optimización sobre los procesos más críticos de la empresa, es necesario realizar un diagnóstico previo con la finalidad de comprender los problemas más graves y sus respectivas causas esto será posible tras la evaluación de indicadores.

2.2.1. Mapeo de Procesos.

El análisis de los procesos de la organización nos ayudará a entender el modelo de negocio y a su vez poder identificar cuáles agregan y no agregan valor. Tras la identificación de dichos procesos, se podrán verificar los posibles desencadenantes para poder realizar un diagnóstico de la empresa.

Se realizará un análisis de los procesos actuales lo cual permite saber cuáles son las actividades que no contribuyen de manera óptima al cumplimiento de la misión de la empresa. Se identifican los procesos de la empresa a nivel estratégico, operativo y funcional, representados en un mapa de procesos. Los procesos del nivel estratégico y principales van alineados con la visión y misión de la empresa procurando en todo momento un enfocados hacia el cliente. Los procesos de soporte los cuales se visualizan en la parte inferior dan apoyo para que las operaciones se puedan realizar de manera adecuada.

Nivel cero.

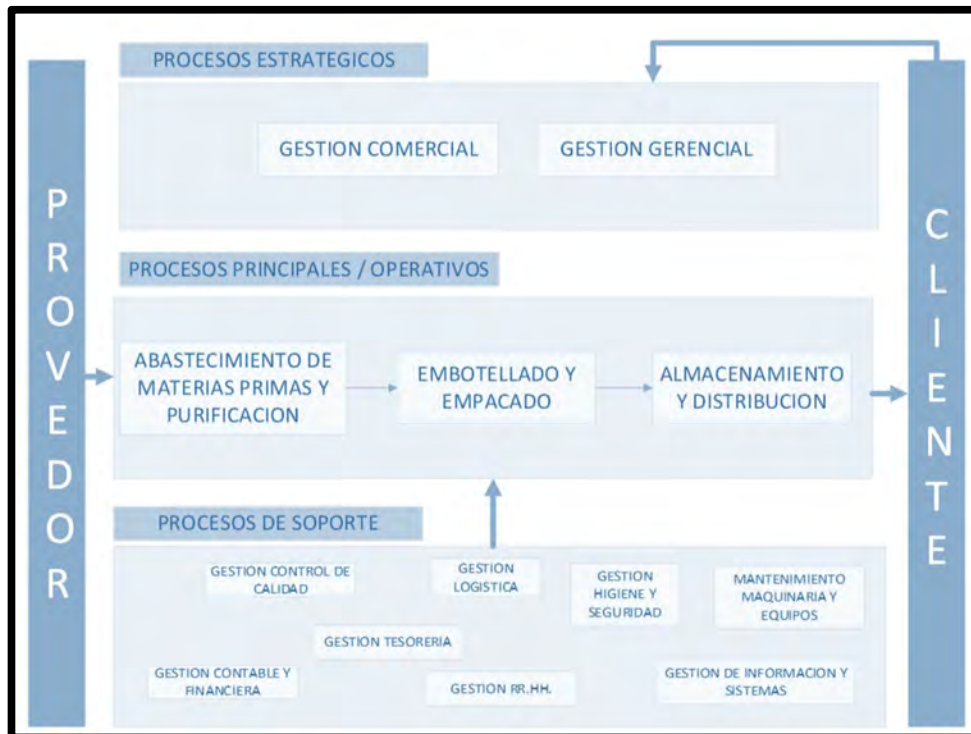


Ilustración 28:Matriz macroproceso

Fuente: Elaboracion propia

Se realizará un análisis de los macroprocesos presentados en el esquema, con la finalidad de priorizar el más crítico para realizar su desagregó en niveles, se hará la representación mediante 2 diagramas de procesos y un flujograma.

Nivel uno.

En el macroproceso, representado en la Ilustración 28:Matriz macroproceso , se desarrollará la etapa del macroproceso más crítica de la empresa. Este macroproceso será electo tras realizar la matriz de priorización, mostrada en Ilustración 29:Matriz de priorización, donde se le otorga mayor porcentaje de decisión a los criterios que afectan al planeamiento estratégico o de la empresa. Para la puntuación, se toma como referencia la tabla de ponderaciones.

RELACIONES	
FUERTE	9
MODERADA	3
DEBIL	1

Tabla 6: Tabla de ponderaciones

Fuente: Elaboración propia

FILA #	PORCENTAJE	MACROPROCESO CRITERIOS	COLUMNA #														
			1	2	3	4	5	6	7	8	9	10	11	12	13	14	
			GESTION COMERCIAL	GESTION GERENCIAL	ABASTECIMIENTO	PRODUCCION Y EMBOTELLADO	DISTRIBUCION	GESTION CONTROL CALIDAD	GESTION LOGISTICA	GESTION HIGIENE Y SEGURIDAD	MANT. MAQ. Y EQUIPOS	GESTION CONTABLE Y FINANCIERA	GESTION RR.HH	GESTIO DE INFORMACION Y SISTEMAS	METROLOGIA	GESTION TESORERIA	
1	15%	NIVEL DE VENTAS	9	1	3	9	3	3			1	1		1		3	
2	10%	INVENTARIO	1		9	9	3		3							1	
3	10%	IMPACTO EN COSTOS DE FABRICACION			1	1	3				3	1				1	3
4	10%	IMPACTO TIEMPOS ATENCION PEDIDOS	1		3	3					3			3	1	3	
5	10%	CALIDAD DEL PRODUCTO						9			3					3	
6	5%	DIAS SIN ACCIDENTES OPERARIOS		1						9			1				
7	10%	PEDIDOS INCOMPLETOS	3		3	9	3				3	1	3	3		3	
8	15%	PARADAS DE PLANTA								3	9		3			3	
9	5%	OPERATIVIDAD SISTEMA INFORMATICO												9			
10	10%	RECHAZO PRODUCTO CLIENTES						9							3	1	
	100%	PONDERADO	1.85	0.2	2.05	3.6	1.4	2.3	0.3	0.9	2.7	0.4	0.8	1.2	1.4	1.5	
	20.30	NIVEL DE IMPORTANCIA	9%	1%	10%	17%	7%	11%	1%	4%	13%	2%	4%	6%	7%	7%	

Ilustración 29: Matriz de priorización

Fuente: Elaboración propia

Debido a la criticidad del macroproceso producción y embotellado consideraremos a este como foco para desarrollar el presente estudio.



Ilustración 30:Nivel 1

Fuente: Elaboración propia

Se realizará un análisis de macroproceso actual de producción y llenado, y se selecciona procesos más críticos, para el correspondiente desagregado desde lo más general a lo más específicos realizará un desarrollo mediante el uso de flujograma.

Nivel tres.

Dentro del tercer nivel existen varios sub procesos, se elegirán los más críticos para el correspondiente desarrollo mediante diagramas de flujos, detallando los responsables y sus actividades. El macro Producción y Llenado, representado en la Ilustración 28:Matriz macroproceso. Se graficará la etapa del proceso más crítico de la empresa. Este proceso será seleccionado a partir de la matriz de priorización, mostrada en Ilustración 29:Matriz de priorización, donde se le otorga mayor porcentaje de decisión a los criterios que afectan a los objetivos estratégicos de la gestión logística. Para la puntuación, se toma como referencia la

Tabla 6:Tabla de ponderaciones. Los criterios de la siguiente tabla serán formulados en base a los objetivos estratégicos de la organización. Los pesos fueron asignados por el jefe de producción de la empresa, quien brindó la información necesaria para el estudio

Tabla 6:Tabla de ponderaciones.

FILA #	PORCENTAJE	CRITERIOS	COLUMNA #		
			1	2	3
		PROCESOS	PRODUCCION	ALMACENAMIENTO	LLENADO PRODUCTOS
1	20%	ESTIMACION DEMANDA Y PLANIFICACION	9	3	9
2	5%	RECEPCION PEDIDOS Y ORGANIZACION	9		
3	5%	PERSONAL FALTATE Y ROTACION	3	3	
4	5%	FALLA COMPONENTES PLANTA	9		
5	5%	ESTANDARIZACION DE EL PROCESO	9		
6	5%	MANTENIMIENTO Y LIMPIEZA	3	9	3
7	10%	INVENTARIADO		1	9
8	15%	FALTA DE INSUMOS/MATERIA PRIMA			9
9	15%	PRESION LABORAL			9
10	15%	CALIDAD DEL PRODUCTO			9
	100%	PONDERADO	3.45	1.3	6.9
	11.65	NIVEL DE IMPORTANCIA	30%	11%	59%

Ilustración 31: Matriz nivel 3

Fuente: Elaboración Propia

Se evidencia la necesidad de realizar un estudio y encontrar las causas del problema en los procesos de Producción y embotellado de la presentación.

PRODUCCION.

El proceso productivo está formado de 3 etapas las cuales serán explicadas a continuación

a) Habilitación de insumos.

Botellas PET: El material proviene de dos fuentes para presentación: 380 ml y 550 ml se utilizarán preformas, las cuales serán sometidas al soplado.

Soplado de Botellas: Las preformas o embriones (15 g, 380 ml, 20 gr y 550 ml) son sometidos a un horno semiautomático con resistencia eléctrica, para luego ser soplados a una determinada presión en un molde para la presentación que finalmente es obtenido la botella de esta presentación y es alimentada a la envasadora tres en uno para su enjuague con agua tratada y posterior llenado.

Enjuague envases: Los envases de las presentaciones 380 ml y 550ml después del soplado, son enjuagados con agua tratada para su posterior llenado. Los envases de 2.5 y 7 L serán desinfectados y luego enjuagados.

Tapas: Pasarán por un proceso de desinfección mediante una ducha con solución de hipoclorito (7.5%) o Dióxido de Cloro (10%) a 10 ppm y enjuague con agua tratada.

Bolsas en Caja: Se solicitan las cajas, bolsas de aluminio, válvulas *vitop*, bolsas termocongelables y pegamento, del almacén de envases, para el armado de la caja y producción.

Pegado: Consiste en pegar el fondo de las cajas.

Codificado: Es colocada la fecha de producción y vencimiento.

b) Tratamiento de agua.

Captación del agua de pozo: Previo al inicio de la captación del agua de pozo, se tomará una muestra de está verificándose las condiciones físico químicas del agua considerando el olor, color, PH, TDS y dureza. Verificado este punto se activa la bomba para que al agua pase a un Tanque de agua cruda (5 m³) donde se iniciara con el proceso de cloración de agua.

Desinfección Química (Cloro) en Tanque de Agua Cruda: Una vez que el agua se almacene en el tanque de agua cruda, se dosifica de manera automática con 36 ml de hipoclorito de Sodio al 7.5 %, controlándose la concentración de cloro libre residual, la cual debe encontrarse de 0.5 a 1 ppm.

Filtrado de Grava: Luego de tanque de agua cruda pasa por el filtro de cuarzo o grava para retener todas las partículas que vienen en el agua.

Filtro de cuarzo tiene como finalidad la remoción de turbidez, partículas en suspensión y sedimentos finos con una capacidad de filtración de hasta 20 micrones nominales. El filtro cuenta con un lecho filtrante de cuarzo de diversa granulometría.

Filtrado de Carbón Activado: Luego del filtro de cuarzo el agua simplemente pasa al filtro de carbón activado, tiene como finalidad la remoción de sabor y olores desagradables del agua, así como los contaminantes orgánicos disueltos, reducción de cloro residual y subproductos (por proceso de adsorción).

Filtro es de limpieza automática, donde las impurezas retenidas serán evacuadas hacia el drenaje por retro lavado a contraflujo del lecho filtrante, este proceso permite eliminar las impurezas retenidas recuperando la performance operativa y rendimiento óptimo del material filtrante para un nuevo servicio, el filtro cuenta con un lecho filtrante de carbón activado granulado. Tanto el filtro de grava, como los de carbón activado son de limpieza automática, donde las impurezas retenidas serán evacuadas hacia el drenaje por retro lavado a contraflujo del lecho filtrante, este proceso permitirá eliminar las impurezas retenidas recuperando la performance operativa y rendimiento óptimo del material filtrante para un nuevo servicio. Así mismo los filtros serán controlados y programados automáticamente mediante las válvulas cabezales incorporadas en las columnas de filtración.

Filtrado Fino: Esta etapa es controlada por 22 cartuchos de filtros finos de 5 micras donde podrán ser eliminados todos los sólidos finos, asegurando la calidad de agua que ingresará equipo de osmosis inversa. Para la verificación de estado de los filtros se considerará el diferencial de presiones.

Ósmosis inversa: El agua filtrada es dirigida al sistema de osmosis inversa donde se eliminarán sales y iones presente en el agua cruda obteniéndose el agua permeada.

Almacenamiento de Tanque de agua media o permeada: El agua filtrada y permeada será almacenada en el tanque de agua media o permeada, realizándose el control de PH, TDS, y dureza del agua

Desinfección Física con Radiación Ultravioleta: Se corrobora la conformidad del equipo, el agua permeada, es irradiada con luz UV eliminando la carga microbiana del agua. Esta agua es almacenada en el tanque de agua final.

Desinfección química con ozono: Cuando se inicia el proceso de envasado, el agua sale del tanque final y es inyectada con ozono cuya concentración en el agua se deberá encontrar entre 0.1 y 0.4 mg/L. Se excluye de este proceso al agua que será envasada en Bag In Box.

Desinfección con Radiación Ultravioleta: Para este paso es importante que el operador verifique que la lámpara UV este encendida. Teniendo la conformidad del equipo el agua ozonizada pasa por el equipo UV, para su desinfección física, garantizando con este último paso la inocuidad del producto.



Ilustración 32:Etiquetado de Metro 7 l

Fuente: Elaboración propia

c) Envasado, etiquetado y empacado.

Previo a iniciar el envasado se dejar correr durante 10 minutos en la maquina 3 en 1 el agua tratada.

Botellas 380 ml, 550ml: Para el envasado de agua de mesa de las presentaciones 380 ml y 550ml, se utiliza una envasadora tres en uno: Enjuague de envases PET, llenado de la botella y tapa la botella.

Llenado y tapado de las botellas: El agua del tanque final es dosificada en los envases de las presentaciones 380 ml y 550ml, finalmente estas son tapadas y selladas. En este punto se realizará la verificación del contenido adecuado y la hermeticidad de la tapa por medio del torque.

Etiquetado: Las botellas deberán encontrarse secas previo al etiquetado, para el pegado de etiquetas se utiliza una goma y una bobina de etiquetas. Se verifica que la maquina se encuentre a una temperatura de (150 – 180°C) para la fundición de la goma.

Codificado: Una vez etiquetada las botellas estas pasan por un equipo codificador para su impresión de lote de producción en el envase. Este código tiene el lote, fecha de vencimiento del producto y la hora de producción del mismo. Se debe verificar la conformidad del correcto lote y fecha de vencimiento y la legibilidad del mismo.

Empacado: Se verificar la máquina de empacado considerando las temperaturas de la cuchilla de corte la cual debe estar una temperatura de $190^{\circ} \pm 5^{\circ} \text{C}$ y la temperatura del horno la cual debe estar a una temperatura de 150°C a 180 °C, con la finalidad de asegurar la eficacia del equipo.

Para el inicio del empacado, se agruparán las botellas según sea su presentación. Las botellas son recubiertas por una lámina termo contraíble y luego ingresadas al horno, la lámina se contrae y se arma el paquete.

Botellas 2.5 L y 7 L: Previamente al envasado las presentaciones 2.5 L y 7L, son etiquetadas para luego pasar por los siguientes equipos: Desinfección y enjuague de envases PET, llenado de la botella y tapado de botella.

Llenado y tapado de las botellas: El agua del tanque final es dosificada en los envases de las presentaciones 2.5L y 7L, finalmente estas son tapadas y selladas. En este punto se realizará la verificación del contenido adecuado y la hermeticidad de la tapa por medio del torque.

Codificado: Una vez llenado y tapado las botellas estas pasan por un equipo codificador para su impresión de lote de producción en el envase. Este código tiene el lote, fecha de vencimiento del producto y la hora de producción del mismo. Se debe verificar la conformidad del correcto lote y fecha de vencimiento y la legibilidad del mismo.

Empacado: Se verifica la máquina de empacado considerando las temperaturas de la cuchilla de corte la cual debe estar una temperatura de $190^{\circ} \pm 5^{\circ} \text{C}$ y la temperatura del horno la cual debe estar a una temperatura de 150°C a 180°C , con la finalidad de asegurar la eficacia del equipo. Para el inicio del empacado, se agruparán las botellas según sea su presentación. Las botellas son recubiertas por una lámina termo contraíble y luego ingresadas al horno, la lámina se contrae y se arma el paquete.

Envasado bag in box (bolsa en caja) 20 L: Para el envasado de agua de mesa sin gas en la presentación de 20L, se utiliza una envasadora: llenado de la bolsa y tapado.

Llenado y tapado: Este proceso es llenado con un dosificador regulado por un temporizador. Una vez llenado es tapado con una válvula vito. La bolsa dosificada es secada la humedad la parte externa.

Ensamblado: Después del llenado y tapado es colocada en la caja armada, luego esta es pegada la parte superior y colocado la bolsa termocongelables.

Pesado: Con esta operación se controla el volumen de llenado, con balanza dentro del programa de calibración.

Empacado: La bolsa externa se termo contrae a 150°C .



Ilustración 33: Línea 2 de llenado

Fuente: Imagen propia

d) Paletizado.

Botellas y cajas: Los paquetes y cajas son distribuidos en una paleta (parihuela) y cada fila es separada por láminas. Estos paquetes/cajas son cubiertos con *stretch film* para proteger de caídas y del polvo, durante su transporte y almacenamiento.

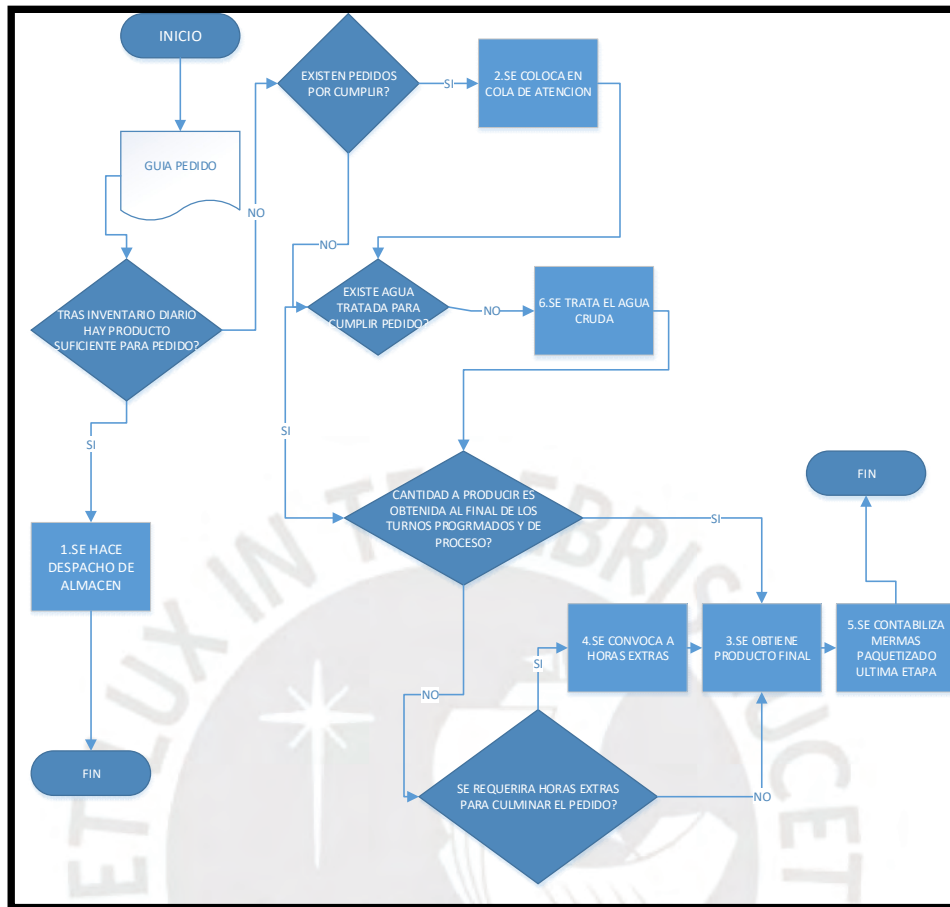


Ilustración 34:Flujograma

Fuente: Elaboración propia

2.2.2 Gestión de indicadores.

Se realizará la elaboración de un análisis de indicadores ya que para el desarrollo del presente trabajo requerirá un correcto análisis de los procesos productivos que se desarrollan, dado que a partir de esto se medirá su rendimiento. Los objetivos de medición de los indicadores fueron recolectados gracias al apoyo del personal de planta dado que son quienes conocen el proceso y sus deficiencias.

N.	PRODUCTO ACTIVIDADES	¿POR QUÉ? ¿INTEN.	INDICADOR	OBJETIVOS	RANGO ACEPTA.
1	ESTIMADO PEDIDO ABASTECIDO CON ALMACEN	PARA PORCENTAJE DE LOS PEDIDOS QUE FUERON ABASTECIDOS CON PAQUETES DEL ALMACEN	PORCENTAJE DE UTILIZACION DEL ALMACEN /CAPACIDAD MAXIMA ALMACENES PT	60%	70%-50%
2	VARIACION EN LA CADENCIA DE PEDIDOS	CONOCER EL NUMERO DE PEDIDOS QUE SON REALIZADOS POR SEMANA (BELLS) VOLATILIDAD DE LOS PEDIDOS	VARIACION DE EL MONTO DE EL PEDIDO FRENTE A SEMANA ANTERIOR	70%	+30%
3	EFICACIA PROCESO PRODUCTIVO	CONOCER EN PORCENTAJE LA CANTIDAD PERDIDA DE AGUA DEBIDO AL PROCESO PRODUCTIVO	(CANTIDAD PRODUCTO * CONTENIDO (LITROS) * UNIDADES EN PAQUETES)/(AGUA REQUERIDA- MERMA DE AGUA)	95% +	-10%
4	HORAS EXTRAS	CONOCER EL TOTAL EN HORAS EXTRAS REQUERIDAS AL MES PARA COMPLETAR LA PRODUCCION	SUMA DE HORAS EXTRAS EN EL MES POR CADA PRODUCTOS	<50	0
5	MERMA PAQUETIZADO FINAL	CONOCER CUANTO PRODUCTO QUE FUE PROCESADO CORRECTAMENTE Y SE PERDIO POR MANEJOS INCORRECTOS EN LA ETAPA FINAL	SUMA DE CANTIDAD DE MERMAS DE CADA PRODUCTO EN EL MES POR CADA PRODUCTO	<400	x 1.2 ratio de disminucion
6	MERMA TRATAMIENTO DE AGUA	PARA CONOCER LA PERDIDA DE EL PRODUCTO A EMBOTELLAR Y CUANTO NOS QUEDARA DISPONIBLE PARA DICHO FIN	SUMATORIA DE MERMA DE LAS PRODUCCIONES EN EL MES	100000 L	+50000 L

Tabla 7: Tabla de indicadores

Fuente: Elaboración propia



Ilustración 35: Indicadores gráficos

Fuente: Elaboración propia

Ficha de Indicador:

● **INDICADOR 1**

Definiciones Generales

Responsable:	JEFE PRODUCCION
Fuente / Procesamiento:	DATA HISTORICA SISTEMA DE REGISTRO
Frecuencia de Medición:	Mensual

Definiciones Especificas

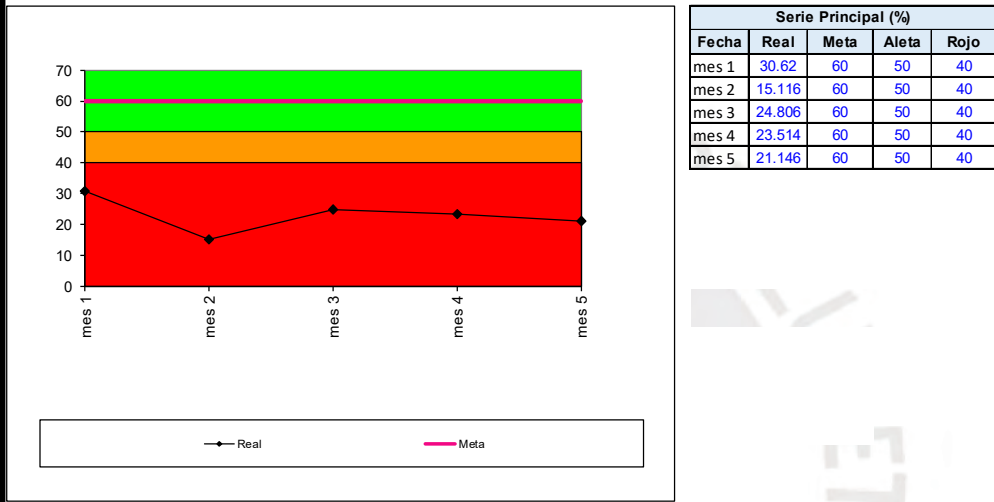


Ilustración 36: Indicador 1

Fuente: Elaboración propia



Ilustración 37: Utilización de los almacenes

Fuente: Propia

Este indicador permite conocer cuanto de la capacidad de los almacenes de producto terminado se viene utilizando actualmente como se ha mencionado, este recurso de planta no se utiliza a plenitud estando

este la mayoría del tiempo vacío como lo puede confirmar los indicadores de utilización de almacenes, es decir cuando llegan los pedidos no se tiene producto terminado que sirva como “colchón”, lo cual conforma el stock de seguridad y disminuya la cantidad de producto de las distintas presentaciones que se deberá fabricar. Actualmente es el panorama en planta, se considera a este como uno de los motivos por los cuales los pedidos de los grandes clientes no son correctamente atendidos.

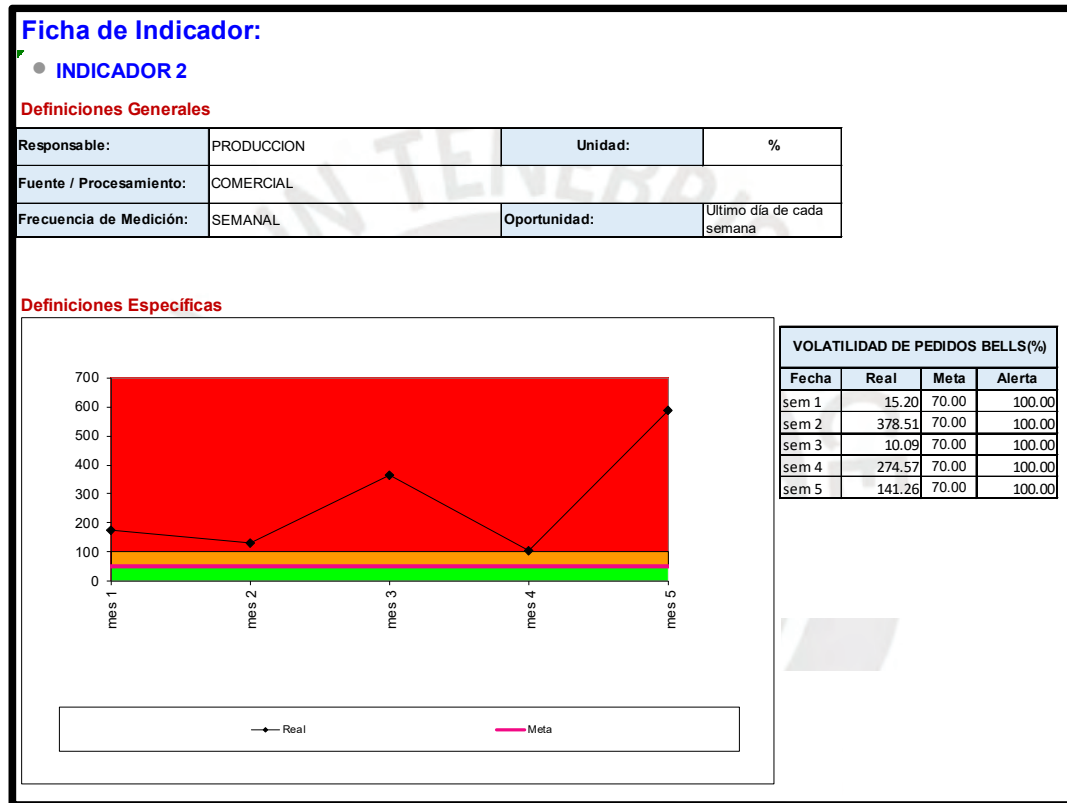


Ilustración 38: Indicador 2

Fuente: Elaboración propia

Aquí se evidencia la volatilidad en los pedidos y debido a que en circunstancias en las que estos son muy elevados no se puede cumplir con las ordenes, ya que sumado los “nulos” inventarios no se llega a completar los pedidos a tiempo, se incurre inclusive a defectos en la calidad del producto y penalidades por pedidos entregados a destiempo. En promedio son 3 días para completar el pedido, muchos de estos inclusive con horas extras no se llegan a culminar.


Ficha de Indicador:

● **INDICADOR 3a**

Definiciones Generales

Responsable:	PRODUCCION	Unidad:	%
Fuente / Procesamiento:	REGISTRO RPA DE PRODUCCION		
Frecuencia de Medición:	Mensual	Oportunidad:	CADA PRODUCCION

Definiciones Especificas



EFICACIA PROCESO PRODUCTIVO 380 ml (%)				
Fecha	Real	Meta	Aleta	Rojo
mes 1	93.48	95.00	85.00	60.00
mes 2	90.51	95.00	85.00	60.00
mes 3	88.88	95.00	85.00	60.00
mes 4	77.83	95.00	85.00	60.00
mes 5	85.92	95.00	85.00	60.00


Ficha de Indicador:

● **INDICADOR 3b**

Definiciones Generales

Responsable:	PRODUCCION	Unidad:	%
Fuente / Procesamiento:	REGISTRO RPA DE PRODUCCION		
Frecuencia de Medición:	Mensual	Oportunidad:	CADA PRODUCCION

Definiciones Especificas



EFICACIA PROCESO PRODUCTIVO 550 ml (%)				
Fecha	Real	Meta	Aleta	Rojo
mes 1	61.05	95.00	85.00	60.00
mes 2	88.26	95.00	85.00	60.00
mes 3	50.24	95.00	85.00	60.00
mes 4	38.27	95.00	85.00	60.00
mes 5	32.39	95.00	85.00	60.00


Ficha de Indicador:

● **INDICADOR 3c**

Definiciones Generales

Responsable:	PRODUCCION	Unidad:	%
Fuente / Procesamiento:	REGISTRO RPA DE PRODUCCION		
Frecuencia de Medición:	Mensual	Oportunidad:	CADA PRODUCCION

Definiciones Especificas



Fecha	Real	Meta	Aleta	Rojo
mes 1	84.69	95.00	85.00	60.00
mes 2	84.42	95.00	85.00	60.00
mes 3	58.31	95.00	85.00	60.00
mes 4	63.49	95.00	85.00	60.00
mes 5	40.91	95.00	85.00	60.00


Ficha de Indicador:

● **INDICADOR 3d**

Definiciones Generales

Responsable:	PRODUCCION	Unidad:	%
Fuente / Procesamiento:	REGISTRO RPA DE PRODUCCION		
Frecuencia de Medición:	Mensual	Oportunidad:	CADA PRODUCCION

Definiciones Especificas



Fecha	Real	Meta	Aleta	Rojo
mes 1	86.23	95.00	85.00	60.00
mes 2	54.76	95.00	85.00	60.00
mes 3	49.16	95.00	85.00	60.00
mes 4	69.48	95.00	85.00	60.00
mes 5	50.82	95.00	85.00	60.00

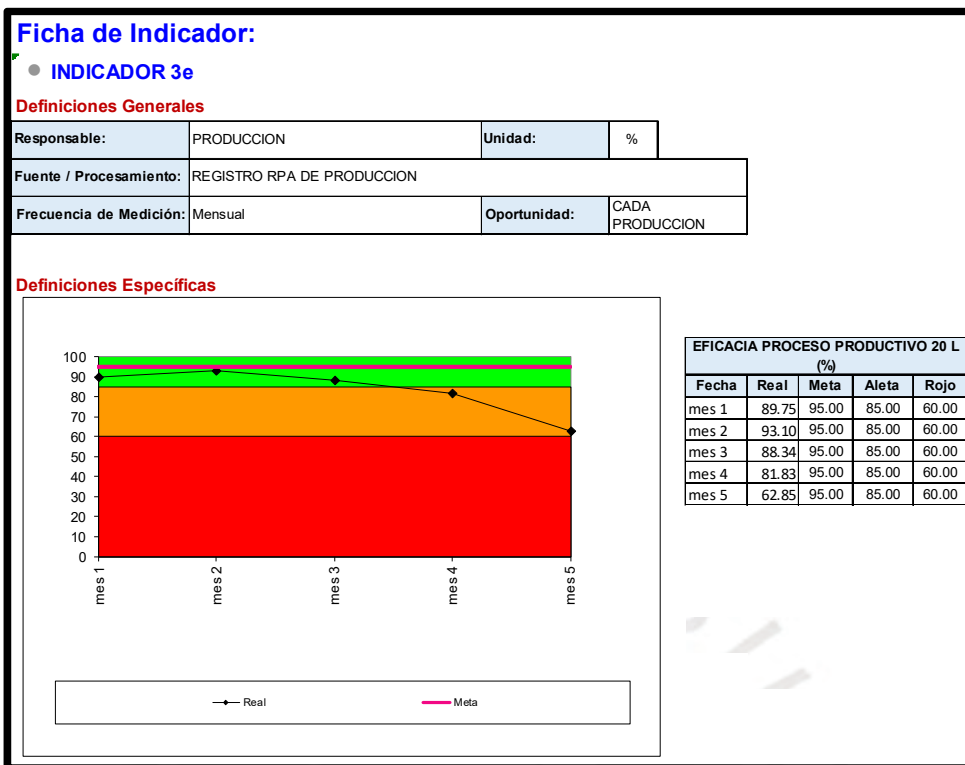


Ilustración 39:Indicador 3

Fuente: Elaboración propia

En la presente ficha indicador se observa la eficacia del proceso productivo según cada una de las presentaciones que se puede observar a través de los meses, 5 más reciente 1 más antiguo este ha ido disminuyendo debido a que las producciones se enfocan más en el cumplimiento que en la calidad y durante el proceso productivo, en el llenado de las botellas semiautomático, el agua se desperdicia mucho más que en meses anteriores. Adicionalmente, debido al cumplimiento de los pedidos se saltan mantenimientos, calibraciones, charlas a los personales, es decir el trabajo no se realiza adecuadamente, esto ha venido empeorando conforme el incremento de los pedidos ha ido incrementando. Se podría decir que este es uno de los motivos por lo cual se perdió la concesión de la botella de Bells 2.5L y fue entregado a la empresa “ISM” ya que cuenta con mayor planificación y capacidad para el cumplimiento de los pedidos, cabe resaltar que una bolsa metálica recipiente que se utiliza para contener el agua de

mesa dentro de las cajas producirá menos desperdicio que el llenado de las botellas de 380 ml observable en el presente indicador.

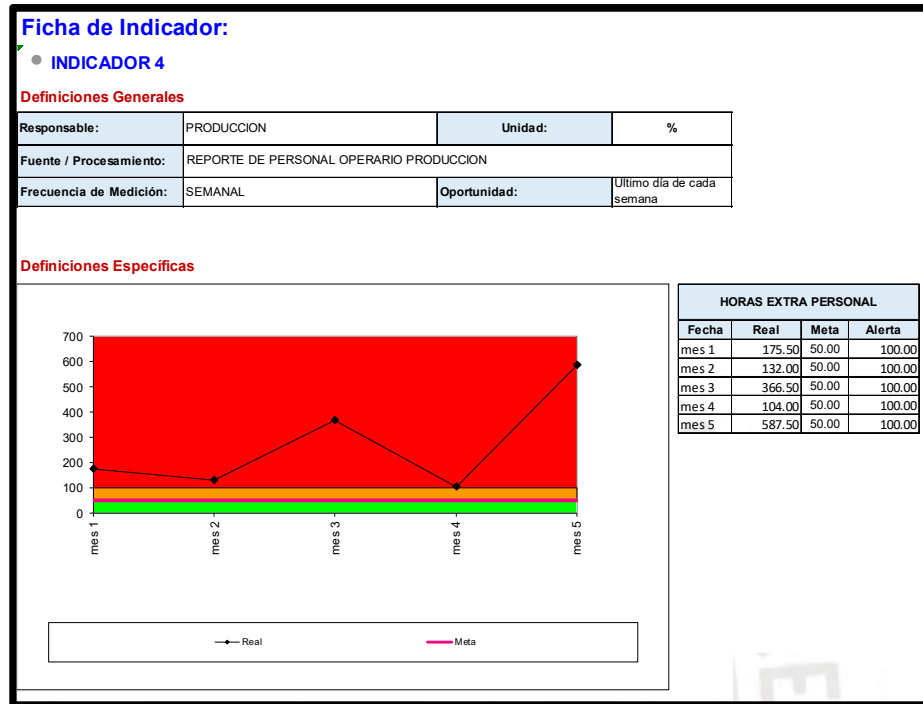


Ilustración 40:Indicador 4

Fuente: Elaboración propia

El presente indicador puede considerarse como uno de los indicadores más relevantes el cual nos indica el motivo y la necesidad de realizar una correcta planeación de los pedidos entrantes y el establecimiento de los stocks de seguridad ya que como se verifica el número de horas extras se han incrementado turno de 12 a 16 horas corridas para el personal operativo y supervisores; sin embargo, tampoco así se ha podido llegar a el pedido solicitado por los clientes ya que se carecía de una correcta planeación. Además, las horas extras influyen en el costo de fabricación del producto dado de que el mismo cansancio, la eficacia del proceso productivo y la calidad se ven desmerecidas.




Ilustración 41: Indicador 5

Fuente: Elaboración propia

En la presente ficha inicialmente se tenía como propósito la disminución de los productos considerados merma en un 0.2 como tasa de disminución ya que esto permitiría tener menos producto terminado clasificado como merma; sin embargo, se ha observado que conforme hay un incremento de la producción la merma ha crecido, lo cual contradice la pretensión de disminuirla, esto principalmente por la falta de mantenimiento de los equipos, la preparación calibración de los mismos, el personal trabajando en horas extras genera. Estos pasos importantes como el control de la calidad en el suministro de insumo, materias primas y algunas malas prácticas de manufactura generen dichos números. Además, es verificable en los constante reclamos de Cencosud y Supermercados Peruanos por materias extrañas, desperfectos y calidad que presentan dichos clientes constantemente.




Ilustración 42:Indicador 6

Fuente: Elaboración propia

El presente indicador permite visualizar la merma correspondiente a la purificación y elaboración del agua de mesa: Como puede observarse, se ha identificado que existe un incremento del agua tratada que dado las deficiencias en la manipulación de la producción esta se echa a perder. Cabe resaltar que este problema se ve acrecentado por la falta de mantenimiento de equipos y controles de calidad, por lo cual debe ser considerada merma. Se genera así el uso ineficiente de los recursos lo cual se traduce en pérdidas monetarias.

2.3 Diagrama de Pareto principales problemas.

A continuación, se mostrará como afectan los problemas en el aspecto económico debido al número de ocurrencias en cada una de las fichas de indicadores. Dichos problemas serán clasificados según su impacto en las ganancias, se realizará el respectivo ABC y se mostrará en el diagrama de Pareto.

Se presenta la gráfica de Pareto:

VALORES CALCULADOS CON RESPECTO A VENTAS ANUALES (MES) ESTIMADOS					
N	PROBLEMA	IMP. ECON.	ACUM. IMP. ECON.	PORC.	PORC. ACUM. %
1	BAJA EFICACIA DEL PROCESO PRODUCTIVO	257486.21	257486.21	29%	29%
2	TENDECIAS ABRUPTAS EN LA VARIACION DE LA CADENCIA DE PEDIDOS	228564.876	486051.0858	26%	55%
3	MERMA PAQUETIZADO FINAL (ULTIMA REVISION)	171141.225	657192.3111	19%	75%
4	MERMA TRATAMIENTO DE AGUA	114207.053	771399.3645	13%	88%
5	PEDIDOS NO ABASTECIDO CON ALMACEN (UTILIZACION)	65611.481	837010.8455	7%	95%
6	ALTO USO DE HORAS EXTRAS	41888.1996	878899.0452	5%	100%
		878899.045		100%	

Tabla 8: Valores Calculados según costos y PV

Fuente: Elaboración propia




Ilustración 43: Diagrama de Pareto

Fuente: Elaboración propia

2.2.4 Análisis Causa y Efecto.

Se comenzará con el análisis de las causas que contribuyen con los problemas detectados, priorizando así el diagrama de Pareto

a) Diagrama de Relación.

Tras realizar el diagrama de Pareto y la obtener la priorización de los problemas principales se procedió a la agrupación en 2 subcategorías de las cuales se presenta la siguiente relación de indicadores.

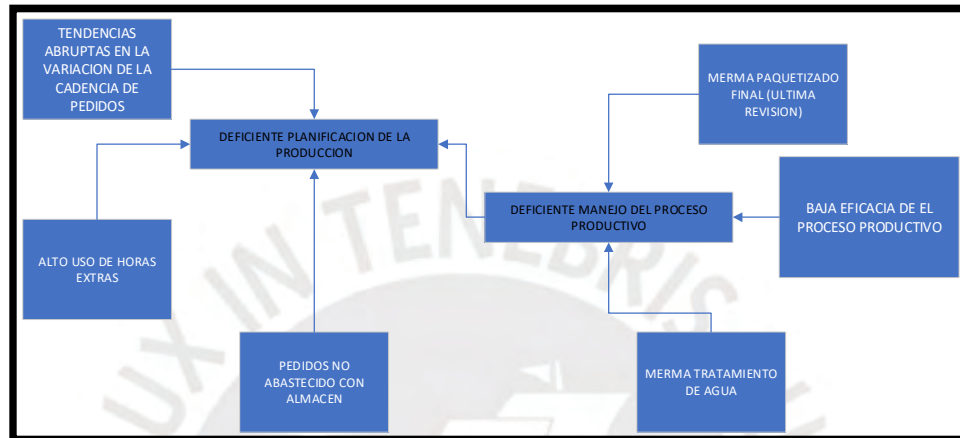


Ilustración 44: Diagrama de relación

Fuente: Elaboración propia

b) Diagrama de Ishikawa.

Se comenzará el análisis con el uso de la cascada de causa-efecto que relaciona de manera gráfica las causas establecidas, con ayuda del personal operativo, los supervisores y el jefe de producción. El gráfico del análisis cascada nivel 1, 2 y 3 se presenta a continuación.

Nivel uno.

En el presente primer nivel se analizan las causas de porqué la planificación de la producción no se realiza correctamente, lo cual acarrea la demora, retrasos y pedidos incumplidos traducidos a pérdidas monetarias.

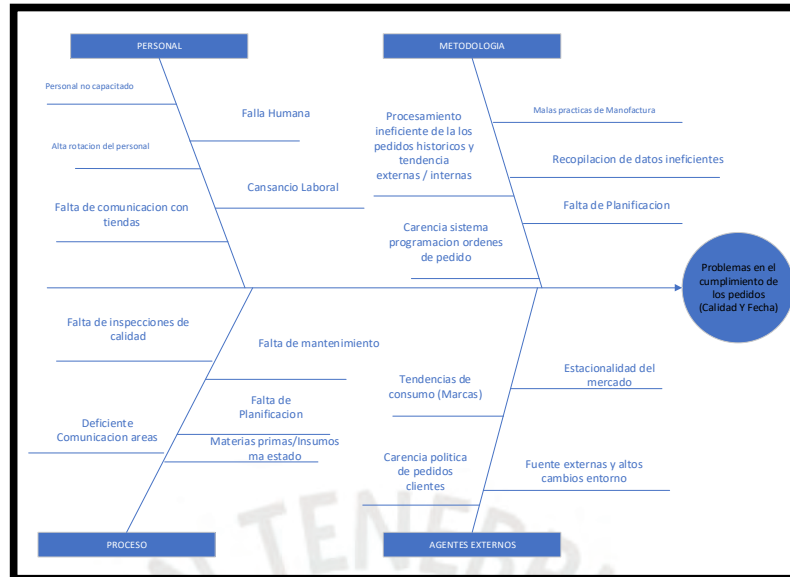
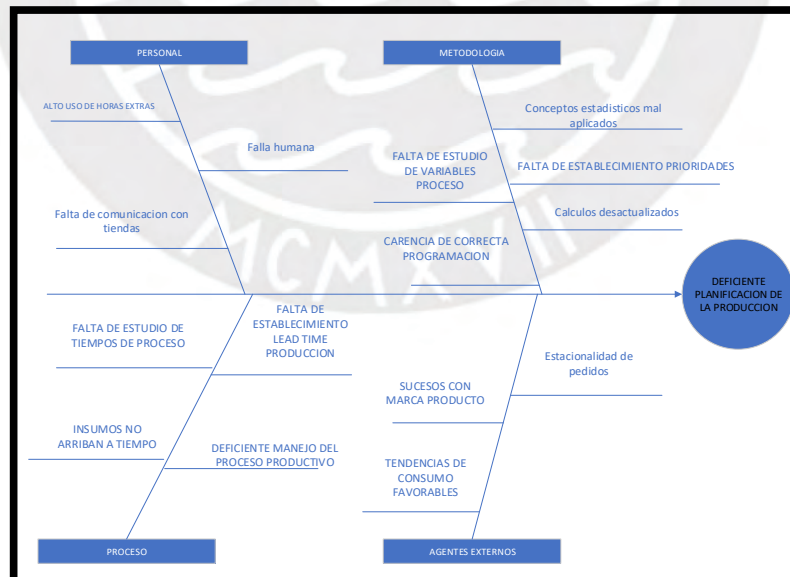


Ilustración 45: Diagrama de Ishikawa 1

Fuente: Elaboración propia

Nivel dos.

Se vuelve a realizar el análisis, pero sobre la complejidad y variabilidad del proceso de llenado para descubrir los motivos que lo generan. Es decir, con la finalidad de buscar la raíz del problema.



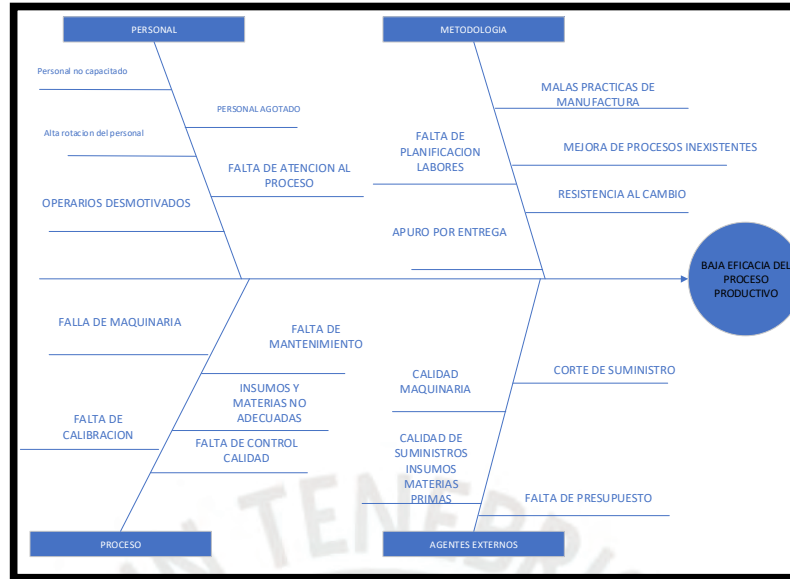


Ilustración 46: Diagrama de Ishikawa 2

Fuente: Elaboración propia

Nivel tres.

Se realiza un análisis nivel tres, pero ahora respecto de la causa principal, la falta de aplicación de metodologías de mejora de procesos. Con este nivel el presente análisis cascada o Ishikawa queda concluido y permite así saber la fuente de los problemas en la presente área de la empresa. Se muestra la imagen correspondiente a la primera problemática; sin embargo, el análisis es similar para el resto de problemáticas halladas.

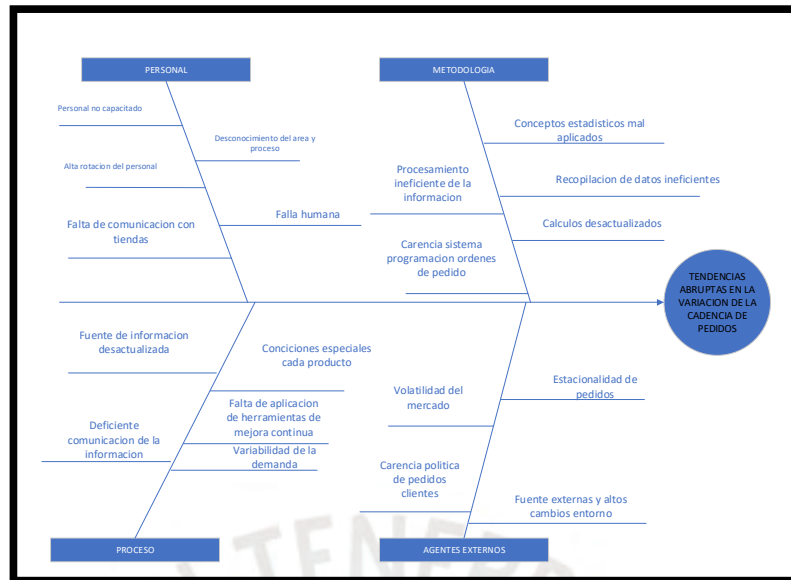


Ilustración 47: Diagramas de Ishikawa 3

Fuente: Elaboración propia

En el análisis se observó cada una de las causas por las cuales el proceso no marcha correctamente. En el nivel 1 se utilizó un panorama global para definir los 2 enfoques de la problemática actual de la empresa. En el nivel 2, separados en 2 grupos, la deficiente planificación de la producción y la baja eficacia del proceso productivo como se observa el diagrama de relación: La deficiente planificación de la producción trajo como consecuencia las tendencias abruptas en la variación de la cadencia de pedidos. Esto ha ido en incremento entre semanas se verifico que existe subidas abruptas de pedido lo cual acrecentado junto con el problema de falta de stock genera que se requiera de H.E; sin embargo, a pesar de dicha dichas adiciones de horas los problemas como el desabastecimiento de insumos, materias primas, la falla de las herramientas y maquinarias como la pistola de silicona o la faja de la empaquetadora no permiten completar los pedidos. Luego, el alto uso de horas extras genera que el personal este cansado disminuyendo su productividad y la calidad general de los productos. Los pedidos no abastecidos con almacén (utilización) permite observar un panorama en el cual dichas áreas llegan a un promedio del 30% de utilización. Es decir, se evidencia que no se está haciendo uso de dichas áreas que permitirían tener un colchón o stock de seguridad en el caso de avecinarse pedidos de gran magnitud.

La merma de tratamiento de agua evidencia la disminución de la cantidad del producto para envasar, además revela que el mantenimiento y labores tales como el sanitizado no ha sido efectuado.

La baja eficiencia del proceso productivo nos revela que el agua tratada destinada para el llenado no está rindiendo lo requerido ya que este indicador nos muestra un cálculo teórico entre la cantidad a destinar y la cantidad que realmente fue destinada (abastecida por las líneas) es decir actualmente existe un desperdicio significativo del líquido elemento.

Finalmente, la merma de paquetizador final (última revisión) es la cantidad en paquetes de merma en las distintas presentaciones de producto que la empresa genera al mes. Esto esta atribuido a distintos factores tales como el mal manejo por parte del personal operativo, cansancio apuro y falta de experticia. La mala calidad de los insumos y materias primas, la falta de controles de calidad antes del proceso final generan que tras el procesado final el producto quede defectuoso generando así tal merma significativa.

c) Confrontación de factores.

Con la finalidad de la confrontación de factores es indispensable extraer información de las personas con más años en la planta, las cuales tienen amplio conocimiento de la frecuencia y los impactos que a la empresa. Debido a esto se seleccionó estratégicamente a las siguientes personas:

-Jefe de producción

-Jefe de Logística

-Operarios Producción

-Técnico de Mantenimiento

-Área Comercial

EXPERTOS	JEFE DE PRODUCCION	JEFE DE LOGISTICA	OPERARIOS DE PRODUCCION	TECNICO DE MANTENIMIENTO	COMERCIAL	CONTEO	PROMEDIO
JEFE DE PRODUCCION		1	1	1	1	4	31%
JEFE DE LOGISTICA	0		1	1	1	3	25%
OPERARIOS DE PRODUCCION	0	1		1	1	3	25%
TECNICO DE MANTENIMIENTO	0	0	1		1	2	15%
COMERCIAL	0	0	0	1		1	8%
TOTAL						13	

Tabla 9: Confrontación de factores

Fuente: Elaboración propia

Aquí se muestra los pesos que cada experto posee dependiendo la jerarquía y las responsabilidades sobre los colaboradores que tienen a su cargo en la empresa, para determinar el puntaje ponderado en cada una de las causas planteadas por el equipo.

d) 5 porqués.

Se presenta las causas raíces encontrada tras la aplicación de la metodología de 5 porqués:

TABLA CAUSAS CRITICAS PONDERADAS				
N	CAUSAS	INFLUYENTE	FRECUENCIA	PONDERADO
1	FALTA DE UNA PLANIFICACION DE LA PRODUCCION	5	6	30
2	FALTA DE UN PRONOSTICO ADECUADO Y FLEXIBLE	5	5	25
3	FALTA DE UN ESTABLECIMIENTO DE STOCK DE SEGURIDAD	4	5	20
4	FALTA DE CONOCIMIENTO DE EVENTOS PROBABLES A SUCCEDER	4	5	20
5	FALTA DE EL REGISTRO DE EL PRODUCTO TERMINADO	4	4	16
6	FALTA DE EL ESTABLECIMIENTO DE UN RITMO DE TRABAJO	4	4	16
7	FALTA ESTUDIO DE CONSUMO DE INSUMOS CRITICOS	4	4	16
8	FALTA DE APLICACION DE Ss Y ESTABLECIMIENTO DE CONTROL DE CALIDAD MP Y INSUMOS	4	4	16
9	FALTA DE ESTABLECIMIENTO DE PATRONES DE MANTENIMIENTO	3	3	9
				40

Tabla 10: Confrontación de factores

Fuente: Elaboración propia

Se presentan las causas raíces las cuales serán motivo de análisis en la consecuente matriz FACTIS:

TABLA CAUSAS CRITICAS PONDERADAS				
N	CAUSAS	INFLUYENTE	FRECUENCIA	PONDERADO
1	FALTA DE UNA PLANIFICACION DE LA PRODUCCION	5	6	30
2	FALTA DE UN PRONOSTICO ADECUADO Y FLEXIBLE	5	5	25
3	FALTA DE UN ESTABLECIMIENTO DE STOCK DE SEGURIDAD	4	5	20
4	FALTA DE CONOCIMIENTO DE EVENTOS PROBABLES A SUCCEDER	4	5	20
5	FALTA DE EL REGISTRO DE EL PRODUCTO TERMINADO	4	4	16
6	FALTA DE EL ESTABLECIMIENTO DE UN RITMO DE TRABAJO	4	4	16
7	FALTA ESTUDIO DE CONSUMO DE INSUMOS CRITICOS	4	4	16
8	FALTA DE APLICACION DE Ss Y ESTABLECIMIENTO DE CONTROL DE CALIDAD MP Y INSUMOS	4	4	16
9	FALTA DE ESTABLECIMIENTO DE PATRONES DE MANTENIMIENTO	3	3	9
				40

Tabla 11: 5 porqués

Fuente: Elaboración propia

2.2.5. Contramedidas.

a) Fase uno - Lista de contramedidas.

A continuación, se mostrará contramedidas establecidas para solucionar las causas raíces.

N°	CAUSAS RAÍZ	CONTRAMEDIDAS	SOLUCIONES PROPUESTAS
1	FALTA DE PLANIFICACION DE LA PRODUCCION	LA ANALITICA DE DATOS (MODELO LSTM) NOS PERMITIRIA ESTABLECER UN MODELO EL CUAL SERIA PREDICTIVO ESTE PERMITIRIA CONOCER Y ADAPTARSE A LOS DISTINTOS PATRONES DE LA DEMANDA PERMITIENDO QUE NOS ADECUAMOS A LA PRODUCCION QUE SE VA A REALIZAR PARA SATISFACER AL CLIENTE TODO ESTO LUEGO SE IMPLEMENTARIA EN UN CUADRO PLANIFICADOR DE LA PRODUCCION	ANALITICA DE DATOS - MODELO LSTM
2	FALTA DE ESTABLECIMIENTO DE UN RITMO DE TRABAJO	AL ESTABLECER UN TACTIME SE ESTARIA ESTABLECIENDO UN RITMO DE TRABAJO SEGUN LA PRODUCCION DEMANDADA EL CUAL SE PODRIA ACCELERAR EN CASO REQUERIR PEDIDOS DE EMERGENCIAS Y REDUCIR RECURSOS EN CASO NO SEA NECESARIO LO CUAL NOS PERMITIRIA UN USO MEJOR DEL RECURSO HUMANO EN LA PLANTA ASI COMO TAMBIEN SE PODRIAN REALIZAR LABORES DE MANTENIMIENTO EN DICHO TIEMPO	IMPLEMENTACION TACTIME - HERRAMIENTA LEAN
3	USO EXCESIVO DE HORAS EXTRAS	SE LOGRARIA LA REDUCCION DE EL USO EXCESIVO DE HORAS EXTRAS TRAS LA IMPLEMENTACION DE UN CUADRO PLANIFICADOR APOYADO POR LA ANALITICA DE DATOS Y LA IMPLEMENTACION DE LOS STOCKS DE SEGURIDAD LO CUAL PERMITIRIA UNA PLANIFICACION ADECUADA CON TIEMPO Y SE EVITARIA EL INCUMPLIMIENTO DE LOS PEDIDOS	CUADRO PLANIFICADOR PRODUCCION CONSECUENCIA HERRAMIENTA N 1
4	FALTA DE ORDEN EN AREA DE TRABAJO Y UTILIZACION DE ALMACENES	AL IMPLEMENTAR LAS 5S EN LA PLANTA DE TRABAJO SE LOGRARIA MANTENER UN ORDEN EN LAS PRINCIPALES AREAS DE TRABAJO COMO EN LOS ALMACENES YA QUE A PESAR DE QUE NO SE UTILIZAN A SU TOTALIDAD SE VE DESORDEN EN ESTOS MIERMA DISEMINADA POR LA PLANTA Y LOS ALMACENES PRODUCTO EN MAL ESTADO JUNTO CON EL PRODUCTO TERMINADO PARA DESPACHAR LO CUAL GENERA COMO CONSECUENCIA UNA DISMINUCION DE LA CALIDAD EN EL PRODUCTO	IMPLEMENTACION 5'S
5	FALTA DE CONOCIMIENTO DE EVENTOS REPETITIVOS A SUCCEDER Y MANTENIMIENTOS	GRACIAS A LA ANALITICA DE DATOS SE PODRIA CONOCER DISTINTOS PATRONES REPETITIVOS QUE SE EXTRAMARIAN DE EL LOS DE OCURRENCIA ASI COMO CANTIDADES DE MATERIAS AMBOS SE ENCUENTRAN EN EL REPORTE DE PRODUCCION DE AGUA SIN EMBARGO ESTA INFORMACION IGUALMENTE SE ALMACENA Y NO SE DA NINGUNA UTILIDAD SE PLANTEARIA UNA REESTRUCTURACION DE DICHA INFORMACION ASI COMO TAMBIEN SU UTILIZACION EN UN MODELO PREDICTIVO LSTM	ANALITICA DE DATOS - MODELO LSTM
6	FALTA DE CONTROL DE CALIDAD	SE UTILIZARIA DISTINTAS TECNICAS DE CONTROL DE CALIDAD APOYADA DE LA ANALITICA DE DATOS PARA DESCUBRIR PATRONES QUE PERMITAN CONOCER TENDENCIAS DE CONSUMO DE INSUMOS Y MATERIA CON LO CUAL SE IDENTIFICARAN LAS CAUSAS DE LOS POSIBLES PROBLEMAS DE CALIDAD CON LA FINALIDAD DE ENRIADICARLOS	CONTROL PREVENTIVO CALIDAD MUESTREOS

Tabla 12: Listado propuestas

Fuente: Elaboración propia

b) Fase dos – Matriz FACTIS.

La finalidad de la matriz FACTIS será la priorización de las soluciones que serán más eficaces de implementarse, la ponderación será realizada con la tabla anterior algunos datos fueron proporcionados por el jefe de producción. Se numerará las causas raíz para posteriormente aplicar los criterios para definir el puntaje de 1,2 o 3 y se multiplicará por el factor de ponderación finalmente se ordenará para visualizar la ruta más crítica.

	Criterios de Selección	Factor de Ponderación
F	Facilidad para solucionarlo 1. Muy difícil 2. Difícil 3. Fácil	6
A	Afecta a otras áreas su implementación 1. Si 2. Algo 3. Nada	1
C	Mejora la calidad 1. Poco 2. Medio 3. Mucho	3
T	Tiempo que implica solucionarlo 1. Largo 2. Medio 3. Corto	5
I	Requiere inversión 1. Alta 2. Media 3. Poca	4
S	Mejora la seguridad 1. Poco 2. Medio 3. Mucho	2

Tabla 13: Criterios de selección

Fuente: Tesis PUCP

N	CRITERIOS DE SELECCION								TOTAL
			F	A	C	T	I	S	
1	FALTA DE PLANIFICACION DE LA PRODUCCION	CRITERIO	FACIL	ALGO	POCO	MEDIO	MEDIO	MUCHO	47
		PUNTAJE	3	2	1	2	2	3	
2	FALTA DE ESTABLECIMIENTO DE UN RITMO DE TRABAJO	CRITERIO	DIFICIL	ALGO	MEDIO	LARGO	MEDIA	MEDIO	37
		PUNTAJE	2	2	2	1	2	2	
3	USO EXCESIVO DE HORAS EXTRAS	CRITERIO	DIFICIL	SI	POCO	MEDIO	POCA	POCO	40
		PUNTAJE	2	1	1	2	3	1	
4	FALTA DE ORDEN EN AREA DE TRABAJO Y UTILIZACION DE ALMACENES	CRITERIO	DIFICIL	SI	MEDIO	LARGO	MEDIA	MEDIO	36
		PUNTAJE	2	1	2	1	2	2	
5	FALTA DE CONOCIMIENTO DE EVENTOS REPETITIVOS A SUCCEDER Y MANTENIMIENTOS	CRITERIO	FACIL	SI	MEDIO	LARGO	MEDIA	POCO	40
		PUNTAJE	3	1	2	1	2	1	
6	FALTA DE CONTROL DE CALIDAD	CRITERIO	DIFICIL	SI	MEDIO	LARGO	ALTA	MEDIO	37
		PUNTAJE	2	1	2	1	1	2	

Tabla 14: Matriz FACTIS

Fuente: Elaboración propia

Como resultado de la matriz FACTIS se obtiene la priorización de los las causas raíces N.º 1,2,3,4 junto con sus metodologías a aplicar.

CAUSA RAIZ	TOTAL	METODOLOGIA
FALTA DE PLANIFICACION DE LA PRODUCCION	47	ANALITICA DE DATOS (LSTM)
USO EXCESIVO DE HORAS EXTRAS	40	PROGRAMACION DE LA PRODUCCION
FALTA DE CONOCIMIENTO DE EVENTOS REPETITIVOS A SUCCEDER Y MANTENIMIENTOS	40	ANALITICA DE DATOS (LSTM)
FALTA DE ESTABLECIMIENTO DE UN RITMO DE TRABAJO	37	TACK TIME

Tabla 15: FACTIS prioridades

Fuente: Elaboración propia

CAPÍTULO 3. PROPUESTA DE MEJORA

En el presente capítulo se desarrollará la propuesta planteada para la mejora del proceso principal el cual es la producción del agua embotellada ya que los problemas se encuentran centrados en esta área y la carencia de la planificación productiva. La presente propuesta pretende solucionar el problema del incumplimiento de los pedidos. Problema, el cual se encuentra agravado debido a la creciente demanda que tiene actualmente en la empresa. Cabe resaltar que el nuevo sistema entrará en funcionamiento para la unidad de negocio de maquila de producto para sus 2 principales clientes Cencosud Retail S.A y Supermercados Peruanos S.A y podrá ser extensible a cualquier producto que se requiera fabricar posteriormente. Entre la causal de incumplimiento de pedidos se encuentran: Una inadecuada planificación de la demanda dada la variabilidad de esta, lo cual la realización de ajustes sucesivos a los pronostico requerirían una experticia estadística. Se realizan recálculos cada vez que se desarrolla una nueva planificación semanal. Lo cual se torna tedioso, requiere tiempo y principalmente no se cumple ni se utiliza, lo cual genera un inadecuado planeamiento que desemboca en perdidas monetarias por dicho motivo se realizará la implementación de un modelo de pronósticos que estará incluido en MPS (*Master Production Scheduling*) a través de una interfaz gráfica. Al inicio de este capítulo se definirá el set de datos (histórico) que se utilizará. Se realizará un estudio exploratorio, se identificará del tipo de serie temporal, su estacionalidad a través del análisis que se presentará a continuación para cada uno de los productos. Se validará las ventajas de la utilización de un modelo LSTM en comparación de los modelos Arima y Prophet los cuales se desarrollarán. Luego se planteará, entrenará, validará para finalmente realizar la predicción de la demanda semanal por venir presentada en la interfaz gráfica para manejo y uso de del personal de producción.

3.1 Calendario desarrollo del proyecto.

Se presenta el calendario del proyecto, en el cual se separa en 4 subgrupos: el análisis, el diseño, la implementación y el monitoreo y control. El cual comprenderá una extensión del proyecto de 56.5 días.

Comprendiendo la actividad con mayor duración el desarrollo del aplicativo y la más corta las reuniones de avance, el cual se ilustrará a continuación:

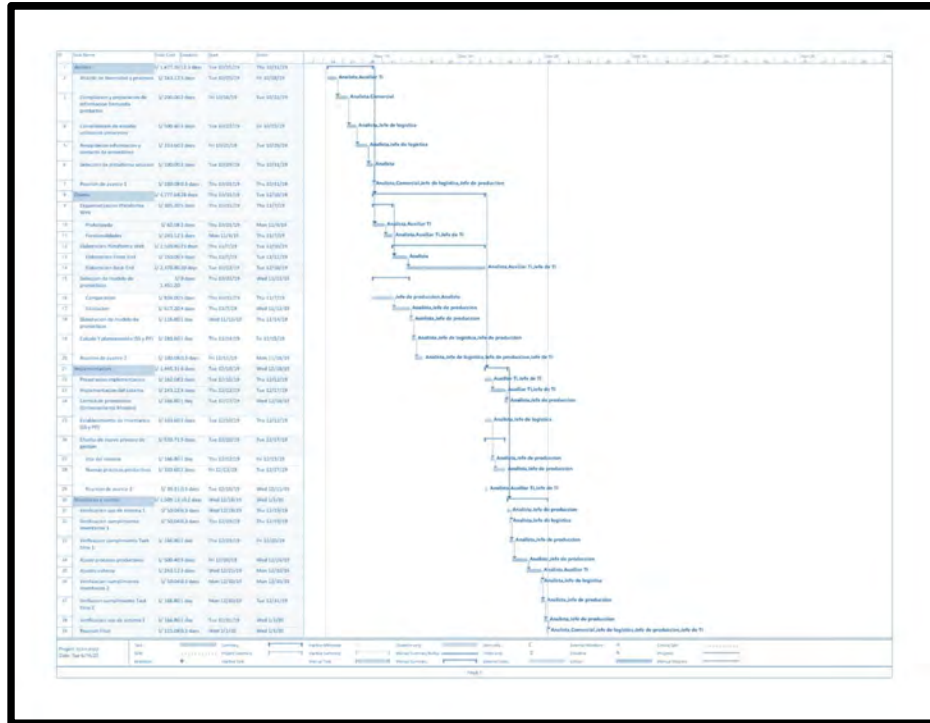


Ilustración 48: Calendario Proyecto

Fuente: Elaboración propia

En el presente estudio a fin de desarrollar la solución para la problemática actual de la empresa y permitir el ordenamiento de la producción iniciará con un análisis general de la demanda histórica de la empresa. Dicho estudio comenzará con un análisis descriptivo de la demanda histórica en la empresa, el cual estará compuesto por el análisis de las medidas de tendencia central y las medidas dispersión. Luego se realizará un análisis exploratorio grafico en el que se enfocará en el análisis de corrida (gráficos unidimensionales), grafico de puntos, histogramas y grafico de cajas. Como tercer ítem se realizará una gráfica ACF la cual estará incluida en el análisis del modelo Arima, la cual tiene como finalidad analizar la correlación. Finalmente se procederá con otorgar a los datos la forma final con la cual trabajará en nuestros modelos. Se continuará con una explicación breve de los 3 modelo escogidos a partir de nuestro análisis inicial.

Se evaluará y medirá su desempeño de cada uno de ellos para así seleccionar el modelo con el cual se trabajará, será esto sustentado en resultados. Se realizará el diseño de la solución para la empresa de estudio y explicará su funcionamiento. Finalmente, en el último capítulo se verificarán los beneficios económicos de la solución presentada a la empresa.

3.2 Análisis Descriptivo.

Se iniciará con un vistazo general de la información del presente set de datos de la demanda histórica con la que se cuenta para realizar los pronósticos correspondientes, la cual consiste en un arreglo de datos conformado por 1475 observaciones y 3 columnas: la fecha de pedido, el producto solicitado y la cantidad de paquetes solicitados. Debido a la semejanza de los productos Wong y Metro (varia etiqueta) son indiferentes para la producción, es decir se componen de los mismos elementos y el pedido es realizado en conjunto. Se realizó una agrupación respectiva obteniendo así el presente set de datos. Además, se eliminará producto Selfie dado a que no entra en nuestro “supuesto” para el esquema de producción “productos de maquila”. Sin embargo, en su ingreso a producción del aplicativo no existiría ningún impedimento para su anexo.

	fecha	producto	PRODTERMPQT
0	2020-02-29	Cencosud 7 L	378
1	2020-02-29	Cencosud 20 L	680
2	2020-02-29	Cencosud 20 L	461
3	2020-02-28	Bells 625 ml	627
4	2020-02-28	Cencosud 20 L	440
...
1734	2017-11-04	Bells 625 ml	492
1735	2017-11-04	Bells 380 ml	238
1736	2017-11-03	Bells 2.5 L	545
1737	2017-11-03	Bells 625 ml	217
1738	2017-11-02	Bells 2.5 L	1342

[1475 rows x 3 columns]
 ['Bells 2.5 L' 'Bells 625 ml' 'Bells 380 ml' 'Bells 20 L' 'Bells 550 ml'
 'Cencosud 20 L' 'Cencosud 625 ml' 'Cencosud 7 L']

Ilustración 49: Observaciones y Productos

Fuente: Elaboración propia

Se verifico además que cada uno de los tributos del set de datos esté en el tipo de datos adecuados fecha: ‘datetime’, producto: ‘string’ y prodtermpqt: ‘integer’.

3.2.1 Medidas de tendencia central.

Con la finalidad de dar inicio del análisis se procedió a obtener la presente información.

Bells 2.5 L		Bells 625 ml	
	PRODTERMPQT		PRODTERMPQT
count	635.000000	count	200.000000
mean	1024.872441	mean	822.275000
std	534.973605	std	460.566005
min	0.000000	min	85.000000
25%	683.000000	25%	448.500000
50%	873.000000	50%	768.000000
75%	1285.500000	75%	1060.000000
max	2674.000000	max	2369.000000

Ilustración 50: Medidas de Tendencia central

Fuente: Elaboración Propia

Se observa las medidas de tendencia central y se observa que Bells 2.5 L y Bells 625 ml son los productos con más pedidos realizados los cuales presentan una moda diaria demandada aproximada (por pedido) de 800 paquetes los demás pedidos tienen una moda aproximadamente de 400 paquetes por pedido. Con lo cual se infiere de que dichos productos tienen una mayor producción en la empresa frente al resto de productos.

3.2.2 Medidas dispersión.

Se procedió a un reporte de las medidas de dispersión tales como varianza el rango, el rango inter cuartil, el coeficiente de variación y la asimetría de Pearson, las cuales serán explicadas a continuación.

Bells 2.5 L	Bells 625 ml
Desv. Std: 534.5522000654647	Desv. Std: 459.413146715459
Rango: 2674	Rango: 2284
Rango Intercuartil: 602.5	Rango Intercuartil: 611.5
Coef. Variación: 0.5215792509481804	Coef. Variación: 0.5597098558456222
Asimetría: 0.8188862272634398	Asimetría: 0.7791606998838754

Ilustración 51: Medidas de dispersión

Fuente: Elaboración Propia

Tras el resultado se pudo encontrar una elevada desviación estándar de 534,55 y 459,41 paquetes correspondientes a los productos Bells en sus presentaciones de 2.5L y de 625 ml. Para el resto de los productos (observable en anexo) la medida es menor a los 350 paquetes. Lo cual nos da a entender de

que existe una mayor dispersión en el número de paquetes por pedido de ambos productos mencionados frente al resto de producto, con lo que se sabe de en estos son los que se generan mayor cantidad de abruptos e incumplimiento de pedidos, lo cual esta sumado a la vez por el número de paquetes solicitados. Tras observar la dispersión mediante el coeficiente de variación se pudo observar que, en su mayoría, los datos, cuentan con una dispersión del 50% a menos, sin embargo, en el caso de Cencosud 20L y 625ml ambos presentan una alta dispersión. Por último, al comparar la asimetría se observa que en general los datos tienden a estar pegados al lado derecho lo cual nos indicaría que cada uno de los pedidos son de una cantidad considerable, cabe resaltar de que el número de paquetes por pedido y la cantidad de observaciones generan que varié esta medida.

3.3 Análisis Exploratorio Grafico.

En el presente acápite se realizará una exploración grafica del conjunto de datos pertenecientes a la demanda histórica.

3.3.1 Gráficos unidimensionales.

Se realizarán los gráficos de corrida estos gráficos están de acuerdo a una secuencia diaria de producción.




Ilustración 52: Gráficos Unidimensionales

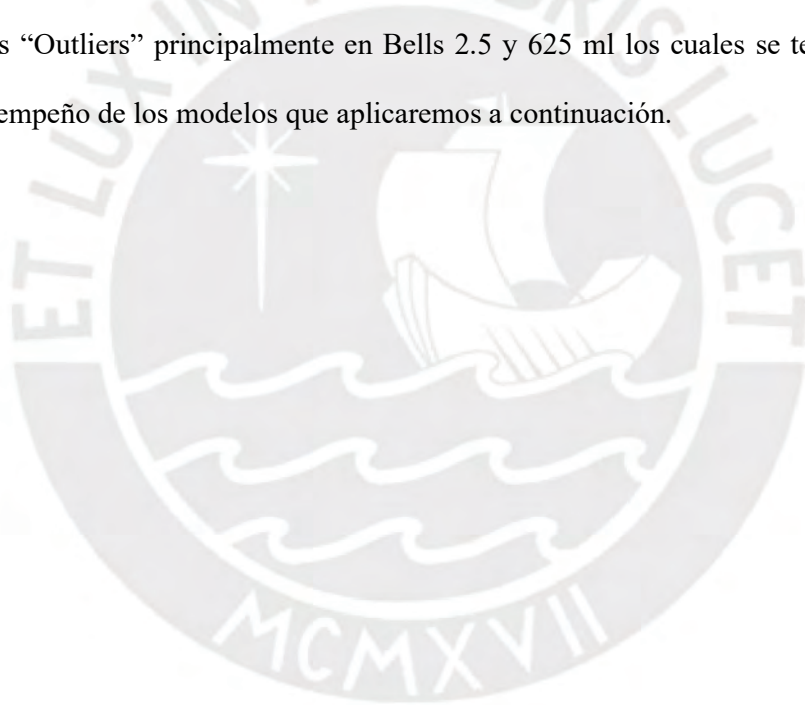
Fuente: Elaboración Propia

Se tiene una visualización general de la demanda por cada uno de los productos. Tras realizar las gráficas de corrida se pudo observar que el tipo de serie de tiempo que presenta nuestra demanda es del tipo aditiva para toda la familia de productos. Cabe resaltar que en Cencosud existe un vacío de pedidos

comprendido por el periodo de inicios del año 2019 (primer cuarto de año) lo cual coincide con el cese de la contratación por parte de Cencosud el cual se reapertura después de dicho periodo. Además, las gráficas de corridas permiten observar que para el caso de Bells 2.5 L y 625ml existe una mayor densidad en los datos de la demanda dado que son los que conforman los productos que tienen mayor demanda en la empresa.

3.3.2 Boxplot, DotPlot e Histogramas.

Se presenta el grafico de cajas y puntos en el cual se observa la distribución de las observaciones con la finalidad de ampliar el juicio sobre las medidas de dispersión antes tratadas. Cabe resaltar de que se observa algunos “Outliers” principalmente en Bells 2.5 y 625 ml los cuales se tendrán presente en el análisis del desempeño de los modelos que aplicaremos a continuación.






Ilustración 53: Boxplot

Fuente: Elaboración Propia

Como era de esperarse se presentan puntos “*outliers*” sin embargo estos son en una mínima proporción frente a la totalidad de los datos. Se observa en el histograma que la cantidad de paquetes por pedido en el presente grafico Bells 2.5L concentra la mayoría de los pedidos de 500 a 1250 y en el caso de Bells 625 ml, la gran totalidad de la cantidad de paquetes se concentran en 500 y 1000 por pedido, se realizó el mismo un estudio para el resto de productos. Cabe resaltar que se podría realizar una agrupación de acuerdo a los grupos de paquetes (cantidades) sin embargo esto causaría de que posiblemente se pierda sensibilidad en los modelos que se trabajaran a continuación.




Ilustración 54: Histogramas

Fuente: Elaboración Propia

Tras realizar el ploteo de los histogramas se pudieron identificar que existe una gran mayoría de los productos que no cumplen con el criterio de curva normal para el histograma dado esto se rechazaría su estacionalidad. Así se puede decir que solamente Bells 2.5L parece cumplir con dicho criterio, con la finalidad de comprobarlo se realizará el siguiente análisis a continuación. Dicho análisis se realizó igualmente para el resto de productos (observables en anexos).

3.4 Análisis series de tiempo.

En el presente acápite se analizará las series de tiempo compuestas por la demanda de productos de la empresa.

3.4.1 Descomposición.

Se ha podido observar que, tras realizar la descomposición aditiva, se permite observar con mayor detenimiento los distintos patrones de comportamiento que presentan la información histórica de cada uno de los productos de la empresa de manera desagregada pudiendo identificar claramente la tendencia y estacionalidad de las observaciones.

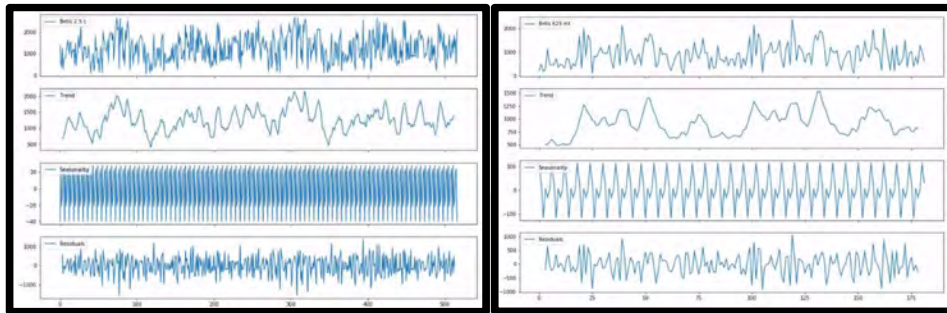


Ilustración 55: Descomposición Series de Tiempo

Fuente: Elaboración Propia

Tras realizar la descomposición aditiva en cada uno de los gráficos de corrida por producto se pudo observar las distintas tendencias, de las cuales ninguna es lineal, estacionalidades y los residuales correspondientes de Bells 2.5L y Bells 625ml. La presente descomposición fue realizada de igual manera a los demás productos (observable en anexos). Además, se concluye que ninguna es estacionaria con lo cual no se podría aplicar los modelos más generales para estimar la demanda sin antes realizar una previa transformación para convertir la demanda en estacionaria.

3.4.2 Estacionalidad.

Con la finalidad realizar un estudio más profundo y asegurarse de la no estacionalidad de las observaciones, se realizara un análisis cuantitativo mediante la siguiente función la cual separa mediante bloques de 20 datos de las observaciones para identificar si existe variaciones en la media y en la varianza (criterio de heterocedasticidad), posteriormente se realiza un ADF test con la finalidad de encontrar los más negativos que nos permite saber que tan estacionaria es la serie (si es que se cumple dicho criterio).

Con la finalidad de tener un valor cuantitativo para asegurar el presente criterio de estacionalidad se realizará una verificación del p-value en el cual demostrara si la serie es no estacionaria si este valor es

menor que 0.05. Tras la ejecución de la función se obtuvo los siguientes resultados:

```
#####Bells 2.5 L#####  
MEDIA[931.25, 1072.95, 761.95, 1627.7, 1525.35, 1188.4, 849.65, 940.0, 1090.1, 941.85, 684.7, 736.7, 755.95, 928.25, 1306.05, 1280.65, 1188.8, 1885.4, 1525.65, 1075.95, 1021.2, 1268.8, 1058.15, 1090.85, 813.0, 816.7, 790.4, 878.0, 684.85, 72  
4.15, 550.15, 728.2]  
VARIANZA[161767.8875, 233842.7475, 202593.04750000004, 256622.91, 525764.8274999999, 204628.44, 354287.8275, 185389.6, 158851.29, 30933.827500000003, 39195.81, 110449.00999999999, 8776.1475, 123455.6875, 365701.9475000  
0007, 264215.6275, 335711.96, 389023.14, 440109.52749999997, 488922.34750000015, 268077.06000000006, 337164.26000000007, 243612.72750000004, 37672.127499999995, 39982.6, 105437.61000000002, 26817.239999999998, 27091.9,  
48313.127499999995, 42378.427500000005, 45143.427500000005, 37050.82666666667]  
ad fuller test: -3.871701155458574  
pvalue:0.002253268571308172  
used lag:10  
nob:624  
critical_values: {'1%': -3.440873084361836, '5%': -2.866182929627575, '10%': -2.5692425987220577}  
icbtest:9256.655067176434
```

Ilustración 56: Criterios Estacionalidad

Fuente: Elaboración propia

Tras la realización la prueba de la hipótesis nula y el *test* ADF se pudo concluir que presentes datos no son del tipo estacionario por lo cual sería necesario aplicar distintas transformaciones para lograr dicha estacionalidad. Cabe resaltar de que hace falta un último estudio con la finalidad de hallar la autocorrelación de las observaciones, es decir las gráficas ACF lo cual será tratado en el acápite del modelo Arima estacional que se desarrollará posteriormente. Dicho modelo requiere de los valores hallados en las gráficas ACF/PACF con la finalidad de establecer los parámetros del modelo.

3.5 Preparación de datos.

Se realizó la siguiente preparación de las observaciones correspondientes al set de datos mostrado al inicio del presente acápite con la finalidad de un procesamiento más adecuado y de la automatización para el procesamiento de datos. El nuevo set de datos de la demanda histórica fue denominado *model.csv* (obtenido y posteriormente elaborado de las solicitudes de pedidos de la base de datos de la empresa) en el cual, el índice está conformado por las fechas y el resto de columnas está conformado por cada uno de los productos a analizar. Cabe resaltar que los días en los cuales no se realizaron pedidos fueron reemplazados por valores no nulos “0” además de rellenar fechas que no fueron registradas debido a que no se solicitaron pedidos dichos días, esto con la finalidad de mantener la continuidad de los datos. Finalmente se retiraron los valores atípicos con la fórmula presentada a continuación, siguiendo el siguiente procedimiento:

```
dat2=dat.loc[dat['producto'] == i ]
q3=dat2.quantile(0.75)
q1=dat2.quantile(0.25)
iqr=q3-q1
lower=q1-1.5*iqr
upper=q3+1.5*iqr
#print(i)
print(int(upper))
uppernum=int(upper)
```

Ilustración 57: Preparación de datos

Fuente: Elaboración Propia

$Upper=Q3+1.5*IQR$, en donde IQR representa el rango Inter cuartil y Q3 el tercer cuartil. Es necesario resaltar que dado la inexistencia de valores atípicos en $Lower=Q1-1.5*IQR$ es decir el límite inferior de los valores atípicos no se procedió a hacer reemplazo alguno en los valores. Dichos valores atípicos superiores fueron reemplazados por el valor de “Upper”.

```
df2[i]=np.where(df2[i]>uppernum,uppernum,df2[i])
```

Ilustración 58: Reemplazo de datos

Fuente: Elaboración Propia

Se remplazo con la presente función, la cual fue realizada para cada uno de los productos. Obteniendo por consecuente el siguiente conjunto de datos listo para la implementación de los modelos.

producto	Bells 2.5 L	Bells 20 L	Bells 480 ml	Bells 880 ml	Bells 825 ml
2017-11-02	1342.0	0.0	0.0	0.0	0.0
2017-11-03	545.0	0.0	0.0	0.0	217.0
2017-11-04	375.0	0.0	238.0	0.0	492.0
2017-11-05	1263.0	0.0	0.0	0.0	0.0
2017-11-06	283.0	76.0	0.0	0.0	194.0
...
2020-02-25	0.0	80.0	0.0	0.0	0.0
2020-02-26	0.0	360.0	0.0	485.0	0.0
2020-02-27	0.0	0.0	515.0	0.0	1013.0
2020-02-28	0.0	0.0	0.0	0.0	627.0
2020-02-29	0.0	0.0	0.0	0.0	0.0

producto	Cencosud 20 L	Cencosud 625 ml	Cencosud 7 L
2017-11-02	0.0	0.0	0.0
2017-11-03	0.0	0.0	0.0
2017-11-04	0.0	0.0	0.0
2017-11-05	0.0	0.0	0.0
2017-11-06	0.0	0.0	0.0
...
2020-02-25	227.0	0.0	0.0
2020-02-26	0.0	0.0	0.0
2020-02-27	0.0	0.0	0.0
2020-02-28	440.0	0.0	0.0
2020-02-29	461.0	0.0	378.0

[850 rows x 8 columns]

Ilustración 59: Datos Preparados

Fuente: Elaboración Propia

Cabe resaltar para fines de entendimiento de los modelos, la secuencia de los datos es de tipo diario. La suma de los días generaría la producción semanal debido a que en la recepción de pedidos estos son hechos en tramos, es decir en una semana se generan 1, 2 hasta 3 pedidos de cada producto ya que sobre este se realizan correcciones y adecuaciones (aumentos generalmente).

3.6 Modelado y Validación.

Se observa una corrida de datos iniciales para cada uno de los productos, cabe mencionar que el espacio de tiempo de los pedidos es de orden diario, cómo se puede observar en los siguientes gráficos. Es importante mencionar que para la comparación entre los datos reales y las predicciones se hizo una separación entre la totalidad de los datos el cual se encuentra en una proporción de 1 para los datos de testeo y como 3 para los datos de entrenamiento de cada uno de los modelos, además de mencionar que los datos suministrados para cada uno de los 3 modelos son los mismos y en la ejecución cada producto se procesa por separado, es decir el producto A no afecta sobre el producto B.

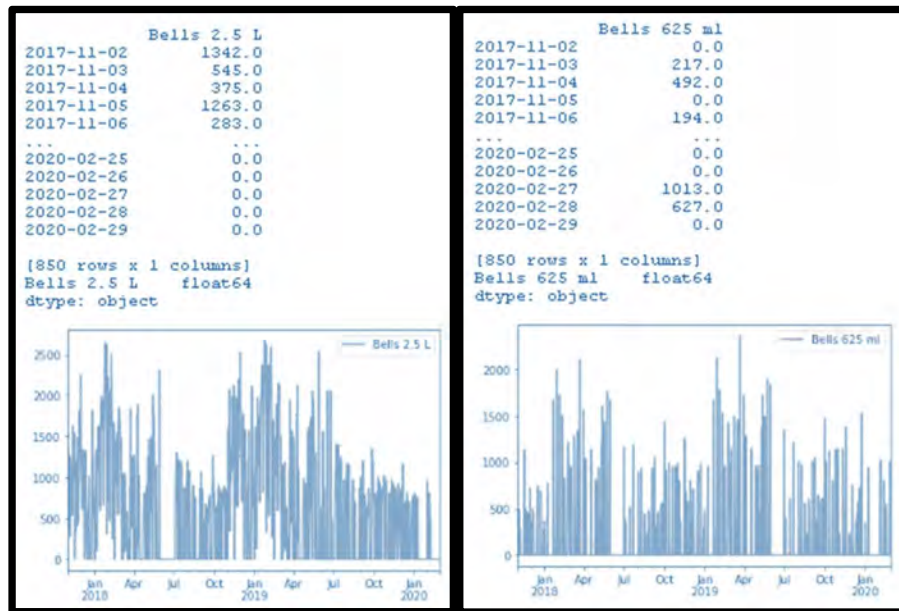


Ilustración 60: Corrida de datos

Fuente: Elaboración Propia

A continuación, se procederá con el modelado.

3.6.1 Arima.

Dado que nuestro set de datos no cumple con la estacionalidad, se podría aplicar un modelo *Sesonal-Arima* el cual permitirá trabajar con nuestra demanda afectada por la tendencia de la estacional, la cual es una de las consideraciones que se tiene. Para el fin de la presente tesis se apoyará de *Auto Arima*, el cual es un paquete que tiene como finalidad optimizar los valores de p , q y d para de reducir el RSME como comparativo final de los distintos modelos. Es decir, se utilizará dicho modelo para realizar la predicción y se comparará con los datos reales de la demanda. Cabe resaltar que debido a la finalidad de automatización del proceso se eligió el presente modelo *Auto Arima* el cual se encargara de la obtención de los parámetros siendo el modelo el cual encargara de esta parte del procesamiento.


```
datanew = pd.read_csv(pathtofile, header=0, parse_dates=[0], index_col=0, squeeze=True, dtype=float)
```

Ilustración 61: Lectura de datos-Arima

Fuente: Elaboración Propia

Se procedió a leer la información del archivo modelo previamente elaborado y se verifico distintos parámetros para asegurar su correcta lectura de los datos.

```
datanew = datanew.resample('D').ffill()  
brand=datanew[[product]]  
  
print (brand)  
print (brand.dtypes)  
brand.plot()  
plt.show()  
  
print (brand)  
  
name=brand.keys()  
X = brand.values
```

Ilustración 62: Separación de datos-Arima

Fuente: Elaboración Propia

Se realizo un reordenamiento diario con fines de verificación ya que se había trabajado esto en el preprocesamiento con la finalidad de mantener la continuidad de las observaciones. Se registro las cabeceras de los datos en la variable “name” y en la variable “X” se guardó los valores de cada una de las fechas, es decir, la cantidad de paquetes.

```
train_size = int(len(X) * 0.67)  
test_size = len(X) - train_size  
date=brand.index[train_size]  
print (date)  
  
train = brand.loc[:date]  
test = brand.loc[date:]
```

Ilustración 63: Partición Testeo Entreno-Arima

Fuente: Elaboracion Propia

Se procedió a separar la información en observaciones de entreno (para el modelo) y de testeo lo que se convertirá en la gráfica en las líneas azules, para observaciones reales y las naranjas las cuales será la información obtenida del modelo.

```
print('Train Set contains:', len(train), 'datapoints')
print('Test Set contains:', len(test), 'datapoints')
```

Ilustración 64: Verificación partición-Arima

Fuente: Elaboración Propia

Con la finalidad de verificar el funcionamiento, se procedió a mostrar la longitud de la información de testeo y de entrenamiento lo cual cumple la relación de 1 a 3.

```
stepwise_model = auto_arima(brand, start_p=1, start_q=1, test='adf',
                             max_p=3, max_q=3, m=52, #####CHEQUAR VALOR
                             start_p=0, seasonal=True,
                             d=1, D=1, trace=True,
                             error_action='ignore',
                             suppress_warnings=True,
                             stepwise=True)

print(stepwise_model.aic())
print(stepwise_model.summary())
stepwise_model.plot_diagnostics(figsize=(8,8))
plt.show()

stepwise_model.fit(train)
```

Ilustración 65: Modelo-Arima

Fuente: Elaboración Propia

Se alimenta el modelo presentado con el arreglo de observaciones denominado “*brand*” el cual representan el número de paquetes. A continuación, se especifican los parámetros límites en el cual el modelo empezara a buscar dichos parámetros para optimizar el modelo correctamente. Se hace referencia al parámetro *start_p* como valor de inicio de “*p*” en el modelo Arima, igualmente para el caso de *start_q*, el test usado para la estacionalidad será el *test ad Fuller* “*ADF*”, posteriormente se especifica el “*max_p*” y “*max_q*”, así el modelo no superará estos valores. Cabe resaltar de que la elección de los presentes valores fue tomada en base a la experiencia de elaboración de distintos modelos de predicción de demandas usando el presente paquete, obteniendo así los mejores resultados posibles. Se activa el parámetro “*seasonal*” con la finalidad que el modelo tenga presente que la serie no es estacional y se

especifican los valores de d y D como 1, el cual hace el número de diferenciaciones que se aplican al conjunto de datos. El parámetro $m=52$ hace referencia a que se estará trabajado en un sistema semanal. El resto de configuración fue establecido a sus valores por defecto. Finalmente se muestra un reporte del modelo elegido y del error AIC el paquete buscara la minimización de este valor. Finalmente se carga el modelo con el método “. fit ()” para así iniciar con los cálculos

```
future_forecast = stepwise_model.predict(n_periods=test_size)
print(future_forecast)
future_forecast = pd.DataFrame(future_forecast,index = test.index,columns=['Prediction'])
```

Ilustración 66: Predicción-Arima

Fuente: Elaboración propia

La variable “future_forecast” almacena las predicciones realizadas, en el cual finalmente serán convertidas a un “DataFrame” para su posterior de visualización.

```
print(test[product])
print(future_forecast['Prediction'])
arima_rmse_error = rmse(test[product], future_forecast['Prediction'])
arima_mse_error = arima_rmse_error**2
mean_value = test[product].mean()
print(f'MSE Error: {arima_mse_error}\nRMSE Error: {arima_rmse_error}\nMean: {mean_value}')
```

Ilustración 67: Calculo RMSE-Arima

Fuente: Elaboración Propia

Se calcula el error cuadrático medio RSME mediante la presente formulación:

```
title=str(product)+"--"+"RMSE: "+str(arima_rmse_error)
#print(title)
fig= plt.figure(figsize=(10,3))
plt.title(title)
plt.ylabel('PQTS')
plt.xlabel('Fechas')
plt.plot(test[product], color='b', label='Real')
plt.plot(future_forecast['Prediction'], color='orange', label='Prediccion')
plt.show()
```

Ilustración 68: Ploteo-Arima

Fuente: Elaboración Propia

Finalmente, se plotea la gráfica correspondiente al modelo en donde se compara las predicciones y los datos de reales con la finalidad de obtener un contraste y validar los resultados.

SARIMAX Results							
Dep. Variable:	y					No. Observations:	850
Model:	SARIMAX(1, 1, 1)x(1, 1, 1, 52)					Log Likelihood	-6201.468
Date:	Tue, 12 May 2020					AIC	12414.936
Time:	21:42:32					BIC	12443.022
Sample:	0					HQIC	12425.727
	- 850						
Covariance Type:	opg						
	coef	std err	z	P> z	[0.025	0.975]	
intercept	-0.1329	0.495	-0.268	0.788	-1.103	0.837	
ar.L1	0.2410	0.040	5.986	0.000	0.162	0.320	
ma.L1	-0.8916	0.018	-48.254	0.000	-0.928	-0.855	
ar.S.L52	-0.0731	0.041	-1.777	0.076	-0.154	0.008	
ma.S.L52	-0.9707	0.165	-5.885	0.000	-1.294	-0.647	
sigma2	2.939e+05	4.44e+04	6.626	0.000	2.07e+05	3.81e+05	
Ljung-Box (Q):			145.50	Jarque-Bera (JB):		16.36	
Prob(Q):			0.00	Prob(JB):		0.00	
Heteroskedasticity (H):			0.79	Skew:		0.26	
Prob(H) (two-sided):			0.05	Kurtosis:		3.46	

Ilustración 69: Summary-Arima

Fuente: Elaboración propia

En el presente reporte se logra visualizar la optimización que realizó el paquete con la finalidad de obtener los mejores parámetros para el presente modelo Arima estacional (*Sesonal Arima*) cabe resalta que el paquete usado para llegar a la optimización fue (*pmdarima*), se encuentra en distintos ERP de gran renombre tales como Oddo (*Open ERP*), frePPLE entre otros. Entre la información más resaltante se encuentra los parámetros del modelo p, q y d. Los valores p es correspondiente al efecto de los valores pasados en el modelo, este fue de 1 el cual hace referencia al dato inmediato posterior, el parámetro d es la cantidad de diferenciación la cual fue establecido a 1 dado la experiencia en distintos modelos antes trabajados ,es decir las diferenciaciones que se realizaran con la finalidad de eliminar la estacionalidad y el q de 1 correspondiente a el valor de que permite especificar el error de nuestro modelo como una combinación de los errores de los valores en el pasado. En el presente caso debido a que el modelo a utilizar tendrá en consideración la parte estacional se seguirá una lógica similar en el caso de (P, D, Q) s que son los componentes visualizables en el segundo paréntesis del modelo con la adición del término

de “s” el cual hace referencia a la periodicidad de las series de tiempo 4 para cuatrimestres ,12 para anual y así sucesivamente¹.

A continuación, se muestra las gráficas obtenidas como parte del reporte y la gráfica de corrida en el cual se confronta las predicciones y los datos reales

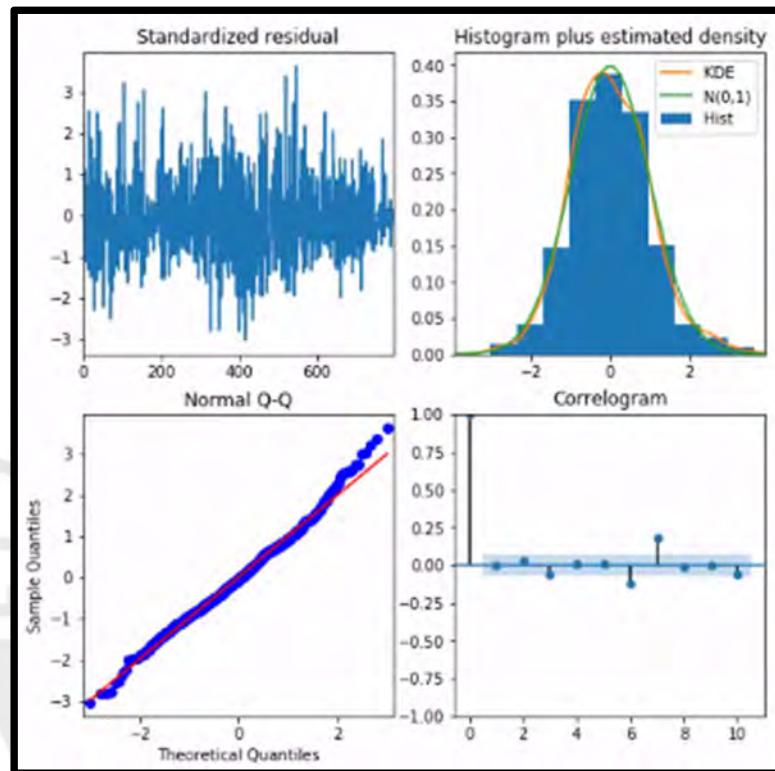


Ilustración 70: Correlograma-Arima

Fuente: Elaboracion Propia

¹ Documentación modelo Arima: <http://alkaline-ml.com/pmdarima/>

Se visualiza los residuales estandarizados y el correlograma, además del grafico de probabilidad de comparación de cuantiles Normal Q-Q y la curva ajustada al histograma como información adicional de los parámetros calculados por el paquete la toma de su decisión.




Ilustración 71: Grafica Predicción-Arima

Fuente: Elaboración propia

Finalmente, la presente aplicación del modelo lleva a concluir que se tuvo un buen desempeño dado que esto se observa en los distintos productos, sin embargo, en el caso de los productos de Cencosud el modelo Arima falla para la obtención de los pronósticos posiblemente ya que estos no tienen el mismo grado de continuidad como en el caso de Bells, el modelo se precipita a 0 lo cual no nos da una buena predicción para esta última familia de productos. Referente a la autocorrelación tras convertir los datos a estacionarios se pudo concluir que esta existe una correlación significativa en el primer desfase ya que dicho valor fue establecido previamente en la configuración previa del modelo, lo cual es válido para cada uno de los productos.

3.6.2 Prophet.

Como se observa esta implementación no requiere algún de procesamiento adicional, salvo el otorgado al modelo antes mencionado es en esto en que recae la facilidad de su implementación y manejo. Se evidencia su principal fortaleza del presente modelo en el manejo de tendencias y estacionalidades. Se observa fragmentos del modelo elaborado y se inicia con la corrida del presente algoritmo obteniendo los siguientes resultados.

```
#modelo phobet
from fbprophet import Prophet
import pandas as pd
import numpy as np
import matplotlib
import matplotlib.pyplot as plt
import seaborn as sns
import math
from sklearn.metrics import mean_squared_error
from statsmodels.tools.eval_measures import rmse
import warnings
import cufflinks as cf
cf.go_offline()
cf.set_config_file(offline=False, world_readable=True)
```

Ilustración 72: Librerías-Prophet

Fuente: Elaboración propia

Se muestran las siguientes librerías entre las cuales ponemos renombrar a 'fbprophet' el cual es el modelo en sí.

```
df = df.resample('D').ffill()
df_pr =df.reset_index()
brand=df[['product']]
print(brand)
```

Ilustración 73: Verificación-Prophet

Fuente: Elaboración propia

Se realiza un similar procesamiento de la información dado que se utilizará un modelo para cada producto y es necesario de que se seleccione dicha columna del set de datos.

```

df_pr = brand.reset_index()

print(df_pr)
df_pr.columns = ['ds', 'y']
print(len(df_pr))
train_size = int(len(df_pr) * 0.67)
test_size = len(df_pr) - train_size

train_data_pr = df_pr.iloc[:train_size]
test_data_pr = df_pr.iloc[train_size:]

```

Ilustración 74: Preparación-Prophet

Fuente: Elaboración propia

Aquí se realiza la transformación requerida para alimentar al modelo, el cual consiste en un reseteo del índice y el renombramiento de las columnas. En el cual el índice del tiempo se llamará ‘ds’ y los valores se almacenarán en la columna ‘y’, se realizará la separación habitual de la proporción de 1 a 3 para los datos de entonamiento y de testeo.

```

print('Train Set contains:', len(train_data_pr), 'datapoints')
print('Test Set contains:', len(test_data_pr), 'datapoints')
print(train_data_pr)
print("#####")
print(test_data_pr)
m = Prophet(weekly_seasonality=True, daily_seasonality=True, yearly_seasonality=True)
m.fit(train_data_pr)

```

Ilustración 75: Configuración modelo - Prophet

Fuente: Elaboración propia

El modelo será almacenado en la variable “m” cabe resaltar de que se activan las estacionalidades ‘weekly’, ‘daily’ y ‘yearly’ con la finalidad de capturar dichos patrones en caso de que las observaciones lo contengan.

```

length_test=len(test_data_pr)

future = m.make_future_dataframe(periods=length_test, freq='D')
#future = m.make_future_dataframe(periods=12, freq='MS')
prophet_pred = m.predict(future)
prophet_pred

prophet_pred = pd.DataFrame({"Date" : prophet_pred[-length_test:]['ds'],
                             "Pred" : prophet_pred[-length_test:]['yhat']})
print(prophet_pred)

prophet_pred = prophet_pred.set_index("Date")
prophet_pred.index.freq = "D"
prophet_pred

prophet_pred.shape

```

Ilustración 76: Predicción - Prophet

Fuente: Elaboración propia

La variable “*future*” almacenara las predicciones encontradas, en el cual las estacionalidades contarán de una frecuencia diaria y los periodos a pronosticar serán de longitud igual que las observaciones de testeo, dado a que son diarios. Se alimenta al modelo ya entrenado y se lo almacena en la variable “*prophet_pred*”, Por último, se reinserta el índice diario.

```
test_data = pd.DataFrame(columns = ['Prophet_Predictions'])
prophet_pred['Pred'].values
test_data["Prophet_Predictions"] = prophet_pred['Pred'].values
```

Ilustración 77: Almacenamiento predicción - Prophet

Fuente: Elaboración propia

Se genera un nuevo *DataFrame* con la columna ‘*Prophet_Predictions*’

```
mean_value = test_data["Prophet_Predictions"].mean()
print(f'MSE Error: {prophet_mse_error}\nRMSE Error: {prophet_rmse_error}\nMean: {mean_value}')
title=str(product)+"--"+RMSE: "+str(prophet_rmse_error)
fig= plt.figure(figsize=(10,3))
print(test_data_pr['y'])
testeo=pd.DataFrame(test_data_pr['y'].values,index = test_data_pr['ds'],columns=['Test'])
real=pd.DataFrame(test_data["Prophet_Predictions"].values,index = test_data_pr['ds'],columns=['Prediccion'])
```

Ilustración 78:RMSE - Prophet

Fuente: Elaboración propia

Finalmente se calcula la métrica de error correspondiente y nuevamente se genera 2 nuevos *DataFrames* con la finalidad de realizar la comparación.

```
plt.plot(testeo, color='b', label='Real')
plt.plot(real, color='orange', label='Prediccion')

plt.title(title)
plt.ylabel('PQTS')
plt.xlabel('Fecha')
plt.show()
```

Ilustración 79: Ploteo-Prophet

Fuente: Elaboración propia

Tras esto se procede a plotear las distintas graficas para la visualización y comparación de la información.





Ilustración 80: Grafica Predicción

Fuente: Elaboración propia

Se procedió a realizar el modelamiento con Prophet tras esto se pudo verificar y concluir que existe un ajuste regular en la corrida de datos de este modelo de fácil implementación. Sin embargo, el presente modelo falla en la captura de la estacionalidad entre varios de los distintos productos, además no se verifica que la tendencia este de acuerdo con los datos reales.

3.6.3 LSTM.

El presente modelo LSTM el cual se explica en la presente tesis estará basado en el API 'Keras' el cual apoyará, facilitará el procesamiento y elaboración del modelo en la presente tesis.

```

datanew = pd.read_csv(pathtofile, header=0, parse_dates=[0], index_col=0, squeeze=True, dtype=float)
datanew = datanew.resample('D').ffill()
brand=datanew[product]
print(brand)
print(brand.dtypes)
brand.plot()
plt.show()

X = brand.values
print(X)
print(X.dtype)

```

Ilustración 81: Lectura de observaciones - LSTM

Fuente: Elaboracion propia

Se procede con la lectura del archivo 'model.csv' que comprende la totalidad de las observaciones y se prosigue con el relleno y verificación del índice diario de estas. Posteriormente, se realiza la separación de la columna que contiene el primer producto dado que se analizará uno por uno. Cabe resaltar de que se extrae los valores puros con la finalidad de realizar su procesamiento.

```
X = brand.values
print(X)
print(X.dtype)

train_size = int(len(X) * 0.67)
test_size = len(X) - train_size
train, test = X[0:train_size,:], X[train_size:len(X),:]
print('Train Set contains:', len(train), 'datapoints')
print('Test Set contains:', len(test), 'datapoints')
```

Ilustración 82: Partición de datos - LSTM

Fuente: Elaboracion propia

Se realiza la repartición en datos de testeo y datos reales en la proporción de 1 a 3 el cual es igual en todos los modelos y se muestra la cantidad para fines de verificación.

```
#TRANSFORMAR A SUPERVISED LEARNING
def timeseries_to_supervised(data, lag=1):
    df = pd.DataFrame(data)
    columns = [df.shift(i) for i in range(1, lag+1)]
    columns.append(df)
    df = pd.concat(columns, axis=1)
    df.fillna(0, inplace=True)
    return df
```

Ilustración 83: Transformación a Supervised - LSTM

Fuente: Elaboracion propia

La finalidad de la transformación a *Supervised Learning* es debido que permite que tras el cambio de una variable X_t esta genere una respuesta en la variable X_{t+1} es decir una especie de $x \rightarrow y$, "x" genera "y" tomando en cuenta la temporalidad es decir aquí se generara un arreglo, el cual la primera columna se encuentran los valores de X_t y en la segunda se encuentran los valores X_{t+1} .


```

supervised = timeseries_to_supervised(X, 1)
print(supervised.head())

#TRANSFORMACION A ESTACIONARIO

```

Ilustración 84: Demostración transformación - LSTM

Fuente: Elaboración propia

Se puede verificar con el siguiente comando que genera la llamada de la función.

```

#CUANTO CUANTO AUMENTA ENTRE PERIODOS
def difference(dataset, interval=1):
    pd.diff = list()
    for i in range(interval, len(dataset)):
        value = dataset[i] - dataset[i - interval]
        pd.diff.append(value)
    return pd.Series(pd.diff)

```

Ilustración 85: Diferenciación - LSTM

Fuente: Elaboración propia

Con la finalidad que el modelo capture los aumentos o disminuciones del número de paquetes solicitados con respecto a la medida anterior se requiere que esté realice una diferenciación, que a su vez generará a que la serie se convierta en estacionaria con la finalidad de mejorar el aprendizaje del modelo.

```

#PARA EL FINAL INVERTIR EL CAMBIO
def inverse_difference(history, yhat, interval=1):
    return yhat + history[-interval]

```

Ilustración 86: Invertir diferenciación - LSTM

Fuente: Elaboración propia

La presente función generada se encargará, al final del procesamiento, de invertir la diferenciación esto con la finalidad de poder comparar los datos obtenidos frente a los datos de testeo. Se realizará tras obtener las predicciones.


```

def scale(train, test):
    # fit scaler
    scaler = MinMaxScaler(feature_range=(-1, 1))
    scaler = scaler.fit(train)
    # transform train
    train = train.reshape(train.shape[0], train.shape[1])
    train_scaled = scaler.transform(train)
    # transform test
    test = test.reshape(test.shape[0], test.shape[1])
    test_scaled = scaler.transform(test)
    return scaler, train_scaled, test_scaled

```

Ilustración 87: Escalado - LSTM

Fuente: Elaboración propia

La función “Scale” permitirá escalar, es decir convertir los incrementos o decrementos entre los datos X_t y X_{t+1} en valores que se encuentren entre -1 y 1 esto con la finalidad que los valores que sean recibidos por la red LSTM se encuentra la función tanh la cual recibe valores dentro de este parámetro; dado esto, es necesario de que los valores se encuentren dentro de -1 y 1.

```

def invert_scale(scaler, X, value):
    new_row = [x for x in X] + [value]
    array = np.array(new_row)
    array = array.reshape(1, len(array))
    inverted = scaler.inverse_transform(array)
    return inverted[0, -1]

```

Ilustración 88: Invertir Escalado - LSTM

Fuente: Elaboración propia

Se genero la función “invert_scale” con la finalidad de que, tras la predicción dichos valores, estos esten entre -1 y 1 lo cual es incomparable con los datos de testeo. Por este motivo, tras la obtención de los valores predichos se procesará con la presente función, lo cual nos dará los datos diferenciados; es decir, los incrementos entre X_t y X_{t+1} .

```

#####
def fit_lstm(train, batch_size, nb_epoch, neurons):
    X, y = train[:, 0:-1], train[:, -1]
    X = X.reshape(X.shape[0], 1, X.shape[1])
    model = Sequential()
    model.add(LSTM(neurons, batch_input_shape=(batch_size, X.shape[1], X.shape[2]), stateful=True))
    model.add(Dense(1))
    model.compile(loss='mean_squared_error', optimizer='adam')
    for i in range(nb_epoch):
        #####
        model.fit(X, y, epochs=1, batch_size=batch_size, verbose=0, shuffle=False)
        #####
        model.reset_states()

    #####
    return model
#####

```

Ilustración 89: Carga de modelo - LSTM

Fuente: Elaboración propia

La función “*fit_lstm*” permite que el modelo se cargue con los patrones de la demanda. Tras esto, se realiza el entrenamiento del modelo. Se especifica qué tipo de modelo se empleará, se otorga previamente la forma requerida para el ingreso de los datos, que consiste en el arreglo: [tamaño de lote, pasos de tiempo, dimensión]. Se configuro el tamaño de lote a 1 debido a que dada la extensión de las observaciones no sería necesario generar alguna separación; sin embargo, el valor podría variar para adaptarse a contener un número mayor de observaciones. Los pasos de tiempo serán considerados como 1 dado que las predicciones van de 1 en 1. Finalmente, la dimensión del ingreso será el vector observaciones. El parámetro “*epochs*” será establecido a 1 como por defecto sin embargo este será remplazado cuando se ejecute la función al valor de 350 el cual arrojó el menor RMSE.




Ilustración 90: Dimensión modelo

Fuente: Elaboración propia

```

#PREDICCIÓN
def forecast_lstm(model, batch_size, X):
    X = X.reshape(1, 1, len(X))
    yhat = model.predict(X, batch_size=batch_size)
    return yhat[0,0]

```

Ilustración 91: Predicción y forma - LSTM

Fuente: Elaboración propia

La función predicción se encargará básicamente, tras el entrenamiento del modelo, de generar la predicción teniendo en cuenta la misma longitud de los datos de testeo ya que así podrá ser comparable.

```

raw_values = brand.values

diff_values = difference(raw_values)
#MUESTRA LA DIFERENCIA DE t - t-1

#CONVIERTE A LOS t-1 COMO UN X y a los t COMO EL Y
supervised = timeseries_to_supervised(diff_values, 1)
supervised_values = supervised.values

train_size = int(len(supervised_values) * 0.67)
test_size = len(supervised_values) - train_size
train, test = supervised_values[0:train_size,:], supervised_values[train_size:len(supervised_values),:]

print("#####")

```

Ilustración 92: Transformación y partición - LSTM

Fuente: Elaboración propia

Se presenta la corrida del modelo en el cual inicia con la extracción de los valores, al cual denominaremos ‘raw_values’ o mejor dicho valores en crudo. Tras esto se diferencian los valores con la función antes elaborada. Dichos datos diferenciados, es decir los incrementos o decrementos del X_t y el X_{t+1} son convertidos a datos supervisados es decir una especie de “X” a “Y”, tras esto los valores son almacenados en la variable ‘supervised_values’ en la cual se realiza la partición de los datos. Los datos de testeo y datos de entrenamiento tienen la proporción de 1 a 3 tal como fue mencionado y usado en el resto de modelos anteriormente.

```

# ESCALAR LA DATA PARA EL LSTM entre -1 y 1
scaler, train_scaled, test_scaled = scale(train, test)
#####
epochs=350
lstm_model = fit_lstm(train_scaled, 1, epochs, 1)
#####
train_reshaped = train_scaled[:, 0].reshape(len(train_scaled), 1, 1)
lstm_model.predict(train_reshaped, batch_size=1)
#lstm_model.predict(train_reshaped, batch_size=1)

predictions = list()

```

Ilustración 93: Escalado de la diferenciación - LSTM

Fuente: Elaboración propia

Tras la separación de los valores de entrenamiento y testeo se escalan dichos valores, se especifica la cantidad de épocas “hiper parámetros del modelo, configurable a través de prueba y error” (Brownlee, 2018). En este caso fue escogido dicho valor ya que fue el que nos permitió tener un menor valor en el error cuadrático medio.

```

for i in range(len(test_scaled)):

    X, y = test_scaled[i, 0:-1], test_scaled[i, -1]
    #yhat = y #PROBAR QUE ESTE SIEN
    yhat = forecast_lstm(lstm_model, 1, X)

    yhat = invert_scale(scaler, X, yhat)

    yhat = inverse_difference(raw_values, yhat, len(test_scaled)+1-i)

    predictions.append(yhat)
    expected = raw_values[len(train) + i + 1]
    print('Dia=%d, Prediccion=%f, Esperado=%f' % (i+1, yhat, expected))

rmse = math.sqrt(mean_squared_error(raw_values[-len(test):], predictions))
print('Test RMSE: %.2f' % rmse)

```

Ilustración 94: Almacenado de respuesta y RMSE - LSTM

Fuente: Elaboración propia

Se genera el bucle ‘for’ con la finalidad de poder realizar una comparación día a día de cada una de las observaciones las cuales se observan en la parte inferior. Entiéndase ‘yhat’ como la variable que contendrá las predicciones, siendo estos los datos de testeo. Los datos que salen directo del modelo y es necesario de que pase por una des estandarización (se transformen los valores de -1 y 1), posteriormente es requerido también, que se deshaga la diferenciación. Tras esto dichas predicciones serán almacenadas en la variable “predictions” así se podrá visualizar el valor real de las predicciones y proceder con su

comparación. En la última línea se observa la fórmula empleada para obtener el ‘*RMSE*’ en el cual se compararán los valores reales extraído de “*raw_values*” y los valores predichos almacenados en ‘*predictions*’.

```

title=str(product)+"--"+RMSE:"+str(rmse)

#####

fig= plt.figure(figsize=(10,3))
print(brand[-len(test):].index)

real=pd.DataFrame(raw_values[-len(test):],index = brand[-len(test):].index,columns=['Test'])
testeo=pd.DataFrame(predictions,index = brand[-len(test):].index,columns=['Prediccion'])

print(testeo)
print(real)

plt.plot(real, color='b', label='Real')
plt.plot(testeo, color='orange', label='Prediccion')

plt.title(title)
plt.ylabel('PQTS')
plt.xlabel('Fecha')
plt.show()

```

Ilustración 95: Ploteo - LSTM

Fuente: Elaboración propia

Se realiza la conversión de los datos los cuales no cuentan con un formato adecuado para el ploteo, en los *Dataframe* real y testeo respectivamente. Finalmente, se procede a realizar el ploteo de los gráficos el cual se genera para cada uno de los productos.

Dia=102, Prediccion=604.938699, Esperado=478.000000
Dia=103, Prediccion=452.858513, Esperado=894.000000
Dia=104, Prediccion=603.334592, Esperado=0.000000
Dia=105, Prediccion=357.785956, Esperado=1206.000000
Dia=106, Prediccion=824.814148, Esperado=0.000000
Dia=107, Prediccion=471.411527, Esperado=0.000000
Dia=108, Prediccion=372.512066, Esperado=0.000000
Dia=109, Prediccion=314.904022, Esperado=594.000000
Dia=110, Prediccion=505.754472, Esperado=790.000000
Dia=111, Prediccion=575.542705, Esperado=452.000000
Dia=112, Prediccion=487.701332, Esperado=0.000000
Dia=113, Prediccion=338.064399, Esperado=0.000000
Dia=114, Prediccion=288.470396, Esperado=0.000000
Dia=115, Prediccion=253.352677, Esperado=543.000000
Dia=116, Prediccion=431.262722, Esperado=656.000000
Dia=117, Prediccion=473.737533, Esperado=523.000000
Dia=118, Prediccion=443.910525, Esperado=864.000000
Dia=119, Prediccion=570.517032, Esperado=810.000000
Dia=120, Prediccion=558.721705, Esperado=788.000000
Dia=121, Prediccion=561.947019, Esperado=0.000000
Dia=122, Prediccion=343.652657, Esperado=176.000000
Dia=123, Prediccion=363.239077, Esperado=0.000000
Dia=124, Prediccion=282.668714, Esperado=0.000000
Dia=125, Prediccion=248.518154, Esperado=0.000000
Dia=126, Prediccion=222.428753, Esperado=1350.000000
Dia=127, Prediccion=804.344301, Esperado=1350.000000
Dia=128, Prediccion=794.138287, Esperado=833.000000
Dia=129, Prediccion=641.643096, Esperado=1188.000000
Dia=130, Prediccion=781.024610, Esperado=698.000000
Dia=131, Prediccion=644.378593, Esperado=810.000000
Dia=132, Prediccion=692.778485, Esperado=0.000000
Dia=133, Prediccion=440.028284, Esperado=0.000000
Dia=134, Prediccion=355.259120, Esperado=541.000000
Dia=135, Prediccion=519.450576, Esperado=0.000000
Dia=136, Prediccion=345.565284, Esperado=799.000000
Dia=137, Prediccion=616.813436, Esperado=0.000000
Dia=138, Prediccion=379.159540, Esperado=729.000000

Ilustración 96: Corrida por días - LSTM

Fuente: Elaboración propia

Se presenta un fragmento de la corrida de los datos en donde se puede observar la capacidad de predicción del presente modelo.





Ilustración 97: Grafica predicción - LSTM

Fuente: Elaboración propia

A simple vista se puede observar una mejor adaptación a los datos reales y las predicciones realizadas, además maneja sin problemas los espacios en él. A continuación, se realizará la comparación de los resultados individuales de los 8 productos para cada uno de los 3 modelos.

3.7 Comparación de resultados.

Se realiza la comparación de los resultados tras la corrida de cada uno de los modelos para cada uno de los productos con finalidad de comparar los distintos resultados a través de una misma métrica de error.

En cada uno de los modelos se tomó la métrica RMSE error cuadrático medio ya que esta es común en cada uno de los 3 modelos. Servirá así para comparar la el performance de estos.

producto	arima	prophet	lstm
Bells 2.5 L	579.4	926.44	475.22
Bells 20 L	111.5	105.93	104.7
Bells 380 ml	162.51	156.17	195.09
Bells 550 ml	198.33	173.24	176.61
Bells 625 ml	487.12	364.6	367.49
Cencosud 20 L	212.13	215.66	207.31
Cencosud 625 ml	116.26	98.04	114.15
Cencosud 7 L	211.46	165.28	177.13
Promedio	259.84	275.67	227.2125

Ilustración 98: Resultados

Fuente: Elaboración propia

Tras la recopilación de los resultados se elaboró la tabla en la cual se obtuvo un promedio de errores cuadráticos para el modelo Arima de (260), para el modelo Prophet de (276) y para el modelo LSTM de (228) en número de paquetes. Se observa que existe un mejor desempeño entre el modelo Arima y el modelo LSTM por lo cual cabe resaltar de que entre las diferencias de ambos modelos se prefiere el modelo LSTM debido a la ventaja y facilidad de automatización como también su capacidad de manejar de mejor manera un número mayor de observaciones en el futuro. También maneja adecuadamente los picos y temporales sin pedidos. Por dichos motivos se decidió elegir al modelo LSTM como ganador para la implementación del planificador de la demanda, el cual será presentado a continuación.

3.8 Objetivos de la solución.

Actualmente en la empresa de estudio se observa la problemática ya diagnosticada, no se lleva una correcta planificación de la producción, dado que el flujo de trabajo actual consta de apuntar los pedidos requeridos en el esquema y realizar la producción de los mismo. Como se diagnosticó en el segundo capítulo, el estudio previo reveló que este método de trabajo sin una previa planificación basada en los históricos y el establecimiento de stocks de seguridad no permite cumplir con los requerimientos de los clientes ya que se generan abruptos. Por consecuencia no es posible cumplir las órdenes solicitadas,

inclusive si se trabaja 3 turnos a plena capacidad. Además, el ordenamiento de esta planificación acrecienta el problema.

Fecha	Valor 1	Valor 2	Valor 3	Valor 4
09/01/20	945	-	864 pps	2517 pps
10/01/20	700	756	235 pps	217 pps
11/01/20	560	1101	756 pps	698 pps
12/01/20	756	756	810 pps	2517 pps
13/01/20	756	756	810 pps	408 pps
14/01/20	756	756	810 pps	756
15/01/20	756	756	810 pps	400
16/01/20	756	756	810 pps	440 pps
17/01/20	756	756	810 pps	805
18/01/20	756	756	810 pps	337
20/01/20	756	756	810 pps	817 pps

Ilustración 99: Situación actual

Fuente: Elaboración propia

3.9 Diseño de la Solución.

El presente modelo tendrá en cuenta el flujo de trabajo, el cual consta de las observaciones históricas, que serán alimentada con cada una de las órdenes de pedidos. Esta información es la que se utilizará para la alimentación del modelo como a su vez realizar las predicciones subsecuentes. Esto será mostrado por la interfaz gráfica. Como se conoce, se tendrán los ingresos (*inputs*) tales como las ordenes planeadas, la demanda pronosticada, el inventario actual, los límites de producción, política de producción (*Lead Time*), características del producto (requerimientos de insumos) y el punto de pedido para los insumos.

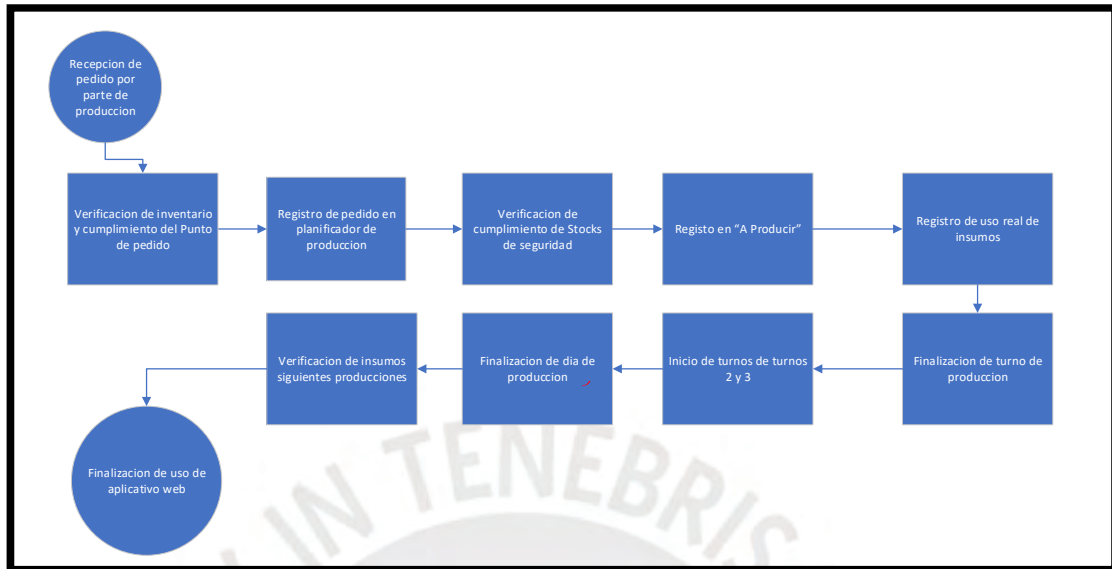


Ilustración 100: Mapa de proceso planteado

Fuente: Elaboración propia

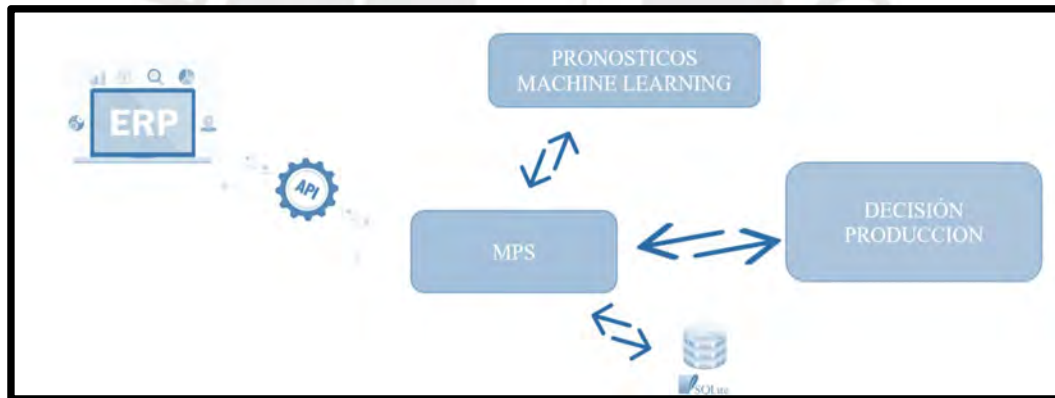


Ilustración 101: Arquitectura solución

Fuente: Elaboración propia

La presente solución que se plantea crear para la empresa en estudio consistirá en un *MPS* basado en *HTML*, en el cual las predicciones serán desarrolladas por el modelo *LSTM*, el cual está en el lenguaje *Python* y todas las interacciones se darán mediante *JavaScript*. Los cálculos correspondientes al calendario planificador, cálculos de producción, mermas, obtención del *Takt Time*, el registro en la base de datos y la carga de información de la misma se manejarán mediante *PHP*. La configuración referente

a los requerimientos de insumos por artículos será alimentada desde la base de datos. El aplicativo web usara una base de datos SQLite, y el servidor web IIS.




Ilustración 102: Ventanas

Fuente: Elaboración propia

La solución web constará de 3 ventanas. La pantalla principal, la cual denominaremos planificador producción tendrá una barra en cual muestra el acceso para navegar entre las interfaces el cual es retráctil para poder aprovechar más la pantalla.



Ilustración 103: Cuadros de control

Fuente: Elaboración propia

La primera ventana es la de ‘Planificador Modelo’ en la cual se observa cuatro recuadros el primero es el de “Semana Planificación” el cual contiene un botón que permitirá entrenar el modelo seleccionar en que semana se desea planificar. El segundo recuadro permite ver los productos registrados en el aplicativo, el cual al seleccionarlo, se cargará la información de la base de datos del aplicativo. Basta

dichos 2 campos para visualizar la información en la tabla. El tercer recuadro permite la carga de la cobertura del pronóstico, dicho archivo se encuentra en formato JSON y a su vez permite verificar que los pronósticos se encuentren listos para la visualización. El último recuadro permitirá visualizar la cantidad de paquetes que actualmente se registran en los almacenes de la empresa, dicho dato será consumido a través de una API elaborada con la finalidad de mantener la conectividad entre los diferentes aplicativos de la empresa y servirá al presente *MPS*.

En la parte inferior se tendrá una tabla que permite la visualización del planificador. Se mostrarán 8 columnas. La primera correspondiente a los rotulados del planificador, luego cada una de las columnas estará ocupada por cada día de la semana. La segunda fila estará ocupada por lo Pronosticado (diario), aquí se cargará la información proveniente del modelo LSTM es mostrar las predicciones.

$$Production + Stock_{t-1} = Demanded Supply + Stock_t$$

$$Cant Prod_t - Solicitado_t - Inv Inicial_t - Merma PT_t = Inv Final_t = Inv Inicial_{t+1}$$

$$Turno 1_t + Turno 2_t + Turno 3_t = Cant Prod_t$$

$$Inventario Final_t \geq Stock Seguridad_t$$

$\therefore \in \geq 0$,

Ecuación 8: Modelo Matemático MPS

Fuente: Elaboración Propia

La columna solicitada será editable por el usuario al igual que el inventario inicial y cada uno de los turnos de la cantidad a producir. En la parte inferior de la fila “cantidad a producir” se encontrará cada una de las cantidades a producir en los respectivos turnos. Finalmente, la merma producto terminado permitirá el registro de las mermas que se susciten en la producción cuando se obtiene el producto terminado (transporte inadecuado, despresurización de la botella, deformaciones debido al embalado, entre otros). Se muestra el planificador a la tercera semana de enero 2020.

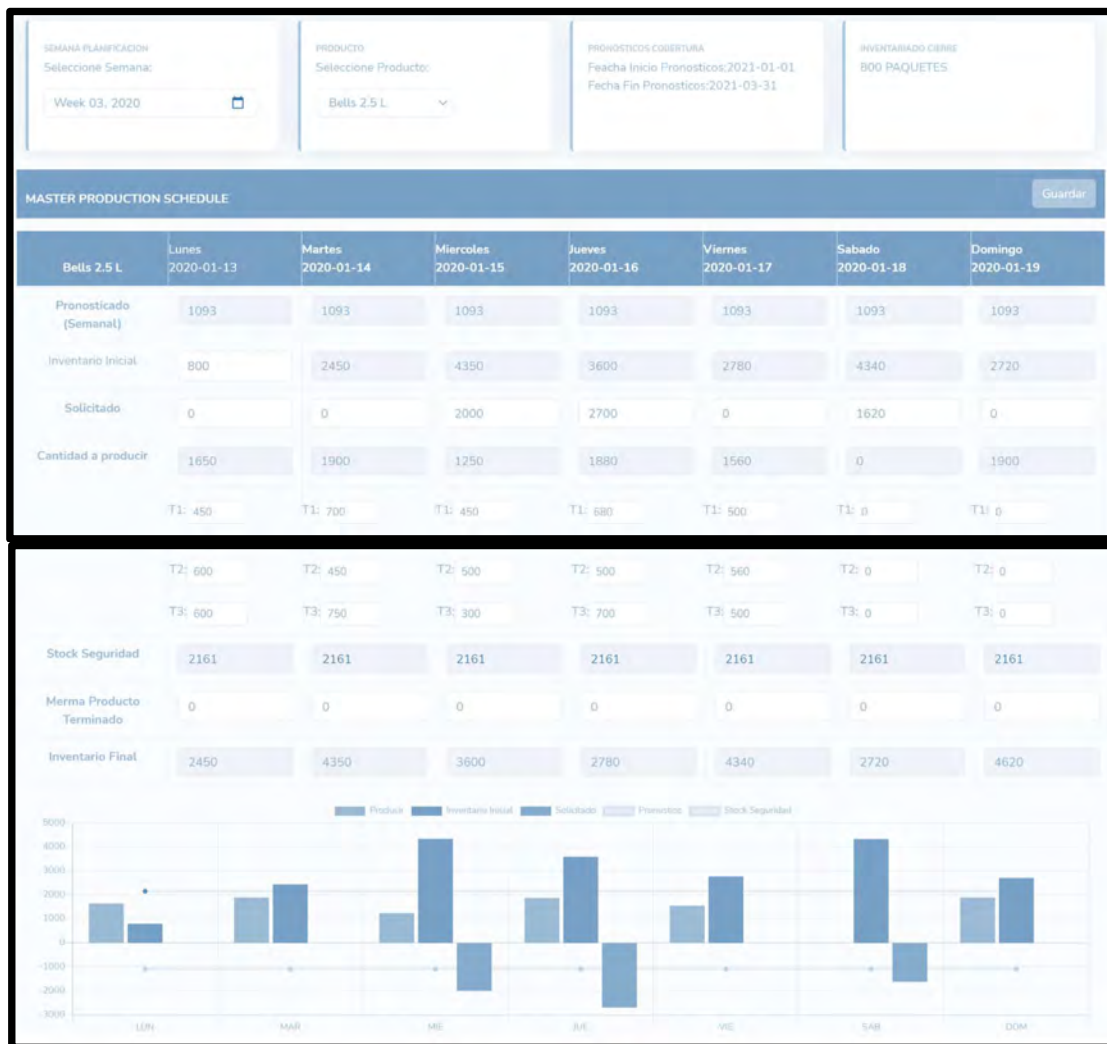


Ilustración 104: Esquema planificador

Fuente: Elaboracion propia

La última fila del esquema planificador contendrá al stock de seguridad, en el cual se implementó un notificador visual en caso de que se esté bajo el stock de seguridad será activado mediante una tonalidad roja, el stock seguirá un sistema de inventarios el cual mantendrá el nivel calculado, nos avisará cuando debemos reabastecer el pedido de acuerdo al volumen de la demanda. Cabe resaltar de que este será un inventario de productos terminados según su uso y según el tiempo, de stock de seguridad, esto con la finalidad de evitar incumplimiento de pedidos causados por los picos de demanda. Con la finalidad de hallar dicho parámetro es necesario previamente el cálculo de las siguientes variables:

Se iniciará con el cálculo del stock de seguridad $SS = K * \sigma'$ el cual estará comprendido por el valor k del nivel de servicio el cual será establecido a 90% otorgando un K equivalente a 1.28. Se proseguirá con el valor de sigma prima σ' para el cual se aplicará la formula $\sigma'_d = \sqrt{LT * \sigma^2_{demandada} + DemandaMedia^2 * \sigma^2_{LT}}$. Los parámetros serán obtenidos de los estudios estadísticos previamente realizados y las ordenes de pedido. Se tendrá en consideración el día de recepción de la orden y la fecha para la cual se requiere el pedido. El cálculo del *Lead Time* toma en consideración las adecuaciones de los pedidos, los cuales tienen notablemente *Lead Time* reducidos.

	Bells 2.5 L	Bells 20 L	Bells 380 ml	Bells 550 ml	Bells 625 ml	Cencosud 20 L	Cencosud 625 ml	Cencosud 7L		
LT	2	2	2	2	2	1.5	1.5	1.5		
Desv LT	1	1	1	1	1	1	1	1		
Demanda Media	1459	270	423	531	860	276	173	400		
Desv Demanda	600	150	230	272	490	152	113	136		
	Bells 2.5 L	Bells 20 L	Bells 380 ml	Bells 550 ml	Bells 625 ml	Cencosud 20 L	Cencosud 625 ml	Cencosud 7L		
Sigma Prima	1688	344	534	656	1105	333	222	434		
SS	2161	441	684	840	1415	427	285	556		
Paquetes X Pallet	54	40	105	115	115	40	115	54	TOTAL	
Pallets	41	12	7	8	13	11	3	11	106	
	k	1.28								
	AREA PALLET m2	TOTAL AREA PALLET m2	AREA INC. SEG m2							
	1.30	137.76	255.54							

Tabla 16: Stock de seguridad

Fuente: Elaboración propia



Ilustración 105: Paletizado de botella 2.5L Bells

Fuente: Imagen propia

Tras realizar dichos cálculos, los cuales podrán ser editados en la pestaña de configuración, se observa la presente tabla en donde se recopiló los parámetros requeridos para el cálculo del stock de seguridad, el cual por resultado arrojó que para un nivel de servicio del 90% se deberá tener 2161 paquetes en stock para Bells 2.5 L ofreciendo así prevención ante las roturas de stock, se realiza un análisis similar para el resto de productos. Se observa en el Excel que, si se mantiene la totalidad de los stocks de seguridad, estos requerirían de la utilización de 106 pallets lo cual, traducido a espacio ocupado en almacenes de producto terminado, un total de 255.54 m². Dichos datos calculados serán registrados en la pestaña de configuración correspondiente al stock de seguridad con esto el calendario planificador podrá tener en cuenta estos valores al momento de mostrar el esquema.



Ilustración 106: Takt Time

Fuente: Elaboración propia

El presente Takt Time será calculado mediante la fórmula en el cual se dividirá el tiempo disponible, el cual corresponderá al (79,69%) ~80% de la totalidad del tiempo de un turno disponible 8h en minutos sobre las unidades por turno a cumplir. Esto otorgará el indicador correspondiente por cada una de los procesos. Esto gracias al análisis y observación de distintos turnos de producción a lo largo de la elaboración de la presente tesis. Cada uno de los *Takt Times* correspondientes a los turnos se mostrará a través de un *tooltip*.

La segunda interfaz estará comprendida por el visualizador de insumos y materias primas, el cual brindará una interfaz agradable visualmente, la cual mantendrá vigilancia del stock de seguridad. Así se permitirá evitar roturas de stock ya que brindará información en tiempo real de los insumos permitiendo que se realice una correcta planificación de la producción.



Ilustración 107: Esquema planificador

Fuente: Elaboración propia

La tercera interfaz estará constituida por el registro y visualización de los distintos materiales/insumos que se requieren para la producción de cada uno de los artículos de la empresa. Esta interfaz consta de una tabla que en el primer reglón visualiza los distintos nombres de los ítems requeridos para la producción, estos han sido previamente configurados en la base de datos. Además, se ha especificado el punto de reposición de cada uno de los artículos. El tercer reglón permitirá observar las distintas cantidades que en este momento se tiene en los almacenes de la planta; por último, en el reglón número cuatro se observa los recuadros de ingresos numéricos para poder actualizar cada uno de los inventarios de artículos e insumos de la planta. Los puntos de reposición serán obtenidos de la siguiente manera:

	BolsaTermo (und)	PegamentoCaja (gr)	Caja (und)	Bolsa metalica +valvula (und)
LT	14	20	15	20
Desv LT	5	5	3	5
Demanda Media	546	2730	546	546
Desv Demanda	214	1070	214	214
sigma prima	2846	14465	1836	2893
SS	3643	18516	2351	3704
Punto Pedido	11287	73116	10541	14624
K	1.28			

Tabla 17: Calculo de Punto de Pedido

Fuente: Elaboración propia

Se observa un fragmento de los cálculos realizados para hallar el punto de pedido para los insumos de producción en el cual el *lead time* que está en semanas, fue convertido con anterioridad. Dichos valores fueron recopilados de distintos registros otorgados por el área de logística. Se realizó el cálculo del stock de seguridad y punto de pedido dando como resultado los siguientes valores. Se utilizo un nivel de servicio del 90% y dicho análisis y cálculo se realizó para el resto de productos.

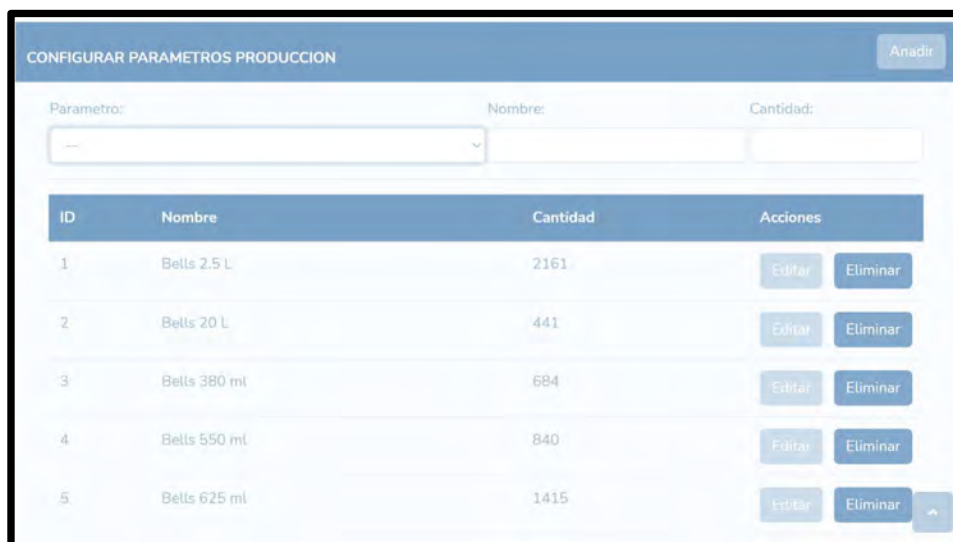


Ilustración 108: Ventana de configuración

Fuente: Elaboración propia

3.10 Funcionamiento y utilización.

Tras el ingreso a la plataforma el personal de producción iniciara en la presente interfaz la cual mostrara la siguiente estructura:

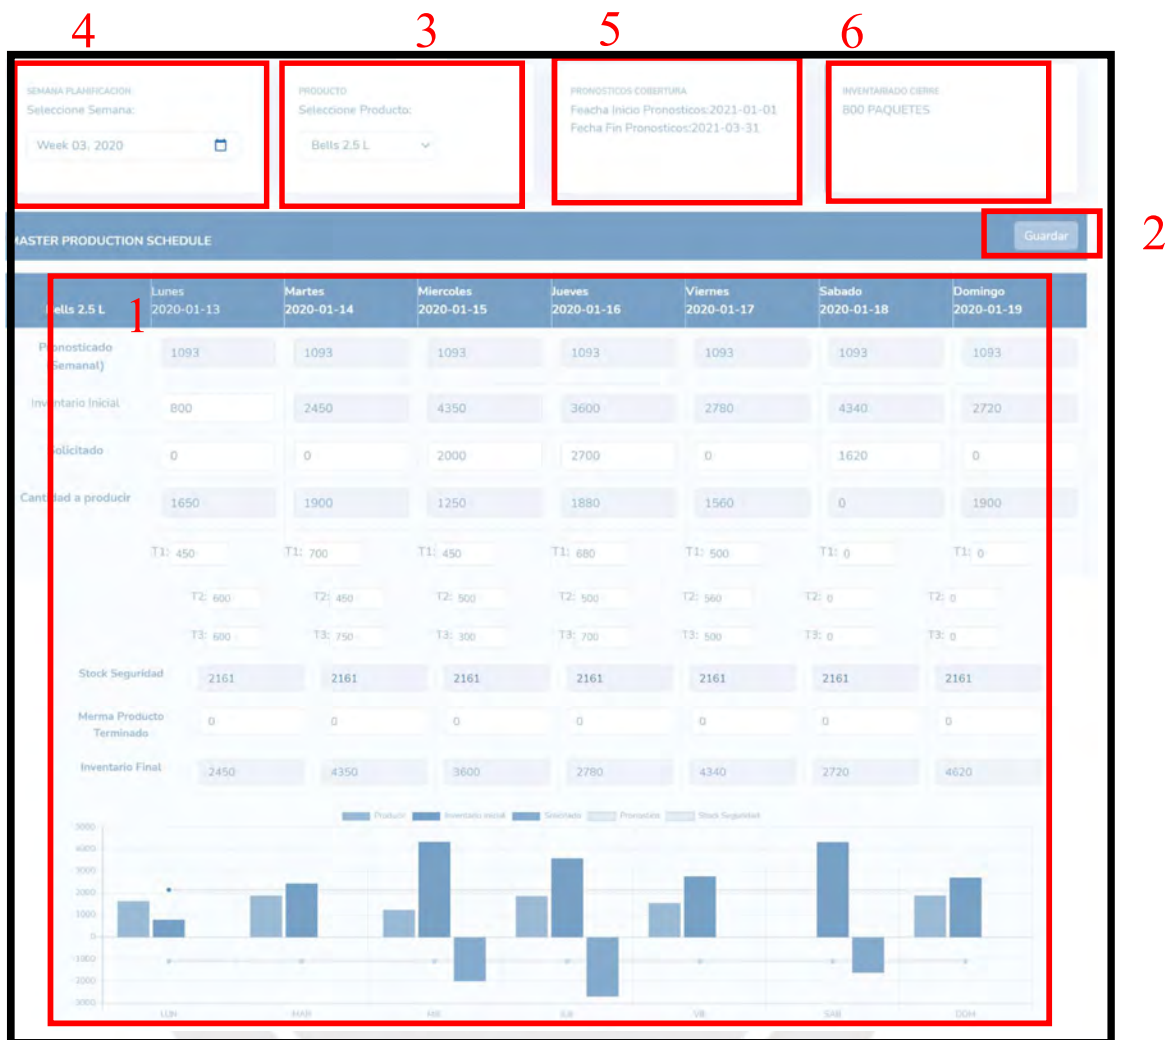


Ilustración 109: Interfaz Planificador

Fuente: Elaboración propia

1. Esquema Planificador: Interfaz principal que permite realizar la planificación y editar parámetros como (inventario inicial, solicitado, producir) con la finalidad del cálculo.
2. Guardar: Sirve para almacenar los registros del planificador en la base de datos con la finalidad de poder visualizar los cambios posteriormente.
3. Seleccione Productos: Sirve para la elección de producto que se planificará.
4. Seleccione Semana: Sirve para la elección de la semana que se planificará.
5. Interfaz de visualización: Permite visualizar los distintos valores del esquema planificador.

6. Inventario de cierre: Tras la consulta visualiza el inventario de cierre de la semana anterior, con el cual el planificador iniciará la semana.



Ilustración 110: Interfaz Materiales

Fuente: Elaboración propia

7. Esquema de materiales: Interfaz en donde se visualizará el punto de pedido y la cantidad que se dispone en los inventarios de cada uno de los insumos/materiales, en la parte inferior se podrá asignar cantidades distintas de inventario en caso de que este se varíe.



Ilustración 111: Interfaz de configuración

Fuente: Elaboración propia

8. Añadir nadir: Permitirá cargar nuevos parámetros de producción.

9. Interfaz de modificador: Permite añadir, editar y eliminar de los parámetros de producción.

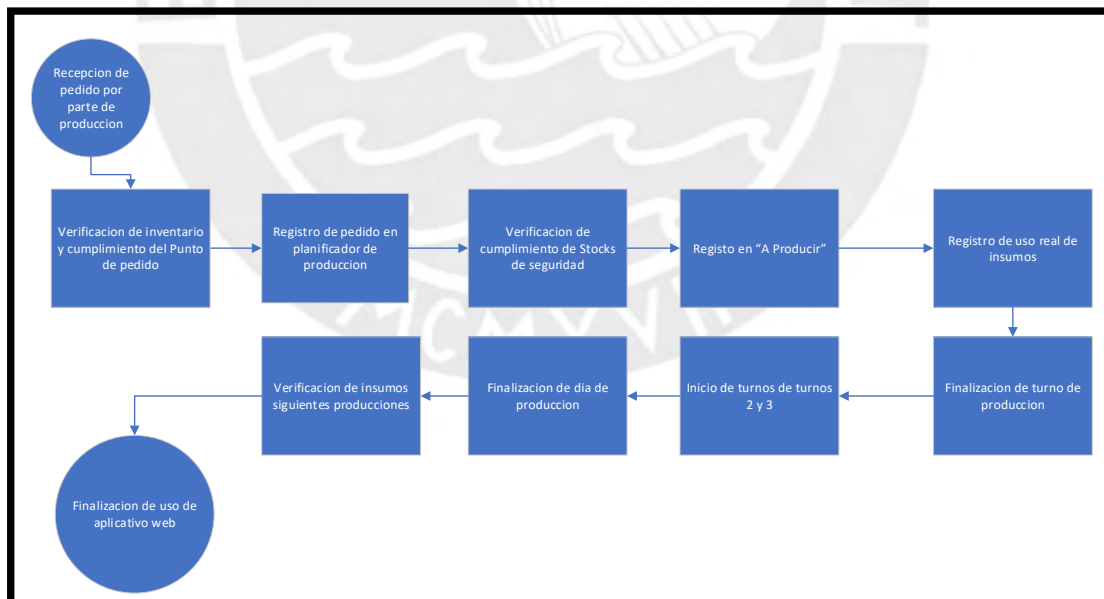


Ilustración 112: Propuesta de flujo de trabajo

Fuente: Elaboración propia

El siguiente flujo de trabajo fue planteado para la utilización del aplicativo en pro de la correcta gestión y planificación de la producción, el cual sería sugerido para la utilización por el personal de producción.



Capítulo 4: Evaluación técnica y económica

En el presente capítulo, se desarrollará la evaluación económica, técnica y conclusiones de la mejora realizada, en la primera parte se medirá cuan eficaz fue la propuesta lanzada, tras esto se validará los beneficios generados por la solución presentada y finalmente se analizará la sensibilidad del proyecto de mejora presentado.

4.1 Evaluación técnica.

Se realizará el análisis técnico que ha sido generado por la implementación de la mejora presentada dentro del área de producción de manera específica según las mejoras que fueron planteadas en el anterior acápite. Cabe resaltar de que el horizonte comparativo es del último mes del año 2019 frente al primer mes del 2020 de los productos de la marca Bells, esto tras la implementación de las mejoras. Se estableció dicha ventana de tiempo dado su similitud de acuerdo al negocio.

4.1.1 Evaluación técnica para el planificador de la demanda.

		Propuesta	Pre-Mejora	Post-Mejora	Variancia
1	Evaluación técnica para el planificador de la demanda	Reducción en el uso de horas extras debido a la correcta programación de la producción (Monetario)	PEN 4,043.81	PEN 799.86	-80.22%
2		Reducción del mal uso de recursos por el correcto establecimiento de turnos de trabajo	15.34%	7.98%	-45.93%
3		Reducción de la improvisación por el establecimiento del Tack time	PEN 5,334.00	PEN 1,459.00	-51.47%
4	Evaluación técnica para establecimiento del modelo de pronósticos LSTM	Reducción del error en el pronóstico del inventario	PEN 8,868.30	PEN 263.82	-97.03%
5	Evaluación técnica para establecimiento del sistema de inventarios	Reducción de incumplimiento de pedidos debido al establecimiento de los stocks de seguridad y punto de pedido	PEN 934.35	PEN 549.62	-41.18%

Tabla 18: Resumen evaluación. técnica

Fuente: Elaboración propia

Se evidencia que existe una disminución en costo monetario y porcentual gracias a cada una de las propuestas establecidas. Evidenciado así una mejora tras la implementación de la solución que a continuación será detallada:

a) Reducción en el uso de horas extras debido a la correcta programación de la producción (Monetario).

Dado que el uso de horas extras conlleva que los costos de hora hombre del personal de producción sean mayores, lo cual es un factor mandatorio por ley, lo convierte en contraproductivo para las utilidades de la empresa. La presente implementación del MPS (*Master Production Schedule*), permite realizar una correcta planificación de los pedidos reduciendo así el número de horas extras requeridas para culminar los pedidos solicitados. Se logrará mediante el registro de la cantidad de paquetes solicitados en el planificador de la demanda. Se realizará los distintos cálculos y se ofrecerá al personal de producción la capacidad de planificar la producción de los distintos días de la semana para cumplir los requerimientos productivos solicitados.

Con la finalidad de tener una comparativa acerca de cómo dicha implementación afecto en el uso de horas extras se seleccionó un registro representativo de la utilización del uso de horas extras para ambas ventanas de tiempo (mes anterior y posterior a la mejora).

N	Cargo	Factor Multip	1.25	1.35	2	Pago por Hora Normal	Costo Total Horas Extras
		N	25%	35%	100%		
1	Empleado	1	14.00	7.00	8.00	3.875	166.43
2	Empleado	2	20.00	10.00	16.00	3.875	273.19
3	Empleado	3	18.00	9.00	24.00	3.875	320.27
4	Empleado	4	18.00	9.00	16.00	3.875	258.27
5	Empleado	5	20.00	10.00	24.00	3.875	335.19
5	Empleado	5	18.00	17.00	23.50	3.875	358.24
6	Empleado	6	20.00	10.00	24.00	3.875	335.19
7	Supervisor	7	10.00	5.00	16.00	6.25	320.31
8	Empleado	8	18.00	9.00	8.00	3.875	196.27
9	Empleado	9	18.00	9.00	16.00	3.875	258.27
10	Empleado	10	20.00	10.00	24.00	3.875	335.19
11	Empleado	11	20.00	10.00	16.00	3.875	273.19
12	Empleado	12	20.00	10.00	16.00	3.875	273.19
13	Supervisor	13	20.00	10.00	8.00	6.25	340.63
		TOTAL	254.00	135.00	239.50		4,043.81

Tabla 19: Horas extras pre-mejora

Fuente: Elaboración propia

		Factor Multip	1.25	1.35	2		
N	Cargo	N	25%	35%	100%	Pago por Hora Normal	TOTAL MENSUAL Horas Extras
1	Empleado	1	8.00	4.00	-	3.875	59.68
2	Empleado	2	8.00	4.00	-	3.875	59.68
3	Empleado	3	7.00	4.00	-	3.875	54.83
4	Empleado	4	8.00	4.00	-	3.875	59.68
5	Empleado	5	6.00	3.00	-	3.875	44.76
5	Empleado	5	6.00	3.00	-	3.875	44.76
6	Empleado	6	8.00	4.00	-	3.875	59.68
7	Supervisor	7	8.00	4.00	-	6.25	96.25
8	Empleado	8	8.00	4.00	-	3.875	59.68
9	Empleado	9	8.00	4.00	-	3.875	59.68
10	Empleado	10	6.00	3.00	-	3.875	44.76
11	Empleado	11	8.00	4.00	-	3.875	59.68
12	Empleado	12	6.00	3.00	-	3.875	44.76
13	Supervisor	13	4.50	2.00	-	6.25	52.03
		TOTAL	99.50	50.00	-		799.86

Tabla 20: Horas extras post-mejora

Fuente: Elaboración propia

Se observa la presente tabla comparativa de la situación previa aplicación de la solución propuesta en la cual se realizaba un uso excesivo de hora extras donde según el Ministerio del Trabajo² se tienen los factores de recargo por las horas extras laboradas se observa:

25%	35%	100%	Comparativa Monetaria
-60.83%	-62.96%	-100.00%	-80.22%

Tabla 21: HE Comparativa

Fuente: Elaboración propia

Existe una disminución en el uso de las 2 primeras horas extras del 61%, un 63% para el uso de las hasta la tercera y un 100% en el uso mayor a 3 horas extras. En resumen, una reducción del 75% en el uso de horas extras. Además, se verifica que realizando una comparativa monetaria los costos son reducidos hasta en un 80% se evidencia así una mejora significativa en el uso del recurso humano.

² Diario Gestión 01/10/2018: <https://gestion.pe/tu-dinero/calculan-horas-extras-221817-noticia/>

a) **Reducción del mal uso de recursos por el correcto establecimiento de turnos de trabajo.**

Se evidencia de que el personal, tras largas jornadas de trabajo y conforme transcurren los días de la semana, pierde su eficiencia en las labores tal como se puede comprobar en el presente estudio (Brunies, 2001), autora perteneciente al PMI (*Project Management Institute*).




Ilustración 113: Sobre trabajo

Fuente: PMI

En el cual se verifica que el trabajo mayor a 50 horas por semana afecta el rendimiento de las labores, cabe resaltar que debido a que el proceso en la empresa es mayoritariamente manual, como se conoce a partir de la explicación del sistema productivo. Esto se ve traducido en una mala utilización de los recursos especialmente los que requieren del manejo por parte de los operarios de producción, dichas deficiencias se evidencian en la siguiente tabla:

TIPO	PRODUCTO	OPERACION	PRE-MEJORA	POST-MEJORA	VARIACION
RECURSO	Merma de botellas/bolsas metálicas	Llenado	9.29%	6.45%	-31%
RECURSO	Merma de tapas / válvulas	Sellado	9.15%	2.27%	-75%
RECURSO	Merma de etiquetas / cajas	Empacado	7.97%	4.63%	-42%
RECURSO	Preforma 15 (und)	Soplado	-	2.65%	-
RECURSO	Preforma 17.5 (und)	Soplado	-	0.78%	-
RECURSO	Preforma 20 (und)	Soplado	-	0.86%	-
RECURSO	Preforma 42 (und)	Soplado	-	0.36%	-
PROD T	Agua Tratada	Lavado,Llenado	42.60%	21.31%	-49.99%
PROD T	Producto Terminado	Empacado,Paletizado,Almacenado, Distribucion	7.68%	5.22%	-32.03%

Tabla 22: Mermas comparativa

Fuente: Elaboración propia:

Se observa que los insumos, ahora utilizados de forma correcta basándose en una planificación previa, ha permitido realizar los procesos productivos de la forma estandarizada previamente establecida siguiendo las buenas prácticas productivas evitando recurrir a personal externo del área, además con el apoyo del registro de las mermas en el soplado, lo cual previamente no se tenía, se permitió que estos indicadores sirvan de control y mejora de procesos.

b) Reducción de la improvisación por el establecimiento del Takt time.

La implementación del ritmo de trabajo permitió reducir la necesidad de que personal de otras áreas realicen funciones en la línea de producción, esto permitió que, de acuerdo a la carga productiva, se acelera la cantidad de paquetes que bota la línea o reducir esta cantidad. Es el personal de producción quien realiza las funciones, así se evita el factor de la inexperiencia del personal externo del área el cual puede acarrear problemas. Además, cuando el número de paquetes de la línea es bajo permite un correcto uso de los recursos; es decir, redireccionar dicho operario u operarios de producción para realizar tareas que puedan requerir o estar pendientes de realizar.



Tabla 23: Incidencia pre-mejora

Fuente: Elaboración propia:

Como se evidencia en el presente cuadro, a través del diagnóstico realizado en el capítulo 2, el requerimiento de apoyo en el área productiva se identifica como uno de los causales de demoras en la producción. Se implemento el *TaktTime* como contramedida a dicho problema. Esto permitió reducir dicha incidencia en un promedio de 51% comprobando la efectividad de dicha contramedida.




Tabla 24: Incidencias post-mejora

Fuente: Elaboración propia:

Incidencias produccion	PRE			POST			Mejora
	Duracion promedio	Veces	Total min	Duracion promedio	Veces	Total min	
Etiquetado/armado Cajas	168	10	1680	45	2	90	0.95
Falla mecanica	130	4	520	37	2	74	0.86
Falta de materiales e insumos	134	6	804	62	2	124	0.85
abastecimiento de insumos	74	10	740	37	5	185	0.75
No especifico	20	1	20	35	1	35	0.75
Personal	32	22	704	34	8	272	0.61
Corte de Luz	29	4	116	45	1	45	0.61
Calibracion de maquina	30	5	150	30	3	90	0.40
Sanitizacion de la linea	38	8	304	32	8	256	0.16
Falla operativa	60	1	60	34	2	68	0.13
Orden y limpieza de linea	73	2	146	65	2	130	0.11
Reunion	45	2	90	45	2	90	0.00

Tabla 25: Comparativas Incidencias

Fuente: Elaboración propia

4.1.2 Evaluación técnica para establecimiento del modelo de pronósticos LSTM.

a) Reducción del error en el pronóstico del inventario.

Se realiza la comparación entre los valores que el área comercial manejaba acerca de la demanda de los productos frente al modelo de pronósticos escogido para la implementación de la solución. Se utilizará el error RMSE de cada una de las situaciones real frente a la manejada por el área comercial y la implementada en la solución del acápite anterior con la finalidad de contrastar la mejora realizada.

PRODUCTO	MANEJO AREA COMERCIAL-RMSE	MODELO LSTM-RMSE	MEJORA
BELL-S 2.5L	8982.465332	475.22	-95%
BELL-S T 625 ML	8861.727041	104.7	-99%
BELL-S 20UN 380 ML	8832.005415	195.09	-98%
BELL-S 12UN BT 550MI	8832.564953	176.61	-98%
BELL-S CJ 20 L	8832.7243	367.49	-96%

Tabla 26: Comparativa pronostico

Fuente: Elaboración propia

Se realizo la presente comparación de las raíces de los errores cuadráticos medios de cada uno de las situaciones enfrentadas, en el cual se compararon los productos de la marca Bells dando como resultado de mejoras hasta del 99% en la reducción del RMSE. Es decir, se presentará menor error en el número de paquetes presentados en el pronóstico.

4.1.3 Evaluación técnica para establecimiento del sistema de inventarios.

a) Reducción de incumplimiento de pedidos debido al establecimiento de los stocks de seguridad y punto de pedido.

Tras el factor personal, el desabastecimiento de insumos supone la segunda causa del cumplimiento de pedidos, el correcto establecimiento del punto de pedido para los insumos productivos permitió que se evite la parada de producción. La aplicación del stock de seguridad de producto terminado permitió la reducción del incumplimiento de los pedidos. El último mes del año 2019, se contempló un nivel de servicio del 83% tras la mejora se pretende contemplar un nivel de servicio del 90% dado esto se pretende evitar las penalidades impuestas por supermercados peruanos por el incumplimiento de estas dichas penalidades son caras y constituyen un importante egreso de dinero.

			PEN 192.37	Ahorro por cada 1000 botellas penalidad 50%
			PAQUETES SOLICITADOS	1000
			17% incumplimiento	10% incumplimiento
PROD	COMPOSICION	CANTIDAD	0.085	0.05
380 ml	0.0657098	66	PEN 17.08	PEN 10.05
550 ml	0.030107647	31	PEN 11.97	PEN 7.04
625 ml	0.316887194	317	PEN 154.37	PEN 90.81
2.5 L	0.414891231	415	PEN 162.22	PEN 95.42
20 L	0.172404126	173	PEN 121.54	PEN 71.49
		TOTAL PEN	PEN 467.18	PEN 274.81
				VARIACION
				-41.18%

Tabla 27: Inventarios mejora comparativa

Fuente: Elaboración propia

PROD	PV UNIT SP	PV PLAZA VEA	BENEFICIO SP
380 ml	PEN 8.86	PEN 11.90	PEN 3.04
550 ml	PEN 6.49	PEN 11.03	PEN 4.54
625 ml	PEN 8.18	PEN 13.91	PEN 5.73
2.5 L	PEN 7.10	PEN 11.70	PEN 4.60
20 L	PEN 11.81	PEN 20.07	PEN 8.26

Tabla 28: Precio venta y beneficios

Fuente: Elaboración propia

Se realizó una tabla comparativa con la finalidad de comparar el pre y la post mejora en donde se observó y concluyó que la propuesta realizada logró reducir en aproximadamente un 41% en general las penalidades que han sido impuestas por la empresa causadas por el incumplimiento/cumplimiento tardío de entrega de productos por cada 1000 paquetes solicitados cabe destacar dichos costos ya contemplan los costos de transporte y los de oportunidad por parte de supermercados peruanos, se realiza la comparativa en la sanción aplicada por el cliente generándose así un beneficio económico a la empresa tras la implementación de la solución.



Ilustración 114: Bells 2.5 l

Fuente: Vea online

4.2 Evaluación económica.

Se validan los beneficios de la propuesta de mejora realizada en el área de producción de manera económica, es decir los pedidos en dinero los cuales no fueron perdidos por la empresa el beneficio económico. Cabe resaltar de que la totalidad de software y paquetes utilizados para la creación de la solución es Open Source debido a esto se evitó realizar una inversión monetaria para la creación e implementación de la solución.

4.2.1 Evaluación económica para el desarrollo e implementación de la solución planteada.

a) Presupuestos de egresos relevantes.

A partir del cronograma se considera la totalidad de H-H que se trabajara en la realización del proyecto.

Recursos	Trabajo	Costo H-H	TOTAL	
Analista	448.8 hrs	S/ 6.25/hr	PEN	2,805.00
Jefe de produccion	177.6 hrs	S/ 14.60/hr	PEN	2,592.96
Jefe de logistica	76 hrs	S/ 14.60/hr	PEN	1,109.60
Jefe de TI	231.2 hrs	S/ 6.25/hr	PEN	1,445.00
Auxiliar TI	290.4 hrs	S/ 3.88/hr	PEN	1,126.75
Comercial	20.8 hrs	S/ 6.25/hr	PEN	130.00
		TOTAL	PEN	9,209.31

Tabla 29: Costo mano obra

Fuente: Elaboración propia

Se presenta la tabla de resumen en el cual se consideran los 57 días totales (Martes 15 de octubre 2019 al miércoles 1 de enero del 2020) de la presente realización de la mejora de procesos lo cual asciende a un costo de 9209.31 soles dicho monto comprende el uso de horas hombres requerido para la elaboración de la mejora, no se registra montos en el costo del software utilizado ya que este se realizó a la totalidad con software de código abierto el cual carece de costo. Se cuenta con el hardware disponible en donde la solución será albergada.

a) Presupuesto de Ingresos relevantes.

Con la finalidad de realizar el presente estudio se considerará los egresos causados por las penalidades impuestas por supermercados peruanos en su producto y la reducción del uso de horas extras. Cabe resaltar que el presente análisis es similar en el caso de los otros productos de la familia Cencosud *Retail*. Con la finalidad del presente estudio el producto escogido es Bells, valores y parámetros escogidos pertenecen a este producto únicamente.

La empresa priorizará la reducción del incumplimiento de pedidos al máximo posible dado que estos representan un egreso relevante de dinero.

		PQT Mensual Prom		45211	
	Tipo	Ahorro Mensual	Ahorro 1000 PQT	Promedio Mensual	
Reduccion horas extras	Fijo	PEN 3,243.95	-	PEN 3,243.95	
Reduccion Incumplimiento de pedidos	Variable	-	PEN 192.37	PEN 8,697.07	
			AHORRO TOTAL MENSUAL A UNA PENALIDAD DE 50%	PEN 11,941.02	

Tabla 30: Ahorro Mensual contramedidas

Fuente: Elaboración propia

b) Calculo Costo de capital.

Con la finalidad de determinar el (COK) costo del capital se utilizará el CAPM (*Capital asset pricing model*) el cual es de amplia utilización, alrededor de un 80%, uso financiero para dicha finalidad, según investigaciones de (Bruner & Harris, 1998)

$$R_e = r_f + \beta * (r_{mkt} - r_f) + \gamma * CRP$$

Ecuación 9: CAMP

Fuente: Elaboración propia

Where: R_e : Expected return for the asset under valuation
 r_f : Risk Free Rate of Return is return of the debt issued by Governments in the form of Treasury Bills or Bond.
 β : Beta is a measure of risk
 r_{mkt} : Market Return
 $(r_{mkt} - r_f)$: Market Premium
 λ : Relative Volatility of Stocks
CRP: Country Risk Premium

Ilustración 115: Formula CAMP

Fuente: CFA Institute (2011)

WACC	Valor	Sustento
Deuda/deuda+mkt	0.27%	Ratio valor razonable de la deuda bancaria sobre market cap
Mkt/deuda+mkt	99.73%	Valor de mercado de la deuda / (market cap+valor de mercado de la deuda)
Tasa imponible	24.84%	Promedio de los últimos 6 años de las tasas efectivas de impuestos
Costo de la deuda	7.24%	Notas EEFF 2018
Costo de capital	8.16%	Según Fórmula CAPM
Beta ajustada	0.76	Cálculo según regla de Hamada
WACC	8.15%	Costo Promedio Ponderado del Capital
WACC Valor Terminal	8.15%	Costo Promedio Ponderado del Capital

Ilustración 116: Estimación beta rubro embotelladoras

Fuente: Universidad Pacifico

Se desarrollará cada una de las variables que serán tomadas en cuenta para hallar el costo del capital.

Rf: Se tomará una tasa libre de riesgo a largo plazo (mayor de 10 años) con fecha de registro del 01/10/19 de 2.02%, Según (Damodaran, 2014), es el interés que un inversionista podrá ganar y que no presenta riesgo alguno de incumplimiento. Se toma el de los bonos generados por el *United States Department of the Treasury* el cual será de un bono de largo plazo otorgado por dicha institución.

Medida del riesgo (Beta): Según (Stephen A. Ross, 2009): el parámetro beta mide el riesgo del portafolio del mercado. Para la evaluación de la solución planteada se utilizará la beta des apalancada, para el sector embotelladoras según (Chang, Gamarra, & López, 2019)

$$\beta = \beta_{\alpha} \left[1 + (1 - t) \left(\frac{D}{P} \right) \right]$$

Ecuación 10: Apalancamiento Beta

Fuente: Elaboración propia

Se establecerá una beta des apalancado análoga de 0.76, dado que no se utilizará financiamiento bancario se obtendrá una beta apalancado de 0.76.

La Prima de riesgo de mercado (Rm-Rf): es la rentabilidad anual promedio que está en el mercado en un plazo largo. Se considerará como prima de riesgo de mercado a 8.45% (DeMarzo, 2008).

Riesgo país: Es el que se asume al obtener activos financieros emitidos por organizaciones de un país extranjero, o por colocar préstamos a ciudadanos en el mismo.

Consulta Octubre 2019	
Rf	2.02%
Beta desempalancado	76.00%
t	30.00%
D/C	0.00%
Beta apalancado	76.00%
Rm-Rf	8.45%
Riesgo pais	1.04%
Costo de capital (Ke)	9.48%

Tabla 31: CAMP Costo Capital

Fuente: Elaboración propia

c) Flujo de Caja Económico.

El Flujo de caja se elabora para la solución presentada en el cual se mostrará los egresos e ingresos provenientes de la implementación del proyecto. Para su realización se tomaron los siguientes ingresos y egresos:

Mes	Flujo de caja economico					
	Trim 1			Trim 2		
	Oct-19	Nov-19	Dec-19	Ene-20	Feb-20	Mar-20
Egreso	PEN 3,069.77	PEN 3,069.77	PEN 3,069.77	PEN -	PEN -	PEN -
Ingreso	PEN -	PEN -	PEN -	PEN 11,941.02	PEN 12,172.94	PEN 12,411.05
Flujo Caja	PEN (3,069.77)	PEN (3,069.77)	PEN (3,069.77)	PEN 11,941.02	PEN 12,172.94	PEN 12,411.05
Flujo Caja Acum	PEN (3,069.77)	PEN (6,139.54)	PEN (9,209.31)	PEN 2,731.71	PEN 14,904.65	PEN 27,315.69

Inversion total	PEN 9,209.31
Ingreso Adicional Mensual Promedio	PEN 20,638.09

Tabla 32: Flujo Caja económico trimestral

Fuente: Elaboración propia



Ilustración 117: Flujo de Caja económico

Fuente: Elaboración propia

d) Indicadores Económicos.

Se basa en el presente flujo de caja y se presentan los indicadores financieros tasa interna de retorno (TIR), Valor actual neto (VAN) y periodo de recuperación.

TASA Ke	9.48%
B/C	PEN 2.18
TIR	58%
VPN	PEN 17,027.75
PR (MESES)	5.02

Implementación Realizada	Egresos Consolidados	Ingresos consolidados
Sistema planificador de la producción y establecimiento de Inventarios	Horas requeridas para el personal que estara dentro del proyecto de mejora de la planificación de la producción	Reduccion de pagos por horas extras al personal de incumplimiento de los pedidos (penalidades a pagar)

Tabla 33:Indicadores Económicos

Fuente: Elaboración propia

Se cálculo la tasa interna de rentabilidad de la presente implementación de la solución con el cual el VPN de esa inversión es igual a cero. Como se observa se obtuvo una alta tasa interna de retorno y se prevé que en 5.02 meses se realice la recuperación de la inversión por lo que se observa una inversión muy rentable a realizar. A partir de este periodo la empresa recibirá el beneficio total de la implementación.

4.3 Análisis Sensibilidad.

Se realiza el presente análisis de sensibilidad con la finalidad de enfrentar el escenario planteado frente 2 nuevos escenarios el pesimista y el optimista, dado esto se podrá saber cómo se afectaría el proyecto en el caso de caer en alguno de estos dos escenarios. Se utilizará la distribución PERT para el presente estudio.

DATOS	
Crecimiento Trimestral	8.00%
Crecimiento Mensual	2.67%

Mes	Flujo de caja economico					
	Trim 1			Trim 2		
	Oct-19	Nov-19	Dec-19	Ene-20	Feb-20	Mar-20
Egreso	PEN 3,069.77	PEN 3,069.77	PEN 3,069.77			
Ingreso				PEN 11,941.02	PEN 12,172.94	PEN 12,411.05
Flujo Caja	PEN (3,069.77)	PEN (3,069.77)	PEN (3,069.77)	PEN 11,941.02	PEN 12,172.94	PEN 12,411.05

Parametro	Nombres	Pesimista	Base	Optimista
Ventas Mensual Prom 1er Trimestre	F5: RHDP	PEN 36,168.80	PEN 45,211.00	PEN 54,253.20
Ahorro en Penalidades Clientes x PQT	F4: APPHE	PEN 0.31	PEN 0.38	PEN 0.46
Recursos Humanos duracion proyecto	F6: VMPT	PEN 11,051.17	PEN 9,209.31	PEN 7,367.45
Ahorro en Personal produccion H.E	F7: APCPQT	PEN 3,892.74	PEN 3,243.95	PEN 2,595.16
Crecimiento en mercado Mensual	F8: CMM	2.13%	2.67%	3.20%
Porcentaje Penalidad	F9: PP	100.00%	50.00%	40.00%

Tabla 34: Análisis de sensibilidad - parámetros

Fuente: Elaboración propia

a) Vista estática.

Se hace uso del análisis tornado para la captura de los impactos estáticos de cada variable en donde se modificará cada una de estas variables en el modelo especificado y se halla las fluctuaciones en el resultado final. Se lista según las fluctuaciones que genera cada variable en el resultado final. Se uso un rango de variabilidad del 10 %, dado esto se concluye que entre las variables que más afectarían se encuentra las ventas mensuales, el porcentaje de penalidad y el ahorro en el personal de producción. El presente análisis se realiza a partir de los datos base realizando la variación de una variable y manteniendo el resto contante.

Precedent Cell	Base Value: 17027.7478464423			Input Changes		
	Output Downside	Output Upside	Effective Range	Input Downside	Input Upside	Base Case Value
F9: PP	15160.721	18894.774	3734.05	0.45	0.55	0.5
F5: RHDP	15160.721	18894.774	3734.05	0.346259	0.423206	0.3847324
F4: APPHE	15160.721	18894.774	3734.05	40689.9	49732.1	45211
F6: VMPT	17871.222	16184.274	1686.95	8288.379	10130.24	9209.31
F7: APCPQT	16348.526	17706.97	1358.44	2919.555	3568.345	3243.95
F8: CMM	16981.369	17074.205	92.84	0.024	0.029333	0.0266667

Tabla 35: Análisis tornado

Fuente: Elaboración propia

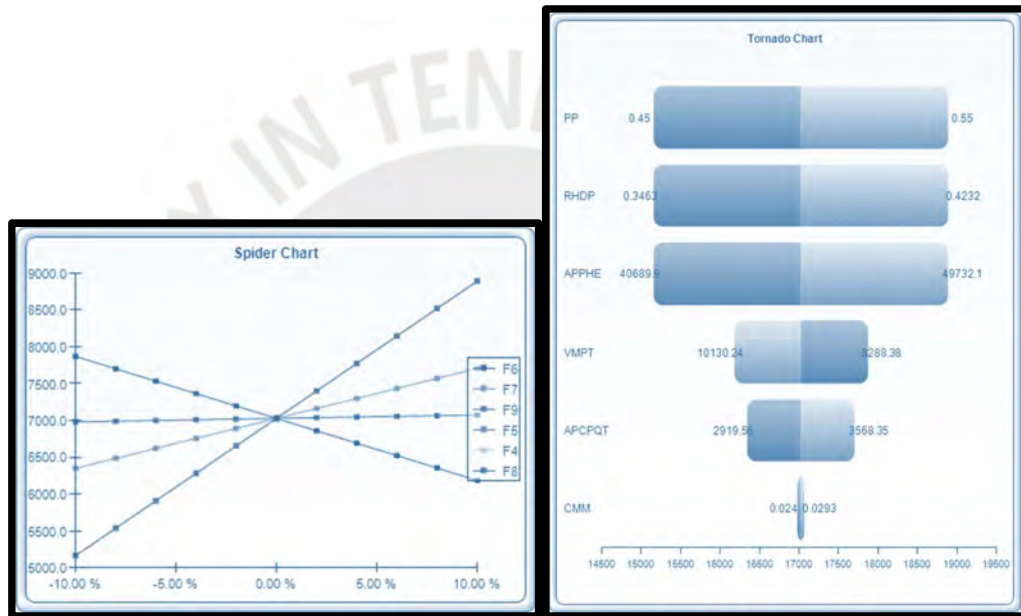


Ilustración 118: Graficas tornado

Fuente: Elaboración propia

b) Vista dinámica.

Se realiza la simulación de Montecarlo con 10000 pruebas con las variables de incertidumbre del presente modelo dando como resultado que en un 82.13% el VPN tendrá valores mayores a 17027 PEN.

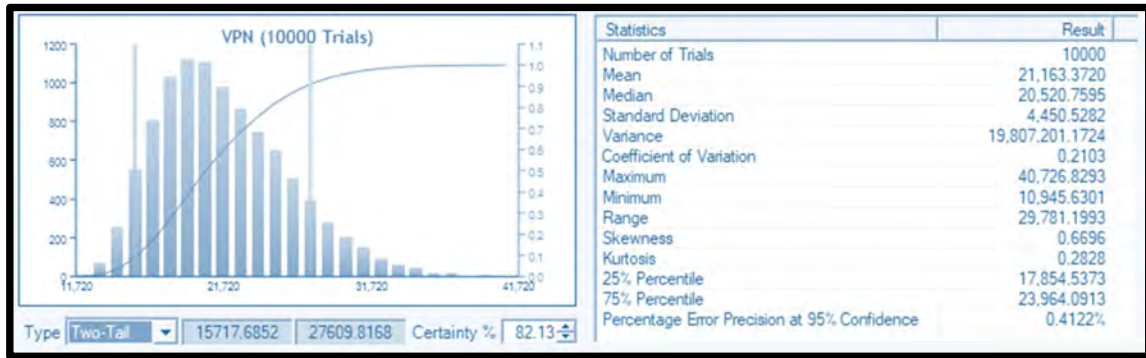


Ilustración 119: Simulación Montecarlo

Fuente: Elaboración propia

Tras esto se procede a realizar el análisis de sensibilidad en el cual se obtiene la correlación no lineal de rango el cual muestra la correlación existente entre cada una de las variables de incertidumbre y de interés del modelo.



Ilustración 120: Correlación sensibilidad Fuente: Elaboración propia

En dicho grafico por ejemplo la correlación entre el VPN y el porcentaje de penalidad es positivo en 0.85 dando la correlación más grande, entiéndase verde por positivo y rojo por negativo. En el esquema de porcentaje de variación explicado permite conocer que variable de incertidumbre explica el VPN y esto en que proporción se realiza.


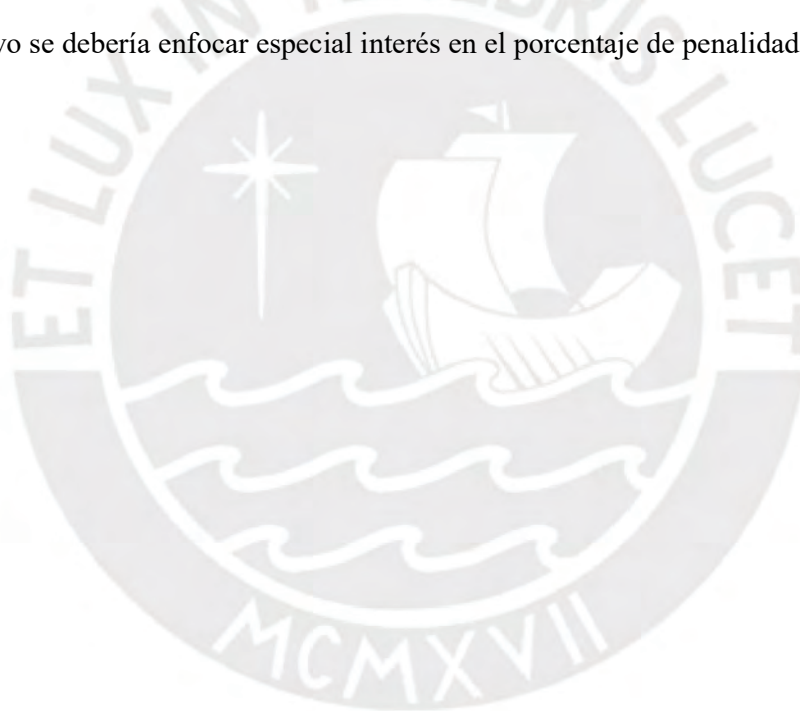


Ilustración 121: Variación explicada

Fuente: Elaboración propia

El presente análisis nos permitió saber el grado de correlación entre todas las variables de incertidumbre y las variables de interés. Esto permite verificar las variables que nos generarían efectos significativos. Por dicho motivo se debería enfocar especial interés en el porcentaje de penalidad.



CONCLUSIONES

La presente tesis busca el desarrollo de una solución que mejore el proceso de la planificación de la producción con la finalidad de evitar el incumplimiento de los pedidos a través de la aplicación de un MPS.

El modelo de pronósticos desarrollados y el sistema de control de inventarios fue enlazado mediante un gestor de la producción (MPS *Master Production Scheduling*), es decir un planificador de la producción futura, el cual integra el estimador *TaktTime* implementándose así al usuario final a través de una interfaz gráfica.

Dado esto se llega a las siguientes conclusiones:

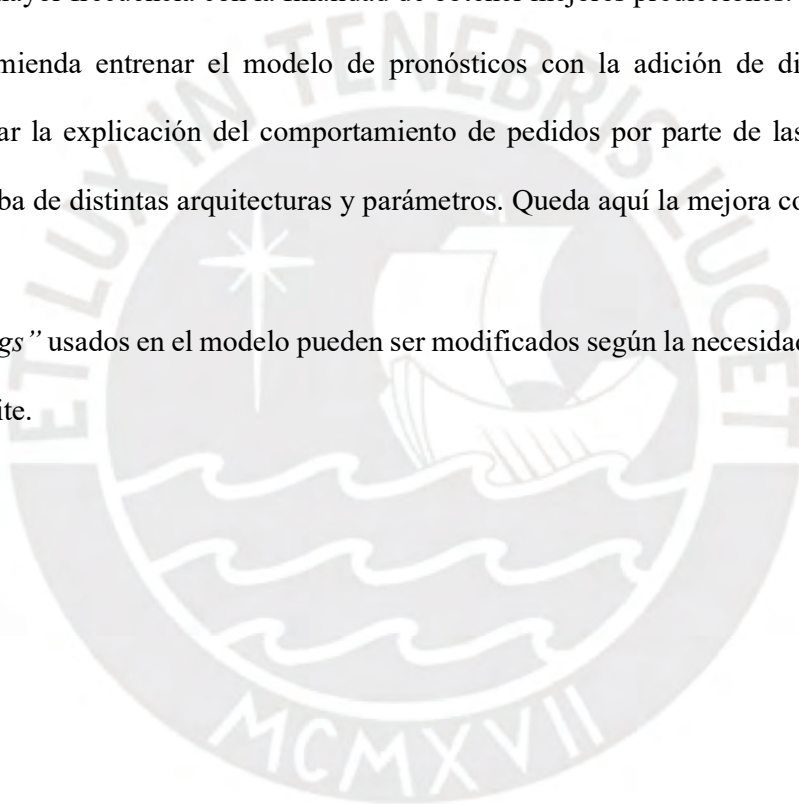
- La carencia de la planificación, la falta de los stocks de seguridad y el establecimiento del punto de pedido generaba un apremio por la culminación de la producción. Estos problemas causan que se salten controles de calidad importantes, se caiga en malas prácticas de gestión y producción, lo que finalmente desemboca en el incumplimiento de pedidos. La correcta planificación permitió (por cada 1000 paquetes en promedio a una penalidad del 50%) una disminución en la tasa de penalidades aplicadas del 41.48%, un beneficio extra de 192.37 PEN.
- Se concluye que la implementación del punto de pedido en los inventarios de insumos permitió evitar el desabastecimiento de los recursos productivos que afectan la elaboración del producto terminado, como a su vez, el establecimiento de los stocks de seguridad permitirá contrarrestar los abruptos que se generan en la demanda de los distintos productos.
- Se concluye que la implementación del cálculo del *TaktTime* y las propuestas adyacentes permiten controlar el ritmo productivo con la finalidad de alcanzar la meta de producción por turno establecido. Gracias a esto, se evidencia una mejora de 80.22% en la reducción del uso de horas extras, una reducción del mal uso de los recursos en un 45.93% y una reducción de la improvisación del 51.47%.

- El cálculo empírico realizado por el área comercial generaba un elevado valor en el RMSE (Métrica comparativa). Esto generaba que producción realizaba la elaboración del producto terminado a partir de lo solicitado. No se preveía los grandes pedidos por venir generando que no se tengan los insumos y producto terminado. Así se generaba el incumplimiento de pedidos. Ante dicho análisis se recurrió a la analítica de datos, en donde el modelo LSTM generaba mejores proyecciones de la demanda debido a su adecuada adaptación a las estacionalidades y tendencias no lineales.
- De acuerdo a los indicadores económicos se concluyó que las propuestas son técnicamente y económicamente viables. Se observa ganancia promedio adicional mensual de 20638.09 para el producto en estudio.



RECOMENDACIONES

- Se propone la interconexión del sistema ERP interno de la empresa con la finalidad que los productos que se registran en el área comercial cuando el área comercial realice su solicitud de producto terminado, este sea registrado en el planificador de la producción con la finalidad de evitar el ingreso manual de dicho número.
- El horizonte del pronóstico es modificable y este puede ser reducido, así el modelo podrá ser entrenado con mayor frecuencia con la finalidad de obtener mejores predicciones.
- Se recomienda entrenar el modelo de pronósticos con la adición de distintas variables que permitan mejorar la explicación del comportamiento de pedidos por parte de las empresas, así como también la prueba de distintas arquitecturas y parámetros. Queda aquí la mejora continua de la solución propuesta.
- Los “*Lags*” usados en el modelo pueden ser modificados según la necesidad del negocio, en caso este así lo amerite.



BIBLIOGRAFÍA

- A neural reinforcement learning approach to learn local dispatching policies in production scheduling . (2006). *University of Karlsruhe: Academic Journal*, 764-787.
- Alvarez, J. D. (2018, Enero 1). ANÁLISIS Y PROPUESTA DE MEJORA DEL SERVICIO DE. LIMA, LIMA, LIMA.
- Brownlee, J. (2018). *How to Develop LSTM Models for Time Series Forecasting*. Retrieved from Machine Learning Mastering: <https://machinelearningmastery.com/how-to-develop-lstm-models-for-time-series-forecasting/>
- Bruner, R. F., & Harris, R. S. (1998). Best Practices in Estimating the Cost of Capital. *FINANCIAL PRACTICE AND EDUCATION*, 28.
- Brunies, R. (2001). Calculating Loss of Productivity Due to Overtime Using Published Charts - Fact or Fiction. *Revay and Associates Limited*, 8.
- Chang, J. E., Gamarra, G. H., & López, P. H. (2019). VALORIZACIÓN DE LA EMPRESA UNIÓN DE CERVECERÍAS PERUANAS BACKUS Y JOHNSTON S.A.A. *Trabajo de Investigación presentado para optar al Grado Académico de Magíster en Finanzas*. Lima, Lima, Peru: Universidad del Pacifico.
- Cheng, F. (2001). *Management Science*. Antai College.
- Colah, C. (2018). *LSTM*. Retrieved from Github: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>
- Damodaran, A. (2014). *Applied Corporate Finance*. New York: Stern School of Business.
- DeMarzo, B. a. (2008). *Corporate Finance*. California: Pearson .
- Espichán Linares, A. M. (2019, 12 02). Implementación de algoritmos para la identificación automática de lenguas originarias peruanas en un repositorio digital. Lima, Lima, Peru. Retrieved from Tesis PUCP: <http://hdl.handle.net/20.500.12404/13482>

- Espinoza, J. E. (2006, 03). Desarrollo de un software para la gestión de proyectos. Lima, Lima, Lima. Retrieved from Tesis Pucp: http://tesis.pucp.edu.pe/repositorio/bitstream/handle/20.500.12404/14431/ESPINOZA_MU%c3%91OZ_JORGE_ENRIQUE.pdf?sequence=1&isAllowed=y
- Flovik, V. (2018, January). *How (not) to use Machine Learning for time series forecasting: Avoiding the pitfalls*. Retrieved from Towards Data Science: <https://towardsdatascience.com/how-not-to-use-machine-learning-for-time-series-forecasting-avoiding-the-pitfalls-19f9d7adf424>
- Flovik, V. (2018, 07 11). *Towards Science*. Retrieved from How (not) to use Machine Learning for time series forecasting: Avoiding the pitfalls: <https://towardsdatascience.com/how-not-to-use-machine-learning-for-time-series-forecasting-avoiding-the-pitfalls-19f9d7adf424>
- GARZÓN, J. I. (2018, NOVEMBER 6). Cómo usar redes neuronales (LSTM) en la predicción de averías en las máquinas.
- Heng Cao, H. X. (2003). A reinforcement learning approach to production planning in the fabrication/fulfillment manufacturing process. *Proceedings of the 2003 Winter Simulation Conference* (pp. 1417 - 1423). YorkTown Heights: IBM T. J. Watson Research Center.
- Jorge Roa, M. R.-A.-L. (2018, November). Predicting Activities in Business Processes with LSTM Recurrent Neural Networks. Ciudad Universitaria, Santa Fe, Argentina.
- Jose L. Gonzalez, D. G. (2010). *Analysis of an Economic Order Quantity and Reorder Point Inventory Control Model for Company XYZ*. Retrieved from <https://digitalcommons.calpoly.edu/cgi/viewcontent.cgi?article=1006&context=imesp>
- Locher, D. A. (2008). *Value Stream Mapping for Lean Development*. New York: CRC PRESS.
- Ordinola, A. (2011, 05). Análisis, diagnóstico y propuesta de mejora del sistema de planeamiento y control de operaciones de una empresa del sector pecuario. Lima, Lima, Peru.

Pacoricuna, E. (2014, 11). Propuesta del programa de producción de la línea de productos líquidos no estériles. Lima, Lima, Peru.

Parraga, J. A. (2011, 11 25). Investigación, análisis y propuestas de políticas de planeamiento y control de inventarios para el sector comercial de productos siderúrgicos. Lima, Lima, Lima.

Stephen A. Ross, J. J. (2009). *Corporate Finance: Core Principles & Applications*. Boston, Massachusetts: McGraw-Hill international edition.

Treasury, U. D. (2019, 10 04). *U.S. DEPARTMENT OF THE TREASURY*. Retrieved from U.S. DEPARTMENT OF THE TREASURY: <https://www.treasury.gov/resource-center/data-chart-center/interest-rates/pages/textview.aspx?data=yield>

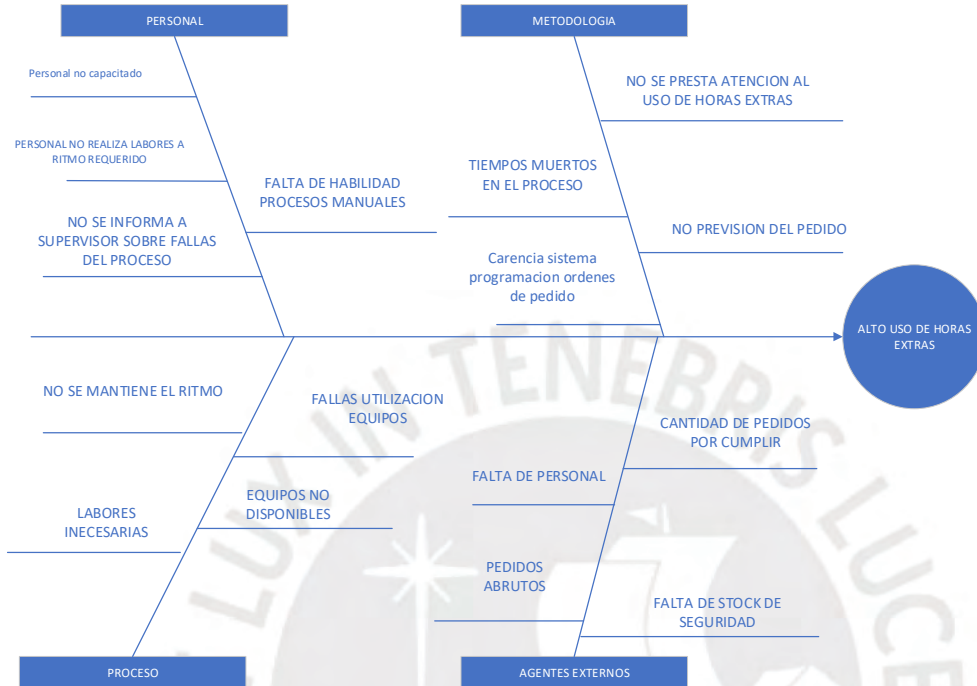
Washesneck, B. (2018). Optimization of global production scheduling with deep reinforcement. *51th Conference Manufacturnig Systems* (pp. 1264-1269). Ausberg: El Sevier. Retrieved from <https://www.sciencedirect.com/science/article/pii/S221282711830372X>

Zapata, M. A. (2015, December). Takt Time el corazon de la produccion. Pereira, Colombia.

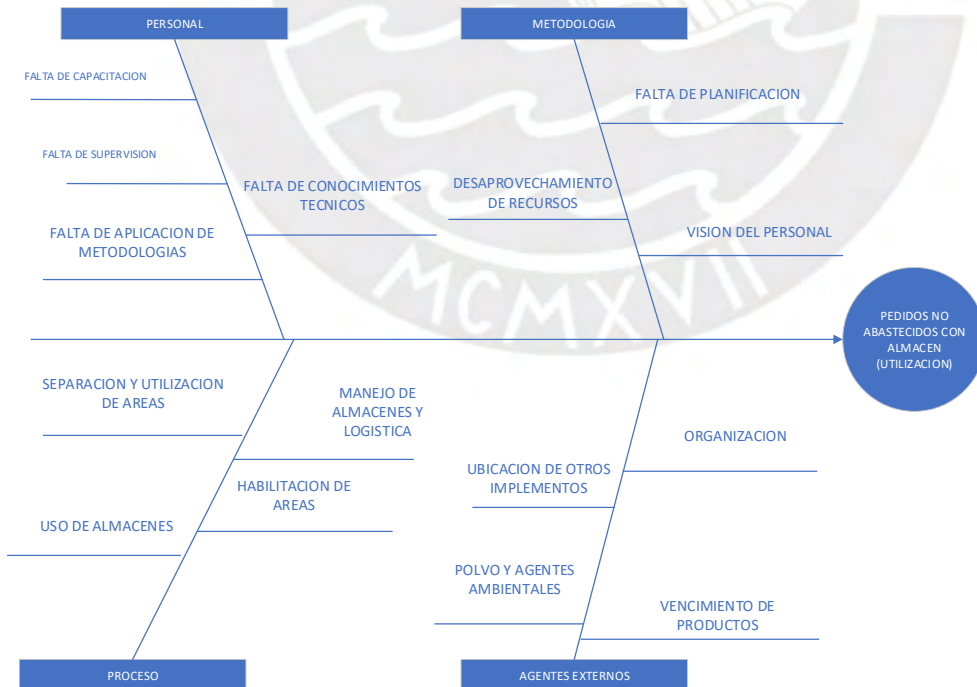


ANEXOS

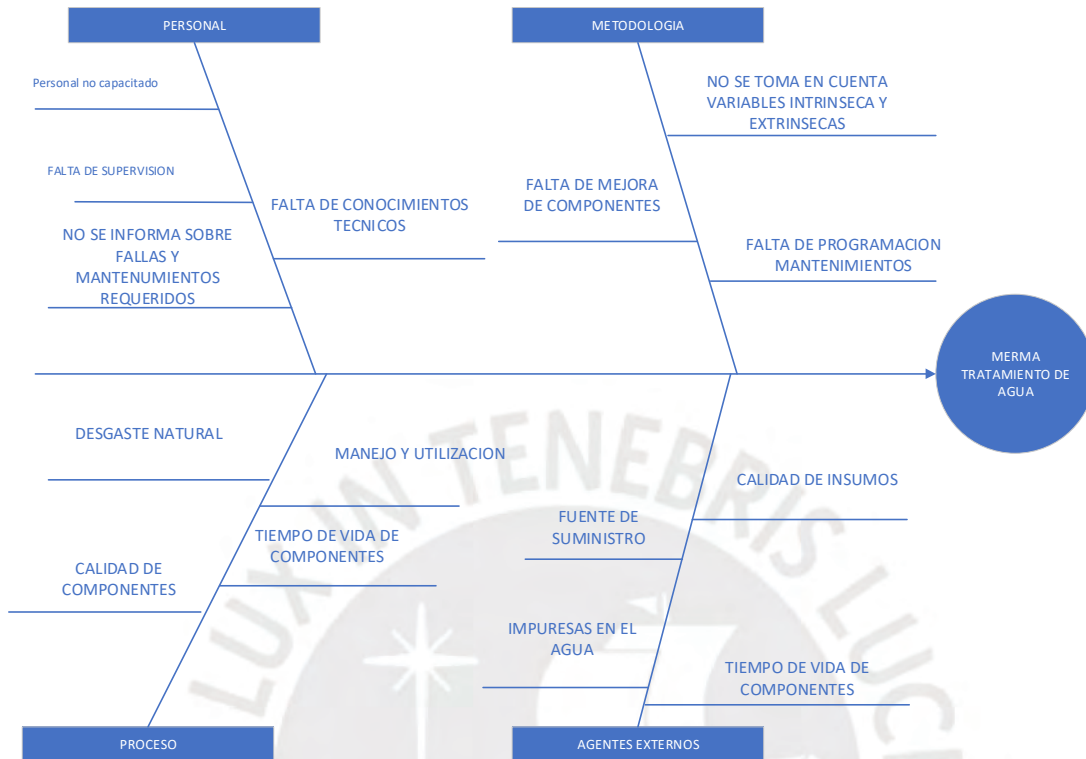
ANEXO 1: Nivel 3 Ishikawa-Alto uso horas extras



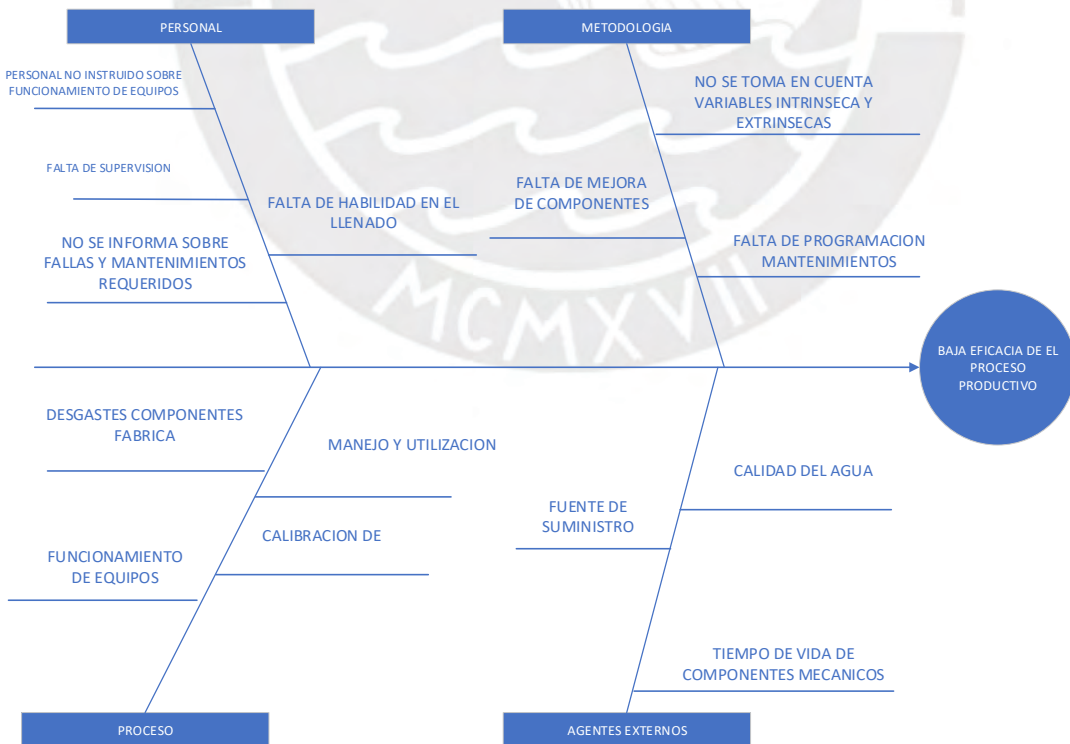
ANEXO 2: Nivel 3 Ishikawa- Pedidos no abastecidos con almacén (Utilización)



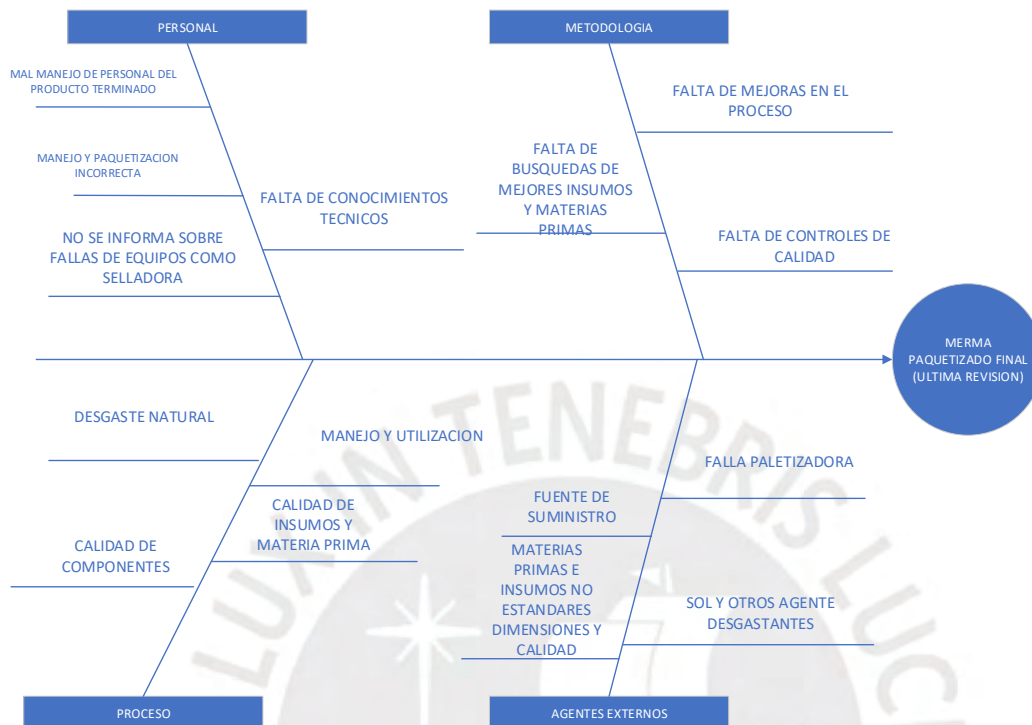
ANEXO 3: Nivel 3 Ishikawa - Merma Tratamiento de agua



ANEXO 4: Nivel 3 Ishikawa – Baja eficiencia del proceso productivo



ANEXO 5: Nivel 3 Ishikawa – Merma paquetizado final



ANEXO 6: Medidas tendencia central Bells 380ml 20L

```

Bells 380 ml
  PRODTERMPQT
count  101.000000
mean   407.732673
std    219.838117
min    78.000000
25%   216.000000
50%   360.000000
75%   528.000000
max   1050.000000
Bells 20 L
  PRODTERMPQT
count  104.000000
mean   264.365385
std    154.959002
min    34.000000
25%   144.000000
50%   245.500000
75%   332.000000
max    770.000000
  
```

ANEXO 7: Medidas tendencia central Cencosud 625ml 7L

```

Cencosud 625 ml
  PRODTERPQT
count  93.000000
mean   247.322581
std    177.275833
min    36.000000
25%   131.000000
50%   187.000000
75%   336.000000
max    805.000000
Cencosud 7 L
  PRODTERPQT
count  95.000000
mean   445.768421
std    237.055898
min    96.000000
25%   232.000000
50%   432.000000
75%   639.500000
max   1328.000000

```

ANEXO 8: Medidas tendencia central Bells 550ml 20L

```


Bells 550 ml
  PRODTERPQT
count  79.000000
mean   506.987342
std    233.033864
min    52.000000
25%   343.000000
50%   482.000000
75%   653.000000
max   1035.000000
Cencosud 20 L
  PRODTERPQT
count  168.000000
mean   393.101190
std    347.471166
min    40.000000
25%   160.000000
50%   324.000000
75%   520.000000
max   3200.000000

```


ANEXO 9: Medidas de dispersión

	Bells 550 ml Desv. Std: 231.55426920401334 Rango: 983 Rango Intercuartil: 310.0 Coef.Variación: 0.4567259379585802 Asimetría: 0.37989044587242005
Bells 380 ml Desv. Std: 218.74710254778614 Rango: 972 Rango Intercuartil: 312.0 Coef.Variación: 0.5364963783620214 Asimetría: 0.7099290051757773	Cencosud 20 L Desv. Std: 346.43548220688376 Rango: 3160 Rango Intercuartil: 360.0 Coef.Variación: 0.8812883059123343 Asimetría: 3.731090918687589
Bells 20 L Desv. Std: 154.2122075440894 Rango: 736 Rango Intercuartil: 188.0 Coef.Variación: 0.5933298023054229 Asimetría: 0.9644090662095487	Cencosud 625 ml Desv. Std: 176.32016097864084 Rango: 769 Rango Intercuartil: 205.0 Coef.Variación: 0.7129157415335681 Asimetría: 1.390739175710811
Bells 550 ml Desv. Std: 231.55426920401334 Rango: 983 Rango Intercuartil: 310.0 Coef.Variación: 0.4567259379585802 Asimetría: 0.37989044587242005	Cencosud 7 L Desv. Std: 235.80493511337443 Rango: 1232 Rango Intercuartil: 407.5 Coef.Variación: 0.5289852846833515 Asimetría: 0.5086683108071944

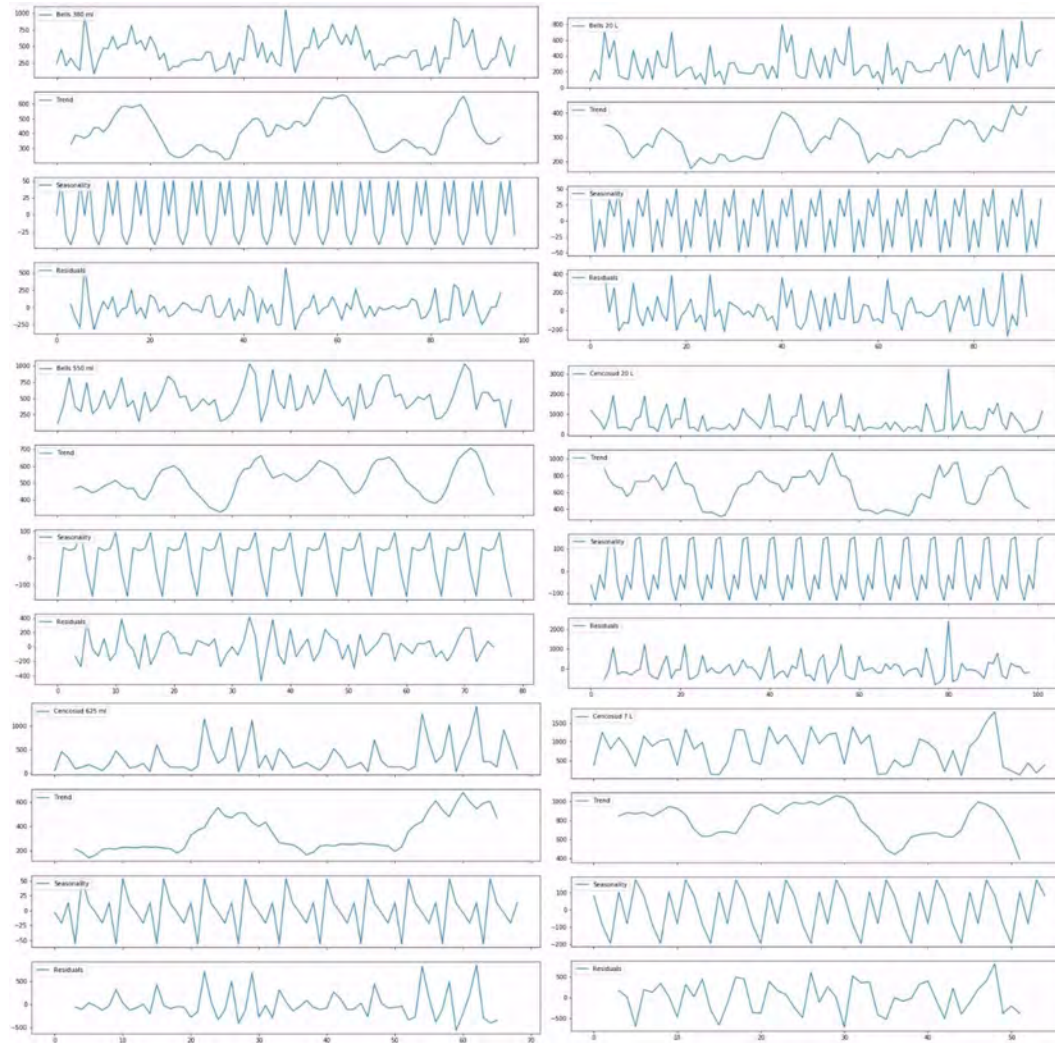
ANEXO 10: Gráficos Unidimensionales



ANEXO 11: Histogramas



ANEXO 12: Descomposición aditiva



ANEXO 13: Verificación estacionalidad

```
#####Bells 625 ml#####
MEDIA[476.55, 998.65, 1085.7, 557.35, 710.15, 962.25, 1118.75, 789.1, 866.1, 658.15]
VARIANZA[54136.847499999996, 237174.72749999995, 231366.31000000006, 98550.12749999999, 65028.42750000005, 278629.0875, 253869.0875, 245011.690000001, 107069.29, 99536.2275000001]
ad fuller test:-5.3901851111160966
pvalue:3.5517479841849884e-06
used lag:2
nob:197
critical values:('1%': -3.463987334463603, '5%': -2.8763259091636213, '10%': -2.5746515171738515)
icbtest:2767.7380202624618

#####Bells 380 ml#####
MEDIA[424.05, 305.15, 449.15, 457.0, 397.95, 515.0]
VARIANZA[53433.947499999995, 19973.1275, 59474.72749999999, 36431.5, 56727.547499999986, 0.0]
ad fuller test:-6.858555967989754
pvalue:1.6246017895055632e-09
used lag:0
nob:100
critical values:('1%': -3.497501033, '5%': -2.89090644, '10%': -2.5824349)
icbtest:1169.782841317822

#####Bells 20 L#####
MEDIA[269.6, 202.3, 306.75, 236.05, 314.0, 230.0]
VARIANZA[24789.04, 11947.71, 27945.5875, 15083.4475, 31300.0, 17100.0]
ad fuller test:-11.537876793433583
pvalue:3.695321800704852e-21
used lag:0
nob:103
critical values:('1%': -3.4954932834550623, '5%': -2.8900369024285117, '10%': -2.5819706975209726)
icbtest:1168.288352550513

#####Bells 550 ml#####
MEDIA[469.05, 491.1, 576.55, 490.42105263157896]
```

```

VARIANZA[45814.2475, 61755.58999999999, 44334.1475, 55887.717451523546]
ad fuller test:-7.3342884038131935
pvalue:1.1069481145473192e-10
used lag:0
nob:78
critical values: {'1%': -3.517113604831504, '5%': -2.8993754262546574, '10%': -2.5869547797501644}
icbtest:906.4522835959227

#####Cencosud 20 L#####
MEDIA[357.9, 362.55, 340.35, 410.85, 386.9, 383.65, 443.35, 458.1, 396.0]
VARIANZA[105576.39000000001, 82184.14750000002, 48026.0275, 114669.2275, 88476.59000000001, 58141.82749999999, 440622.12750000006, 43503.78999999999, 36990.25]
ad fuller test:-13.172340711005006
pvalue:1.2430695532511487e-24
used lag:0
nob:167
critical values: {'1%': -3.470126426071447, '5%': -2.8790075987120027, '10%': -2.5760826967621644}
icbtest:2228.032266632975

#####Cencosud 625 ml#####
MEDIA[166.65, 254.05, 225.95, 261.45, 372.2307692307692]
VARIANZA[8682.527500000002, 20039.947500000002, 26768.6475, 26938.1475, 68896.33136094674]
ad fuller test:-1.7749057200366667
pvalue:0.39298953701345285
used lag:8
nob:84
critical values: {'1%': -3.510711795769895, '5%': -2.8966159448223734, '10%': -2.5854823866213152}
icbtest:1062.9193674217854

#####Cencosud 7 L#####
MEDIA[440.95, 468.45, 496.75, 407.4, 405.1333333333333]
VARIANZA[38849.847499999996, 89386.04749999999, 50787.5875, 58438.64, 27745.84888888889]
ad fuller test:-10.611383817184889
pvalue:5.821909199060608e-19
used lag:0
nob:94
critical values: {'1%': -3.5019123847798657, '5%': -2.892815255482889, '10%': -2.583453861475781}
icbtest:1135.7955094538604

```

ANEXO 14: Modelado-Corrída Unidimensional




```


2017-11-02      Bells 20 L      0.0
2017-11-03      0.0
2017-11-04      0.0
2017-11-05      0.0
2017-11-06      76.0
...
2020-02-25      80.0
2020-02-26      360.0
2020-02-27      0.0
2020-02-28      0.0
2020-02-29      0.0

```

```

[850 rows x 1 columns]
Bells 20 L      float64
dtype: object

```



```


2017-11-02      Bells 380 ml    0.0
2017-11-03      0.0
2017-11-04      238.0
2017-11-05      0.0
2017-11-06      0.0
...
2020-02-25      0.0
2020-02-26      0.0
2020-02-27      515.0
2020-02-28      0.0
2020-02-29      0.0

```

```

[850 rows x 1 columns]
Bells 380 ml   float64
dtype: object

```



```


2017-11-02      Cencosud 20 L    0.0
2017-11-03      0.0
2017-11-04      0.0
2017-11-05      0.0
2017-11-06      0.0
...
2020-02-25      227.0
2020-02-26      0.0
2020-02-27      0.0
2020-02-28      440.0
2020-02-29      461.0

```

```

[850 rows x 1 columns]
Cencosud 20 L  float64
dtype: object

```



```


2017-11-02      Bells 550 ml    0.0
2017-11-03      0.0
2017-11-04      0.0
2017-11-05      0.0
2017-11-06      0.0
...
2020-02-25      0.0
2020-02-26      485.0
2020-02-27      0.0
2020-02-28      0.0
2020-02-29      0.0

```

```

[850 rows x 1 columns]
Bells 550 ml   float64
dtype: object

```



```


2017-11-02      Cencosud 625 ml  0.0
2017-11-03      0.0
2017-11-04      0.0
2017-11-05      0.0
2017-11-06      0.0
...
2020-02-25      0.0
2020-02-26      0.0
2020-02-27      0.0
2020-02-28      0.0
2020-02-29      0.0

```

```

[850 rows x 1 columns]
Cencosud 625 ml float64
dtype: object

```



```


2017-11-02      Cencosud 7 L      0.0
2017-11-03      0.0
2017-11-04      0.0
2017-11-05      0.0
2017-11-06      0.0
...
2020-02-25      0.0
2020-02-26      0.0
2020-02-27      0.0
2020-02-28      0.0
2020-02-29      378.0

```

```

[850 rows x 1 columns]
Cencosud 7 L   float64
dtype: object

```



ANEXO 15: Modelado-Arima

```
#CONFIG ADICIONAL
cf.go_offline()
cf.set_config_file(offline=False, world_readable=True)

datanew = pd.read_csv(pathtofile, header=0, parse_dates=[0], index_col=0, squeeze=True, dtype=float)
#datanew = datanew.resample('W').ffill()

datanew = datanew.resample('D').ffill()
brand=datanew[[product]]

print(brand)
print(brand.dtypes)
brand.plot()
plt.show()

print(brand)

name=brand.keys()
X = brand.values

train_size = int(len(X) * 0.67)
test_size = len(X) - train_size
date=brand.index[train_size]
print(date)

train = brand.loc[:date]
test = brand.loc[date:]

print('Train Set contains:', len(train),'datapoints')
print('Test Set contains:', len(test),'datapoints')

stepwise_model = auto_arima(brand, start_p=1, start_q=1,test='adf',
                             max_p=3, max_q=3, m=52,#####CHEQUAR VALOR
                             start_p=0, seasonal=True,
                             d=1, D=1, trace=True,
                             error_action='ignore',
                             suppress_warnings=True,
                             stepwise=True)

print(stepwise_model.aic())
print(stepwise_model.summary())
stepwise_model.plot_diagnostics(figsize=(8,8))
plt.show()

stepwise_model.fit(train)

future_forecast = stepwise_model.predict(n_periods=test_size)

print(future_forecast)

future_forecast = pd.DataFrame(future_forecast,index = test.index,columns=['Prediction'])

print(test[product])
print(future_forecast['Prediction'])

arima_rmse_error = rmse(test[product], future_forecast['Prediction'])
arima_mse_error = arima_rmse_error**2
mean_value = test[product].mean()
print(f'MSE Error: {arima_mse_error}\nRMSE Error: {arima_rmse_error}\nMean: {mean_value}')

title=str(product)+"--"+"RMSE: "+str(arima_rmse_error)
#print(title)
fig= plt.figure(figsize=(10,3))
plt.title(title)
plt.ylabel('PQTS')
plt.xlabel('Fechas')
plt.plot(test[product], color='b', label='Real')
plt.plot(future_forecast['Prediction'], color='orange', label='Prediccion')

plt.show()
```

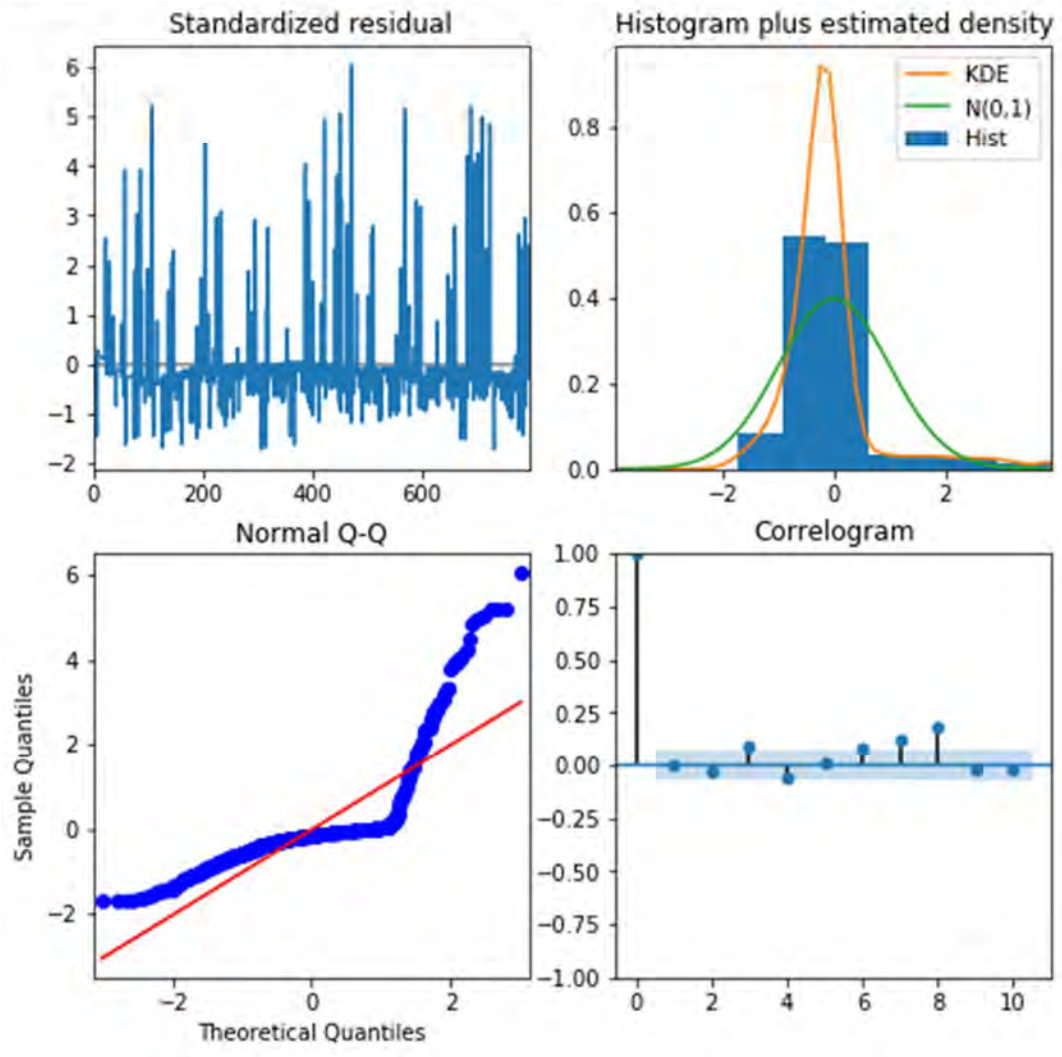
ANEXO 16: Resultados-Arima Bells 20L


SARIMAX Results

```

=====
Dep. Variable:          y          No. Observations:      850
Model:                 SARIMAX(1, 1, 1)x(0, 1, [1, 2], 52)  Log Likelihood         -4816.695
Date:                  Tue, 12 May 2020                    AIC                   9645.389
Time:                  22:09:33                            BIC                   9673.475
Sample:                0                                    HQIC                  9656.180
Covariance Type:      opg
=====
              coef      std err          z      P>|z|      [0.025      0.975]
-----
intercept      0.0063      0.009          0.741      0.458      -0.010      0.023
ar.L1          0.0279      0.034          0.813      0.416      -0.039      0.095
ma.L1         -0.9999      0.436         -2.293      0.022      -1.855     -0.145
ma.S.L52      -0.9772      0.041        -23.932     0.000     -1.057     -0.897
ma.S.L104     0.1564      0.036          4.302      0.000      0.085      0.228
sigma2        9459.9647    4056.281        2.332      0.020    1509.800    1.74e+04
=====
Ljung-Box (Q):                137.70      Jarque-Bera (JB):                4832.47
Prob(Q):                      0.00          Prob(JB):                        0.00
Heteroskedasticity (H):        1.48          Skew:                             2.93
Prob(H) (two-sided):           0.00          Kurtosis:                         13.54
=====

```



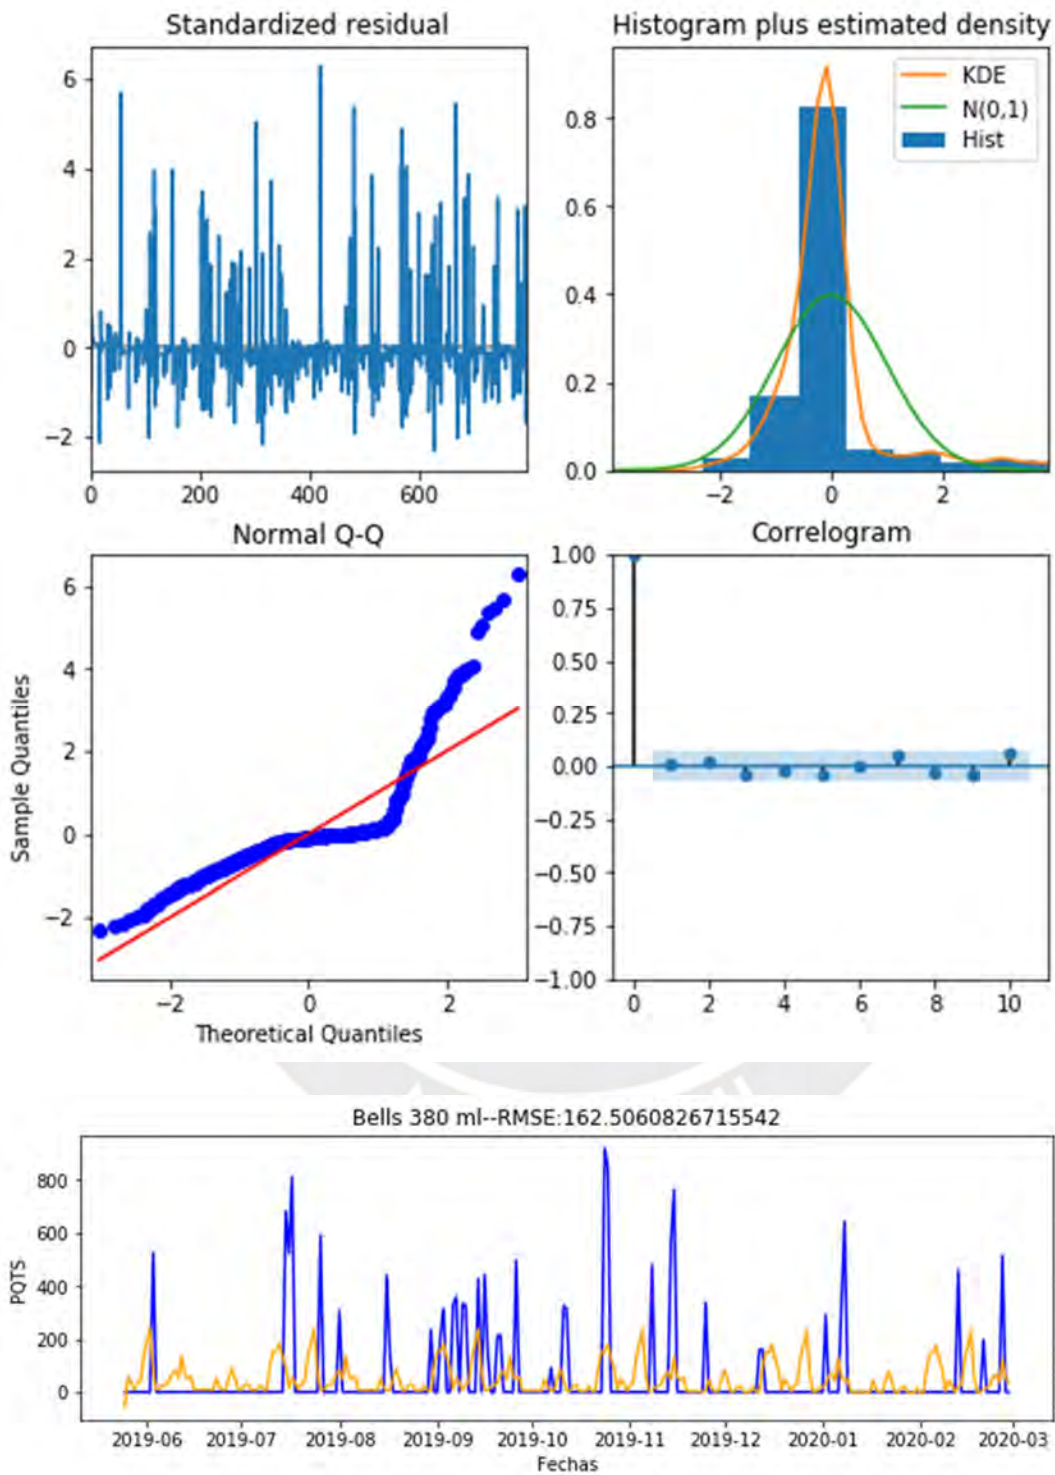


ANEXO 17: Resultado-Arima Bells 380ml

```

=====
SARIMAX Results
=====
Dep. Variable:          y          No. Observations:      850
Model:                 SARIMAX(0, 1, 2)x(0, 1, [1], 52)    Log Likelihood         -5149.241
Date:                  Tue, 12 May 2020                    AIC                    10308.482
Time:                  22:28:52                            BIC                    10331.886
Sample:                0                                    HQIC                   10317.475
Sample:                - 850
Covariance Type:      opg
=====
              coef    std err          z      P>|z|    [0.025    0.975]
-----
intercept    -0.0141     0.020     -0.724    0.469    -0.052     0.024
ma.L1        -0.7004     3.475     -0.202    0.840    -7.511     6.110
ma.L2        -0.2996     1.046     -0.286    0.775    -2.350     1.750
ma.S.L52     -0.9523     0.066    -14.336    0.000    -1.083    -0.822
sigma2       2.067e+04    7.21e+04    0.287    0.774    -1.21e+05  1.62e+05
=====
Ljung-Box (Q):                37.16    Jarque-Bera (JB):                3831.28
Prob(Q):                      0.60    Prob(JB):                       0.00
Heteroskedasticity (H):        1.43    Skew:                            2.56
Prob(H) (two-sided):           0.00    Kurtosis:                       12.44
=====

```



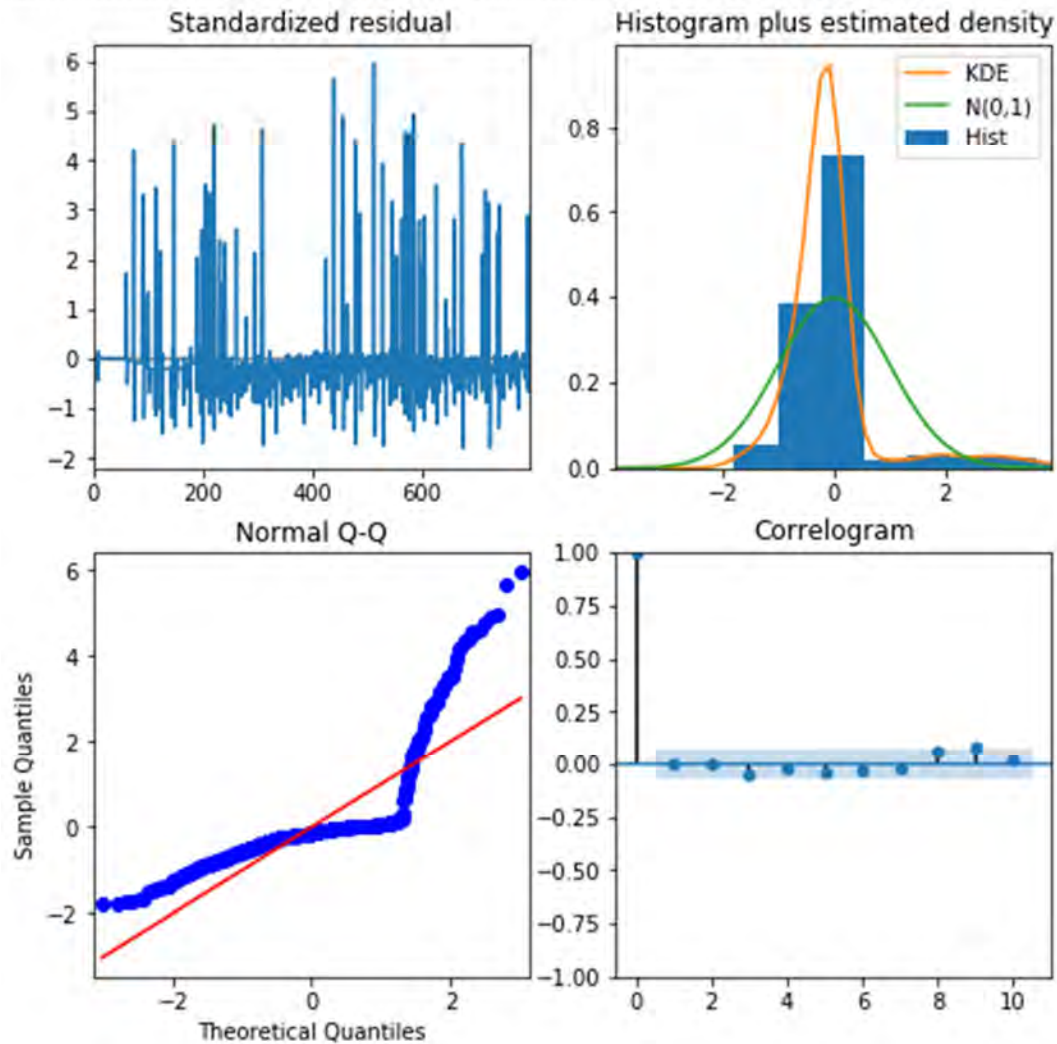
ANEXO 18: Resultado-Arima Bells 550ml


SARIMAX Results

```

=====
Dep. Variable:          SARIMAX(1, 1, 1)x(0, 1, [1, 2], 52)    y    No. Observations:      850
Date:                  Tue, 12 May 2020                      Log Likelihood          -5230.651
Time:                  22:50:42                              AIC                    10473.301
Sample:                0                                     BIC                    10501.386
                       - 850                               HQIC                   10484.092
Covariance Type:      opg
=====
              coef      std err          z      P>|z|      [0.025      0.975]
-----
intercept    -0.0161     0.014      -1.123    0.262     -0.044     0.012
ar.L1         0.2612     0.019     13.678    0.000     0.224     0.299
ma.L1        -1.0000     6.296     -0.159    0.874    -13.341    11.341
ma.S.L52     -1.0634     6.299     -0.169    0.866    -13.409    11.282
ma.S.L104    0.0639     0.389     0.165    0.869     -0.698     0.825
sigma2       2.412e+04    0.000    2.31e+08    0.000    2.41e+04    2.41e+04
=====
Ljung-Box (Q):                62.46    Jarque-Bera (JB):                4441.77
Prob(Q):                      0.01    Prob(JB):                        0.00
Heteroskedasticity (H):       1.47    Skew:                             2.90
Prob(H) (two-sided):          0.00    Kurtosis:                         13.00
=====

```





ANEXO 19: Resultado-Arima Bells 625ml

SARIMAX Results

```

=====
Dep. Variable:          y          No. Observations:      850
Model:                SARIMAX(2, 1, 1)x(0, 1, 1, 52)  Log Likelihood        -5988.628
Date:                 Tue, 12 May 2020  AIC                  11989.256
Time:                 23:14:04      BIC                  12017.341
Sample:               0              HQIC                 12000.047
                    - 850
Covariance Type:     opg
=====

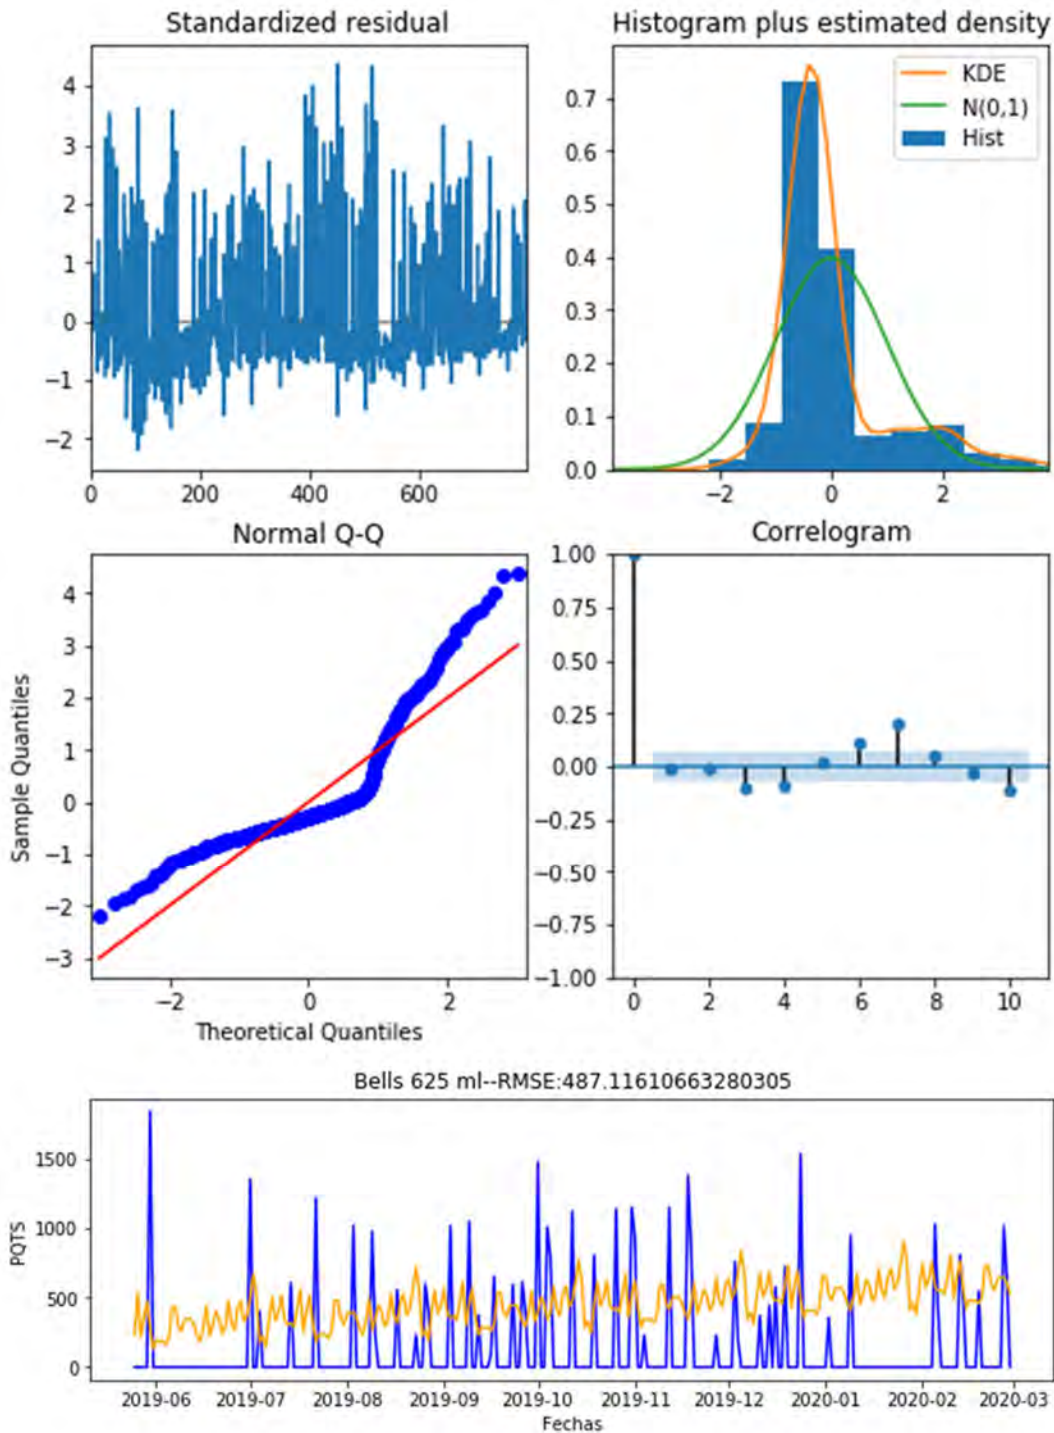
```

	coef	std err	z	P> z	[0.025	0.975]
intercept	-0.0344	0.042	-0.820	0.412	-0.117	0.048
ar.L1	0.0133	0.035	0.378	0.705	-0.056	0.082
ar.L2	-0.0958	0.045	-2.129	0.033	-0.184	-0.008
ma.L1	-1.0000	2.587	-0.387	0.699	-6.070	4.070
ma.S.LS2	-0.9982	2.545	-0.392	0.695	-5.986	3.990
sigma2	1.659e+05	5.6e+05	0.296	0.767	-9.31e+05	1.26e+06

```

=====
Ljung-Box (Q):                204.79  Jarque-Bera (JB):                734.63
Prob(Q):                      0.00    Prob(JB):                        0.00
Heteroskedasticity (H):       0.67    Skew:                            1.76
Prob(H) (two-sided):          0.00    Kurtosis:                        6.13
=====

```

ANEXO 20: Resultado-Arima Cencosud 20L

```

=====
SARIMAX Results
=====
Dep. Variable:          y          No. Observations:      850
Model:                 SARIMAX(2, 1, 2)x(0, 1, [1], 52)  Log Likelihood         -5164.830
Date:                  Wed, 13 May 2020  AIC                   10343.661
Time:                  02:23:16      BIC                    10376.427
Sample:                0              HQIC                   10356.250
Covariance Type:      opg
=====

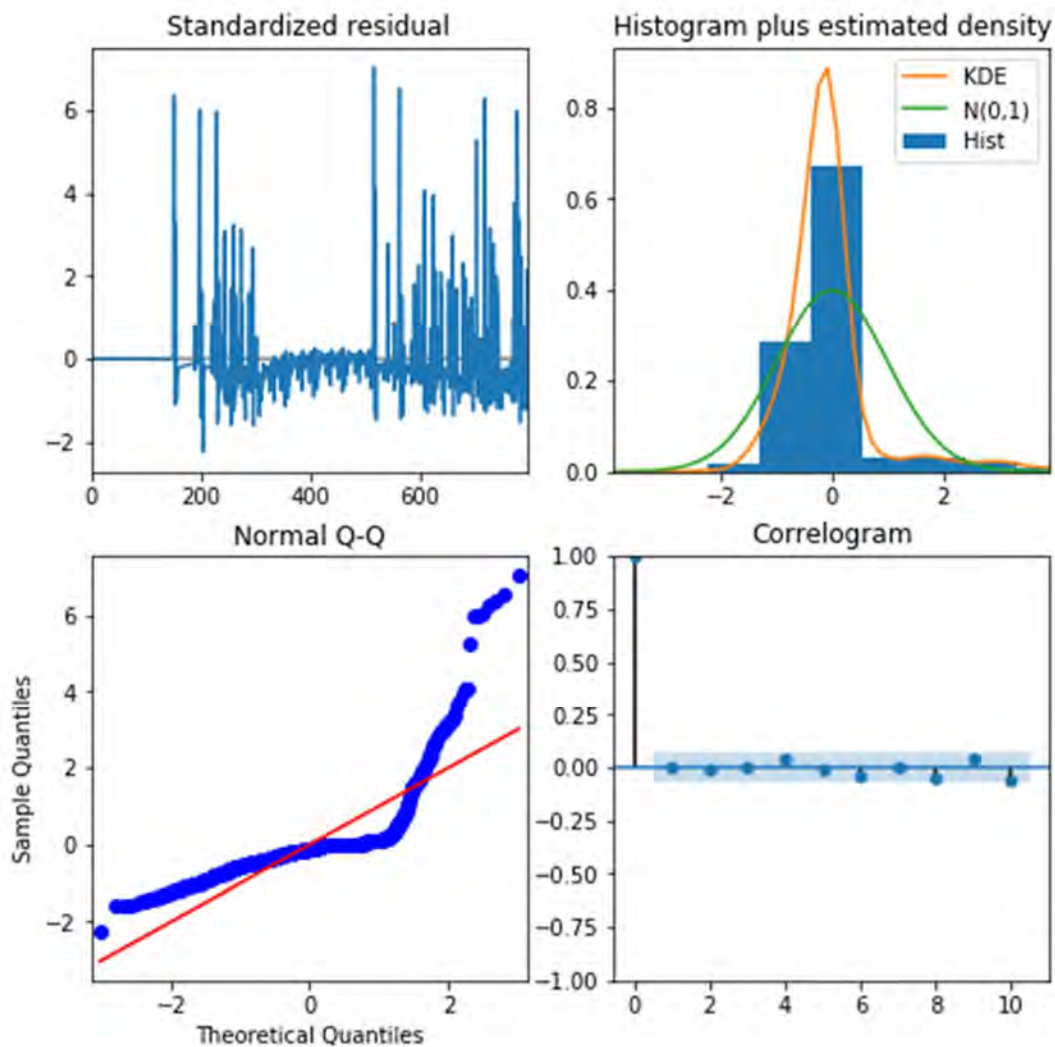
```


	coef	std err	z	P> z	[0.025	0.975]
intercept	0.0103	0.019	0.531	0.595	-0.028	0.048
ar.L1	0.6492	0.376	1.728	0.084	-0.087	1.385
ar.L2	-0.0289	0.071	-0.409	0.683	-0.168	0.110
ma.L1	-1.4797	0.377	-3.922	0.000	-2.219	-0.740
ma.L2	0.4903	0.367	1.335	0.182	-0.230	1.210
ma.S.L52	-0.9930	0.309	-3.210	0.001	-1.599	-0.387
sigma2	2.089e+04	6269.594	3.332	0.001	8603.563	3.32e+04

```

=====
Ljung-Box (Q):                82.12  Jarque-Bera (JB):          10351.84
Prob(Q):                      0.00    Prob(JB):                 0.00
Heteroskedasticity (H):       1.95    Skew:                     3.46
Prob(H) (two-sided):          0.00    Kurtosis:                 19.25
=====

```





ANEXO 21: Resultado-Arima Cencosud 625ml

SARIMAX Results

```

=====
Dep. Variable:          y          No. Observations:      850
Model:                SARIMAX(2, 1, 2)x(0, 1, {1}, 52)  Log Likelihood         -4548.362
Date:                  Wed, 13 May 2020                AIC                    9110.724
Time:                  02:46:00                        BIC                    9143.490
Sample:                0                               HQIC                   9123.313
                    - 850
Covariance Type:      opg
=====

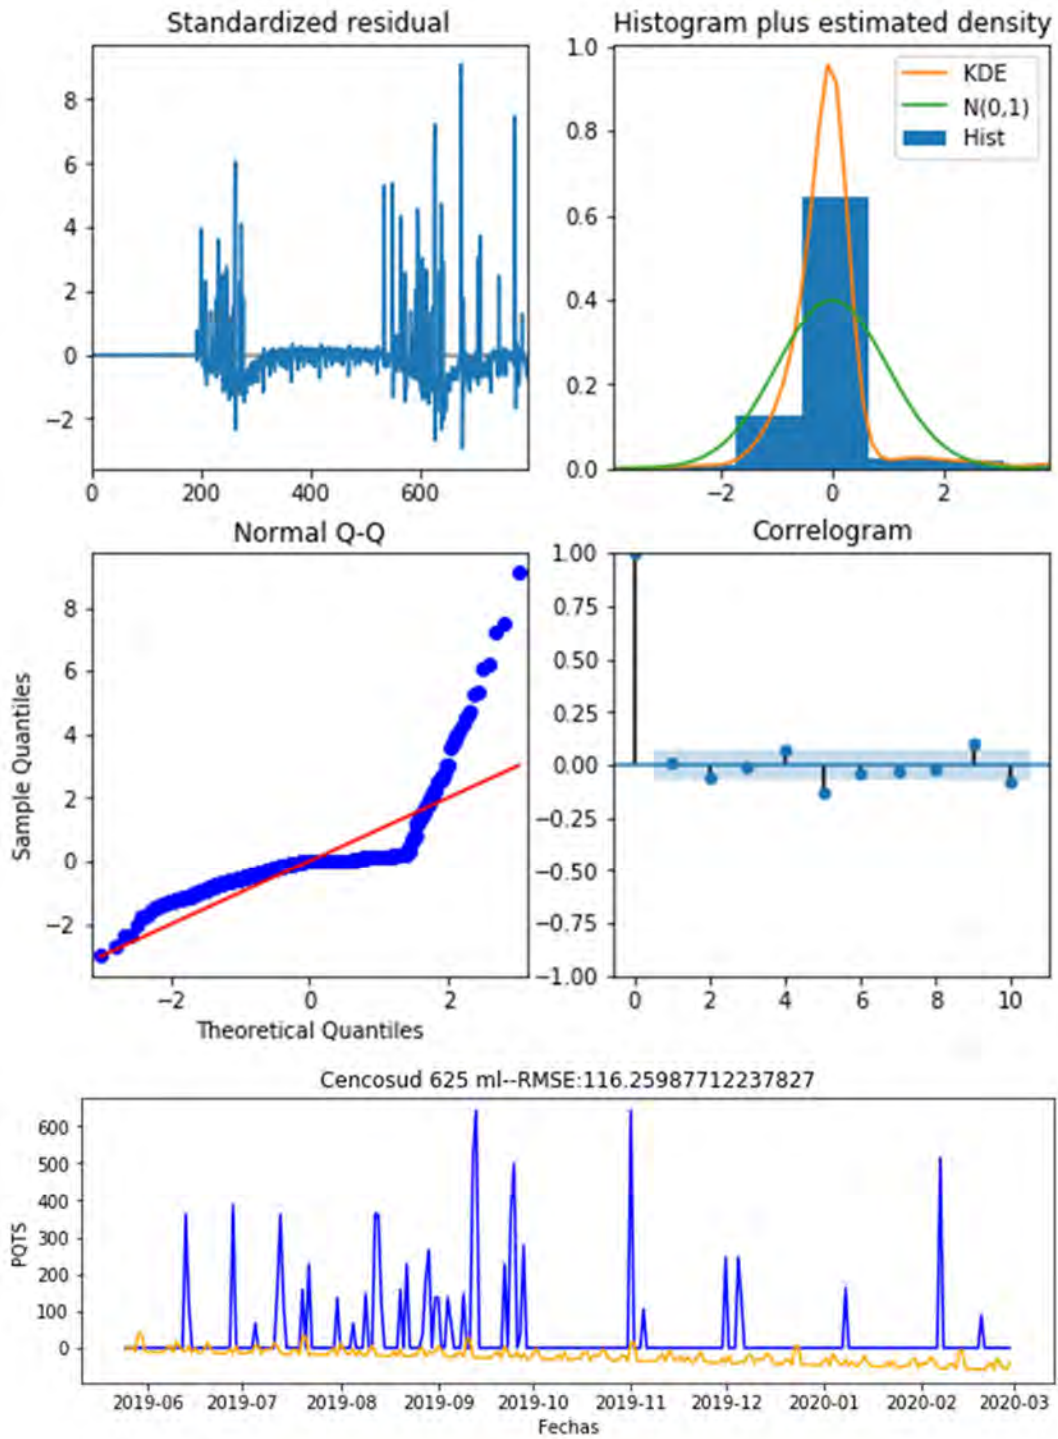
```

	coef	std err	z	P> z	[0.025	0.975]
intercept	-0.0212	0.066	-0.320	0.749	-0.151	0.108
ar.L1	-0.6743	0.084	-8.046	0.000	-0.839	-0.510
ar.L2	0.1249	0.038	3.246	0.001	0.049	0.200
ma.L1	-0.0771	0.087	-0.890	0.374	-0.247	0.093
ma.L2	-0.8425	0.087	-9.717	0.000	-1.012	-0.673
ma.S.L52	-0.9619	0.083	-11.629	0.000	-1.124	-0.800
sigma2	4567.1840	303.738	15.037	0.000	3971.869	5162.499

```

=====
Ljung-Box (Q):          210.32    Jarque-Bera (JB):      20827.06
Prob(Q):                0.00      Prob(JB):              0.00
Heteroskedasticity (H): 3.95     Skew:                  3.95
Prob(H) (two-sided):   0.00      Kurtosis:              26.76
=====

```



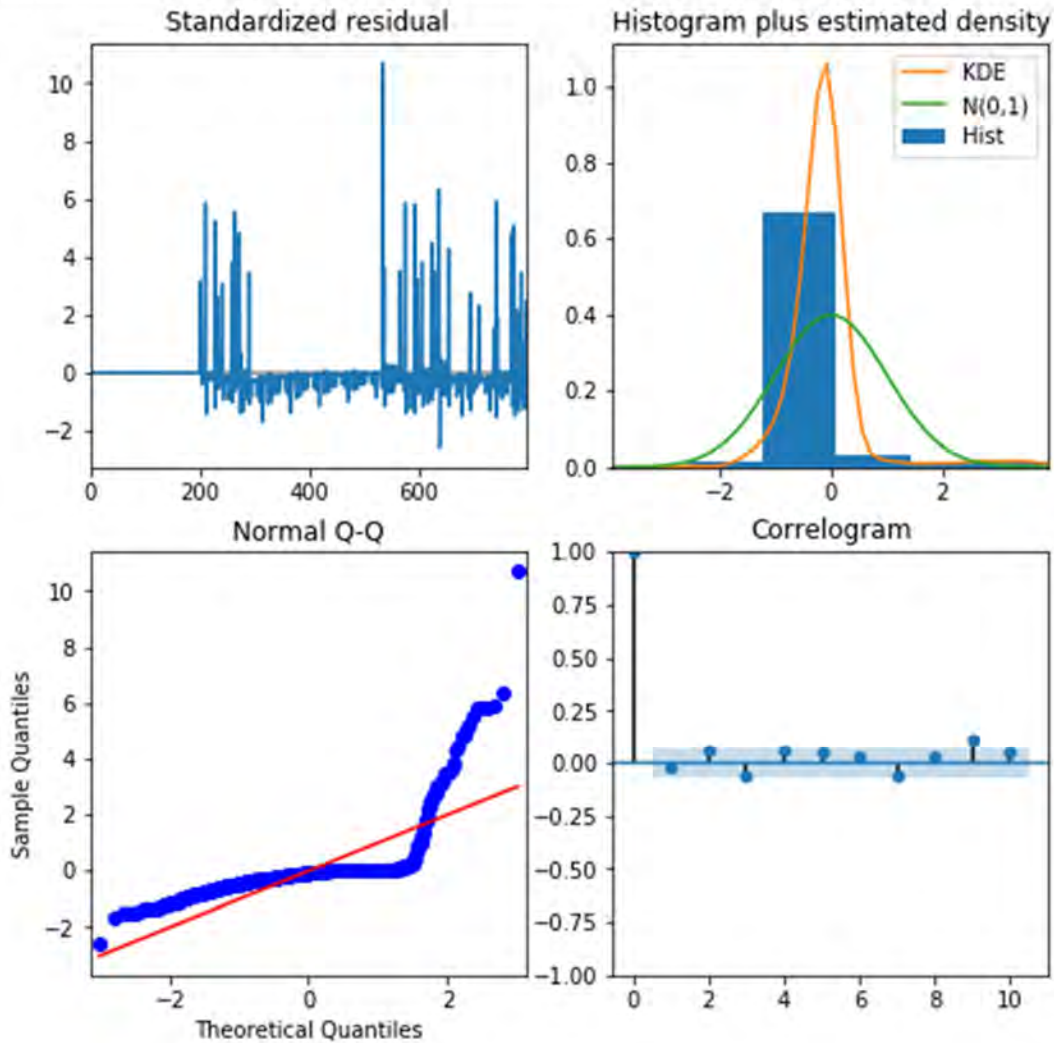
ANEXO 22: Resultado-Arima Cencosud 7L


SARIMAX Results

```

=====
Dep. Variable:          y          No. Observations:      850
Model:                 SARIMAX(2, 1, 2)x(0, 1, [1], 52)      Log Likelihood         -4957.740
Date:                  Wed, 13 May 2020                    AIC                   9929.479
Time:                  07:53:42                            BIC                   9962.245
Sample:                0                                    HQIC                  9942.068
                    - 850
Covariance Type:      opg
=====
                coef    std err          z      P>|z|      [0.025    0.975]
-----
intercept      0.0080    0.021      0.373    0.709    -0.034    0.050
ar.L1          -0.7805    0.027    -29.380    0.000    -0.833    -0.728
ar.L2          0.1889    0.025     7.634    0.000     0.140     0.237
ma.L1         -0.0028    7.759    -0.000    1.000    -15.211    15.205
ma.L2         -0.9972    7.739    -0.129    0.897    -16.166    14.171
ma.S.L52      -0.9208    0.036   -25.424    0.000    -0.992    -0.850
sigma2        1.304e+04  1.01e+05    0.129    0.898   -1.86e+05  2.12e+05
=====
Ljung-Box (Q):                274.36   Jarque-Bera (JB):                32744.28
Prob(Q):                      0.00     Prob(JB):                        0.00
Heteroskedasticity (H):        3.43     Skew:                             4.66
Prob(H) (two-sided):           0.00     Kurtosis:                        32.98
=====

```





ANEXO 23: Modelo- Prophet

```
def run_model(df,product):
    df = df.resample('D').ffill()
    df_pr =df.reset_index()
    brand=df[[product]]
    print(brand)
    #print(brand.dtypes)
    brand.plot()
    plt.show()

    df_pr = brand.reset_index()

    print(df_pr)
    df_pr.columns = ['ds','y']
    print(len(df_pr))
    train_size = int(len(df_pr) * 0.67)
    test_size = len(df_pr) - train_size

    train_data_pr = df_pr.iloc[:train_size]
    test_data_pr = df_pr.iloc[train_size:]

    print('Train Set contains:', len(train_data_pr),'datapoints')
    print('Test Set contains:', len(test_data_pr),'datapoints')
    print(train_data_pr)
    print("#####")
    print(test_data_pr)
    m = Prophet(weekly_seasonality=True,daily_seasonality=True,yearly_seasonality=True)
    m.fit(train_data_pr)

    lenght_test=len(test_data_pr)

    future = m.make_future_dataframe(periods=lenght_test,freq='D')
    #future = m.make_future_dataframe(periods=12,freq='MS')
    prophet_pred = m.predict(future)
    prophet_pred

    prophet_pred = pd.DataFrame({"Date" : prophet_pred[-lenght_test:]['ds'],
                                "Pred" : prophet_pred[-lenght_test:]['yhat']})

    print(prophet_pred)

    prophet_pred = prophet_pred.set_index("Date")
    prophet_pred.index.freq = "D"
    prophet_pred
```



```

prophet_pred.shape
test_data = pd.DataFrame(columns = ['Prophet_Predictions'])
prophet_pred['Pred'].values
test_data["Prophet_Predictions"] = prophet_pred['Pred'].values

print("%XXXXXXXXXXXXXXXXXXXXX")
print(test_data.keys()) #LO FREDICHO
print(test_data)
print("XXXXXXXXXXXXX")
print(test_data_pr.keys()) # EL REAL
print(test_data_pr)
print("%XXXXXXXXXXXXXXXXXXXXX")

print(test_data_pr['y'])
print(test_data["Prophet_Predictions"])

prophet_rmse_error = rmse(test_data_pr['y'], test_data["Prophet_Predictions"])
prophet_mse_error = prophet_rmse_error**2
test_data_pr['y'].mean()

print("XXXXXXXXXXXXXXXXXXXXX")
mean_value = test_data["Prophet_Predictions"].mean()

print(f'MSE Error: {prophet_mse_error}\nRMSE Error: {prophet_rmse_error}\nMean: {mean_value}')

title=str(product)+"--"+RMSE: "+str(prophet_rmse_error)

fig= plt.figure(figsize=(10,3))
print(test_data_pr['y'])

testeo=pd.DataFrame(test_data_pr['y'].values,index = test_data_pr['ds'],columns=['Test'])
real=pd.DataFrame(test_data["Prophet_Predictions"].values
                  ,index = test_data_pr['ds'],columns=['Prediccion'])


print(testeo)
print(real)

plt.plot(testeo, color='b', label='Real')
plt.plot(real, color='orange', label='Prediccion')


plt.title(title)
plt.ylabel('PQTS')
plt.xlabel('Fecha')
plt.show()

```


ANEXO 24: Resultado- Prophet Bells 20L




ANEXO 25: Resultado- Prophet Bells 380ml




ANEXO 26: Resultado- Prophet Bells 550ml




ANEXO 27: Resultado- Prophet Bells 625ml




ANEXO 28: Resultado- Prophet Cencosud 20L



ANEXO 29: Resultado- Prophet Cencosud 625ml



ANEXO 30: Resultado-Prophet Cencosud 7L



ANEXO 31: Modelado-LSTM

```

datanew = pd.read_csv(pathtofile, header=0, parse_dates=[0], index_col=0, squeeze=True, dtype=float)

datanew = datanew.resample('D').ffill()
brand=datanew[[product]]
print(brand)
print(brand.dtypes)
brand.plot()
plt.show()

X = brand.values
print(X)
print(X.dtype)

train_size = int(len(X) * 0.67)
test_size = len(X) - train_size
train, test = X[0:train_size,:], X[train_size:len(X):]
print('Train Set contains:', len(train), 'datapoints')
print('Test Set contains:', len(test), 'datapoints')

#TRANSFORMAR A SUPERVISED LEARNING
def timeseries_to_supervised(data, lag=1):
    df = pd.DataFrame(data)
    columns = [df.shift(i) for i in range(1, lag+1)]
    columns.append(df)
    df = pd.concat(columns, axis=1)
    df.fillna(0, inplace=True)
    return df

supervised = timeseries_to_supervised(X, 1)
print(supervised.head())

#TRANSFORMACION A ESTACIONARIO

#CUANTO CUANTO AUMENTA ENTRE PERIODOS
def difference(dataset, interval=1):
    pd.diff = list()
    for i in range(interval, len(dataset)):
        value = dataset[i] - dataset[i - interval]
        pd.diff.append(value)
    return pd.Series(pd.diff)

#PARA EL FINAL INVERTIR EL CAMBIO
def inverse_difference(history, yhat, interval=1):
    return yhat + history[-interval]

def scale(train, test):
    # fit scaler
    scaler = MinMaxScaler(feature_range=(-1, 1))
    scaler = scaler.fit(train)
    # transform train
    train = train.reshape(train.shape[0], train.shape[1])
    train_scaled = scaler.transform(train)
    # transform test
    test = test.reshape(test.shape[0], test.shape[1])
    test_scaled = scaler.transform(test)
    return scaler, train_scaled, test_scaled

def invert_scale(scaler, X, value):
    new_row = [x for x in X] + [value]
    array = np.array(new_row)
    array = array.reshape(1, len(array))
    inverted = scaler.inverse_transform(array)
    return inverted[0, -1]

```



```

##MODEL
def fit_lstm(train, batch_size, nb_epoch, neurons):
    X, y = train[:, 0:-1], train[:, -1]
    X = X.reshape(X.shape[0], 1, X.shape[1])
    model = Sequential()
    model.add(LSTM(neurons, batch_input_shape=(batch_size, X.shape[1], X.shape[2]), stateful=True))
    model.add(Dense(1))
    model.compile(loss='mean_squared_error', optimizer='adam')
    for i in range(nb_epoch):
        #####
        model.fit(X, y, epochs=1, batch_size=batch_size, verbose=0, shuffle=False)
        #####
        model.reset_states()

    #####
    return model
    #####

#PREDICCION
def forecast_lstm(model, batch_size, X):
    X = X.reshape(1, 1, len(X))
    yhat = model.predict(X, batch_size=batch_size)
    return yhat[0,0]

raw_values = brand.values

diff_values = difference(raw_values)
#MUESTRA LA DIFERENCIA DE t - t-1

#CONVIERTE A LOS t-1 COMO UN X y a los t COMO EL Y
supervised = timeseries_to_supervised(diff_values, 1)
supervised_values = supervised.values

train_size = int(len(supervised_values) * 0.67)
test_size = len(supervised_values) - train_size
train, test = supervised_values[0:train_size,:], supervised_values[train_size:len(supervised_values),:]

print("#####")
# ESCALAR LA DATA PARA EL LSTM entre -1 y 1
scaler, train_scaled, test_scaled = scale(train, test)
#####
epochs=350
lstm_model = fit_lstm(train_scaled, 1, epochs, 1)
#####
train_reshaped = train_scaled[:, 0].reshape(len(train_scaled), 1, 1)
lstm_model.predict(train_reshaped, batch_size=1)
#lstm_model.predict(train_reshaped, batch_size=1)

predictions = list()

for i in range(len(test_scaled)):

    X, y = test_scaled[i, 0:-1], test_scaled[i, -1]
    #yhat = y #PROBAR QUE ESTE BIEN
    yhat = forecast_lstm(lstm_model, 1, X)

    yhat = invert_scale(scaler, X, yhat)

    yhat = inverse_difference(raw_values, yhat, len(test_scaled)+1-i)

    predictions.append(yhat)
    expected = raw_values[len(train) + i + 1]
    print('Dia=%d, Prediccion=%f, Esperado=%f' % (i+1, yhat, expected))

rmse = math.sqrt(mean_squared_error(raw_values[-len(test):], predictions))
print('Test RMSE: %.2f' % rmse)

```

```

title=str(product)+"--"+RMSE: "+str(rmse)

#####

fig= plt.figure(figsize=(10,3))
print(brand[-len(test):].index)

real=pd.DataFrame(raw_values[-len(test):],index = brand[-len(test):].index,columns=['Test'])
testeo=pd.DataFrame(predictions,index = brand[-len(test):].index,columns=['Prediccion'])


print(testeo)
print(real)

plt.plot(real, color='b', label='Real')
plt.plot(testeo, color='orange', label='Prediccion')


plt.title(title)
plt.ylabel('PQTS')
plt.xlabel('Fecha')
plt.show()

```


ANEXO 32: Resultado-LSTM Bells 20L



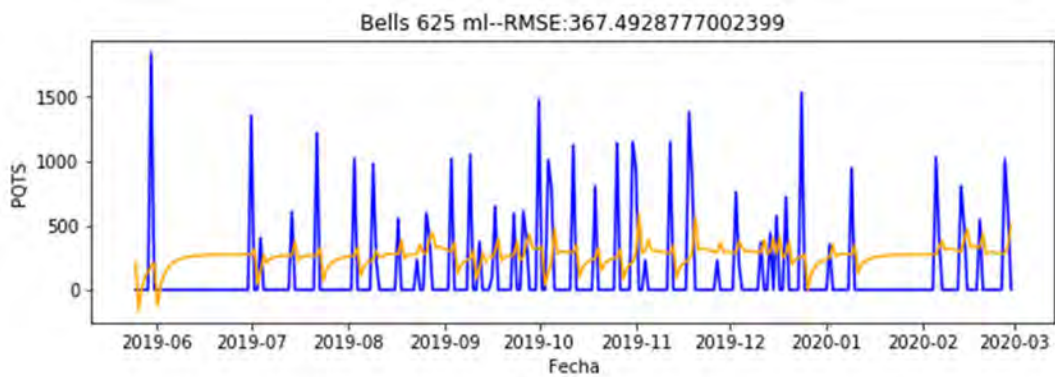
ANEXO 33: Resultado-LSTM Bells 380ml




ANEXO 34: Resultado-LSTM Bells 550ml




ANEXO 35: Resultado-LSTM Bells 625ml



ANEXO 36: Resultado-LSTM Cencosud 20L



ANEXO 38: Resultado-LSTM Cencosud 625ml



ANEXO 39: Resultado-LSTM Cencosud 7L

