

**USO DE HERRAMIENTAS DE ANÁLISIS DE DATOS PARA REDUCIR
EL CONSUMO DE ENERGÍA EN UNA PLANTA DE EMBOTELLADO
DE BEBIDAS CARBONATADAS**

Alumno: Cristian Fernando Ruiz Caro

Tutor: Mariano Gustavo Pérez

Buenos Aires, abril 2019

AGRADECIMIENTOS

A mi esposa Carolina por su apoyo incondicional y afecto, a mi hija Sofia por su paciencia y cariño, y a toda mi familia que con sus consejos y soporte hacen día a día de mí una mejor persona y me acompañan en mis sueños y metas.

RESUMEN

El consumo de energía en las industrias es un tema crítico por el impacto en los costos y en la sustentabilidad de los negocios.

La ciencia de datos está avanzando a pasos agigantados en todos los ámbitos de negocio como un soporte a la toma de decisiones en todos los niveles de la organización.

Dado el alto grado de automatización y de instrumentos de medición con los que cuentan los procesos de producción en la industria de bebidas carbonatadas de consumo masivo, resulta de especial interés explorar el uso de esa información para agregar valor al negocio.

La presente tesis muestra la aplicación de diferentes modelos de análisis de datos para dar soporte a la toma de decisiones con el objeto de mejorar la sustentabilidad y rentabilidad del negocio a través de la reducción del consumo de energía.

La metodología utilizada en el análisis sigue los lineamientos del modelo Cross Industry Standard Process for Data Mining (CRISP-DM), ampliamente difundido y utilizado en proyectos de Data Mining.

PALABRAS CLAVE: Data mining, insights, ahorro de energía, regresión lineal, redes neuronales, Perceptrón multicapa, planta de refrigeración, embotellado, bebidas carbonatadas.

INDICE

LISTA DE TABLAS	V
LISTA DE FIGURAS	V
GLOSARIO	VI
INTRODUCCIÓN	VIII
OBJETIVO GENERAL	X
OBJETIVOS ESPECÍFICOS	X
CUERPO TEORICO	1
CAPITULO 1: MODELO CRISP-DM	1
1.1 INTRODUCCIÓN	1
1.2 MODELO CRISP-DM	1
1.2.1 FASE 1: ENTENDIMIENTO DEL NEGOCIO	2
1.2.2 FASE 2: ENTENDIMIENTO DE LOS DATOS:	3
1.2.3 FASE 3: PREPARACIÓN DE LOS DATOS	3
1.2.4 FASE 4: MODELADO	4
1.2.5 FASE 5: EVALUACIÓN	4
1.2.6 FASE 6: IMPLEMENTACIÓN	5
CAPÍTULO 2 MINERÍA DE DATOS COMO HERRAMIENTA PARA LA PREDICCIÓN DE DATOS UTILIZANDO TÉCNICAS NO PARAMÉTRICAS	6
2.1 TAREAS BÁSICAS DE MINERÍA DE DATOS.	6
2.2 TÉCNICAS DE DATA MINING	8
2.2.1 PARAMÉTRICAS	8
2.2.2 NO PARAMÉTRICAS	8
2.2.2.1 ARBOLES DE DECISIÓN.	9
2.2.2.2 REDES NEURONALES	10
2.2.2.2.5 ALGORITMOS DE REDES NEURONALES	16
2.2.2.3 ALGORITMOS GENÉTICOS	17
2.3 DATA MINING DE TEXTO	17
2.4 HERRAMIENTAS ESTADÍSTICAS	18
2.4.1 DESCRIPTORES ESTADÍSTICOS:	18
2.4.2 ANÁLISIS DE REGRESIÓN	19
2.4.2.1 ESTIMACIÓN DE LOS COEFICIENTES EN UNA REGRESIÓN	19
2.4.3 NORMALIZACIÓN (ESTADÍSTICA)	20
2.4.4 COEFICIENTES DE CORRELACIÓN	21
2.4.4.1 COEFICIENTE DE CORRELACIÓN DE PEARSON	21
2.4.4.2 COEFICIENTE DE CORRELACIÓN DE SPEARMAN, P (RHO)	22
2.4.4.3 CORRELACIÓN CANÓNICA	22

CUERPO EMPIRICO	23
CAPÍTULO 3: PRESENTACIÓN GENERAL DE LA EMPRESA	23
3.1 COCA COLA FEMSA	23
3.2 EL SISTEMA COCA COLA	23
3.2.1 SISTEMA COCA-COLA EN ARGENTINA	24
3.3 COCA COLA FEMSA ARGENTINA (KOFAR)	24
3.3.1 PLANTA ALCORTA	25
3.4 PROCESO DE EMBOTELLADO DE BEBIDAS CARBONATADAS	26
3.4.1 PREPARACIÓN DE LOS INGREDIENTES	26
3.4.2 FORMULACIÓN DEL JARABE TERMINADO	26
3.4.3 AGREGADO DE GAS CARBÓNICO	27
3.4.4 ENVASADO Y CODIFICADO	27
3.4.4.1 PROCESO DE LLENADO	27
3.4.5 ENCAJONADO/EMPACADO Y PALLETIZADO	29
3.4.6 DISTRIBUCIÓN	30
3.5 CONSUMO DE ENERGÍA EN UNA PLANTA DE EMBOTELLADO	30
3.5.1 DISTRIBUCIÓN DE CONSUMO POR SECTORES	30
3.5.2 ESTRATEGIA DE SOSTENIBILIDAD	31
3.5.3 GUÍA PARA AHORRO DE ENERGÍA	32
3.5.4 MES (MANUFACTURING EXECUTION SYSTEM)	32
3.5.4.1 MES PLANTA ALCORTA	33
CAPITULO 4: ANÁLISIS DE DATOS PARA REDUCCIÓN DEL CONSUMO DE ENERGÍA EN UNA PLANTA DE EMBOTELLADO	34
4.1 METODOLOGÍA PARA EL ANÁLISIS DE DATOS.	34
4.1.1 FASE 1: ENTENDIMIENTO DEL NEGOCIO.	34
4.1.1.1 RELEVAMIENTO DE LA SITUACIÓN ACTUAL:	34
4.1.1.3 OBJETIVOS DEL PROYECTO DE ANÁLISIS DE DATOS	41
4.1.2 FASE 2: ENTENDIMIENTO DE LOS DATOS:	42
4.1.2.1 RECOLECCIÓN INICIAL DE DATOS:	42
4.1.2.2. DESCRIPCIÓN DE LOS DATOS	43
4.1.3 FASE 3: PREPARACIÓN DE LOS DATOS	45
4.1.3.1 EXPLORACIÓN DE DATOS	45
4.1.3.2 EXPLORACIÓN INICIAL	47
5.1.3.3 CONSTRUCCIÓN DE DATOS: LIMPIEZA DE DATOS	48
4.1.4 FASE 4: MODELADO	50
4.1.4.1 ANÁLISIS DEL ERROR	63
4.1.4.2 CONCLUSIÓN DEL ANÁLISIS DEL ERROR:	64

4.1.5 FASE 5: EVALUACIÓN	67
4.1.5.1 PLAN DE ACCIÓN:	67
4.1.6 FASE 6: IMPLEMENTACIÓN	68
CONCLUSIONES	71
REFERENCIAS	74
BIBLIOGRAFÍA GENERAL	80
ANEXOS	82

Lista de tablas

TABLA 1 DETALLE DE LÍNEAS DE EMBOTELLADO DE PLANTA ALCORTA (2018).	25
TABLA 2: DETALLE DE VARIABLES DE INTERÉS PARA LA PLANTA DE REFRIGERACIÓN MEDIDAS EN LÍNEAS DE ENVASADO	44
TABLA 3: VALORES MÁXIMOS, MÍNIMOS Y PROMEDIO DE VARIABLES DEL CIRCUITO DE REFRIGERACIÓN DE DATOS SIN DEPURAR DE UNA MUESTRA (10/02/2019 AL 24/02/2019).	48
TABLA 4: VALORES MÁXIMOS, MÍNIMOS Y PROMEDIO DE VARIABLES ASOCIADAS AL CIRCUITO DE REFRIGERACIÓN DE DATOS DE UNA NUESTRA CORREGIDA (10/02/2019 AL 24/02/2019).	49
TABLA 5 COMPARACIÓN DE RESULTADOS OBTENIDOS POR DISTINTOS MÉTODOS PARA ANALIZAR LA CORRELACIÓN ENTRE LA TEMPERATURA DE LLENADO Y EL CONSUMO DE ENERGÍA.	63
TABLA 6 SIMULACIÓN DE DIFERENTES ESCENARIOS MODIFICANDO LA TEMPERATURA DE LLENADO PARA LA DETERMINACIÓN DEL IMPACTO EN EL CONSUMO DE ENERGÍA.	64
TABLA 7: TABLA INPUT PARA ANÁLISIS DE SENSIBILIDAD DE VARIACIÓN DE LA POTENCIA DE FRÍO POR VARIACIONES EN LA TEMPERATURA DE LLENADO POR LÍNEA.	65
TABLA 8: RESUMEN DEL ANÁLISIS DE SENSIBILIDAD DEL CONSUMO DE ENERGÍA DE REFRIGERACIÓN PARA DISTINTAS TEMPERATURAS DE LLENADO	66

Lista de figuras

FIGURA 2: METODOLOGÍA UTILIZADA PARA ANALÍTICA, MINERÍA DE DATOS O CIENCIA DE DATOS 2014 KDNUGGETS.	1
FIGURA 3: DIAGRAMA DEL PROCESO CRISP-DM SOBRE LA RELACIÓN ENTRE LAS DIFERENTES FASES.	2
FIGURA 4: REGIONES DE DECISIÓN OBTENIDAS CON EL PERCEPTRÓN SIMPLE (ARRIBA), LA MULTICAPA CON UNA CAPA OCULTA (EN MEDIO) Y CON DOS CAPAS OCULTAS (ABAJO) ⁴⁰	13
FIGURA 5: PERCEPTRÓN SIMPLE Y PERCEPTRÓN MULTICAPA	14
FIGURA 1: PARTICIPACIÓN DEL CONSUMO DE ENERGÍA ELÉCTRICA POR USO FINAL EN PLANTA ALCORTA. ANTEA GROUP (2015).	30
FIGURA 6 ESPECIFICACIONES TÉCNICAS LLENADORA VOLUMETIC VODM-PET 5.760-128-141, K136628	36
FIGURA 7: ESPECIFICACIONES DE TEMPERATURAS DE LLENADO DE LLENADORA INNOFILL DVR-PET 180/36SC 36PI	37

FIGURA 8: HISTOGRAMA DE TEMPERATURAS DE LLENADO EN LÍNEA 2. PLANTA ALCORTA. ABRIL 2018.	38
FIGURA 9: HISTOGRAMA DE TEMPERATURAS DE LLENADO EN LÍNEA 3. PLANTA ALCORTA. ABRIL 2018	38
FIGURA 10 HISTOGRAMA DE TEMPERATURAS DE LLENADO EN LÍNEA 4, PLANTA ALCORTA. ABRIL 2018	39
FIGURA 11: HISTOGRAMA DE TEMPERATURAS DE LLENADO EN LÍNEA 9, PLANTA ALCORTA. ABRIL 2018	39
FIGURA 12 MINUTOS DE PARADAS POR ESPUMADO EN EL PERIODO ENE-FEB/2019 EN PLANTA ALCORTA.	41
FIGURA 13: PUERTOS Y ESTATUS DE NODOS	46
FIGURA 14: EJEMPLO DE FLUJO DE TRABAJO	46
FIGURA 15: DATOS DE CONSUMO DE ENERGÍA EN LA PLANTA DE REFRIGERACIÓN SIN DEPURAR	49
FIGURA 16: MODELO PARA EL ANÁLISIS DE CORRELACIONES ENTRE DATOS DE LA PLANTA DE REFRIGERACIÓN	50
FIGURA 17: CONFIGURACIÓN EN KNIME DEL NODO NORMALIZER.	51
FIGURA 18: MATRIZ DE CORRELACIONES SEGÚN EL COEFICIENTE DE SPEARMAN	52
FIGURA 19 COEFICIENTES DE CORRELACIÓN DE SPEARMAN PARA LAS VARIABLES DE EMBOTELLADO EN RELACIÓN AL CONSUMO DE ENERGÍA DE LA PLANTA DE REFRIGERACIÓN.	52
FIGURA 20: TEMPERATURA DE LLENADO EN LÍNEA 2 VS CONSUMO DE ENERGÍA EN PLANTA DE REFRIGERACIÓN	54
FIGURA 21: TEMPERATURA DE LLENADO EN LÍNEA 3 VS CONSUMO DE ENERGÍA EN PLANTA DE REFRIGERACIÓN	54
FIGURA 22 TEMPERATURA DE LLENADO EN LÍNEA 8 VS CONSUMO DE ENERGÍA EN PLANTA DE REFRIGERACIÓN	55
FIGURA 23 TEMPERATURA DE LLENADO, CAUDAL DE PRODUCTO Y CANTIDAD DE BOTELLAS PRODUCIDAS EN LÍNEA 2 EL 13/03/2019 DE 19:27 A 20:48	56
FIGURA 24: TEMPERATURA DE LLENADO VS CAUDAL DE BEBIDA EN LÍNEA 2 (13/03/2019)	56
FIGURA 25: TEMPERATURA DE LLENADO VS FLUJO DE PRODUCTO EN LÍNEA 9 15/03/2019	57
FIGURA 26 FLUJO DE PROCESO DE REGRESIONES POLINÓMICAS	59
FIGURA 27: CONFIGURACIÓN DEL BLOQUE RPROP MLP LEARNER	60
FIGURA 28: CONFIGURACIÓN DEL NODO NORMALIZER	60
FIGURA 29: FLUJO DE TAREAS PARA UNA RED NEURONAL DE APRENDIZAJE SUPERVISADO DEL TIPO RPROP MULTILAYER PERCEPTRON PREDICTOR	61
FIGURA 30. FLUJO DE TRABAJO PARA UNA RED NEURONAL CON NODO PNN LEARNER	62
FIGURA 31: CONFIGURACIÓN NODO PNN LEARNER (DDA)	62
FIGURA 32 GRÁFICOS DEL ERROR EN LA PREDICCIÓN DEL CONSUMO DE ENERGÍA PARA DISTINTOS MODELOS	63
FIGURA 33 FLUJO DE PROCESO PARA ANÁLISIS DE SENSIBILIDAD CON UNA RED NEURONAL RPROP MLP	65
FIGURA 34 MONITOREO DE TEMPERATURA DE LLENADO, CAUDALES DE BEBIDA Y CONTADORES DE BOTELLA EN LÍNEA 3.	68
FIGURA 35 TEMPERATURA DE LLENADO Y SU RELACIÓN CON EL CONSUMO DE ENERGÍA.	69
FIGURA 36 TABLERO DE COMANDO SOBRE PAROS DE EQUIPOS EN LÍNEA 3 13/03/2019	69
FIGURA 37 CONFIGURACIÓN DE LA NUBE DE TEXTO DEL CAMPO OBSERVACIONES	82
FIGURA 38 NUBE DE TEXTO CON EL TAMAÑO DE TEXTO DESCRIPTO EN EL CAMPO OBSERVACIONES EN FUNCIÓN DE LOS MINUTOS DE PAROS ASOCIADOS.	83

Glosario

BP: Back Propagation.

BPNN: Back Propagation Neural Network.

CRISP-DM: Cross Industry Standard Process for Data Mining.

FEMSA: Fomento Económico Mexicano S.A.B. de C.V.)

KO: The Coca-Cola Company

KOA: Coca-Cola Argentina

KOF: Coca Cola Femsa

KOFAR: Coca-Cola Femsa Argentina

MES: Manufacturing Execution System

MLP: Multi layer perceptron

PMC: Perceptron multi capa.

P.O.P: Point of purchase.

PET: polietileno tereftalato, es una resina plástica derivada del petróleo.

RefPet: Botella de plástico retornable

RGB: Returnable glass bottle

RNA: Red Neuronal Artificial

TCCC: The Coca-Cola Company

USO DE HERRAMIENTAS DE ANÁLISIS DE DATOS PARA REDUCIR EL CONSUMO DE ENERGÍA EN UNA PLANTA DE EMBOTELLADO DE BEBIDAS CARBONATADAS

INTRODUCCIÓN

En el ambiente competitivo actual, el concepto de sustentabilidadⁱ está cobrando vital importancia para los negocios. Ésta abarca diferentes aspectos, entre los que podemos mencionar: el cuidado por los recursos naturales, el impacto medioambiental de las actividades del negocio, la financiación a largo plazo, entre otros.

En particular, en la industria de bebidas el impacto medioambiental está íntimamente ligado con las actividades realizadas por las áreas de Supply Chain. En esta área cobra un nuevo significado el uso racional de los recursos que además pueden generar beneficios económicos con la reducción de costos de producción.

Las plantas embotelladoras de bebidas representan dentro de la industria alimenticia un ejemplo de altos estándares de productividad, automatización y tecnología. Este alto nivel de tecnificación genera durante su funcionamiento una enorme cantidad de datos e información que potencialmente puede ser utilizado para dar valor al negocio, como por ejemplo identificando y priorizando iniciativas para reducir el consumo de energía, que luego se traduzcan en reducción de costos y mejoras en la sustentabilidad del negocio alineado a la vez con las estrategias de sostenibilidad de la empresa.

La presente tesis busca realizar un aporte en esta área, tomando la información disponible sobre los procesos de producción y aplicándole herramientas de análisis de datos, con el objeto de dar soporte a la toma de decisiones y a la gestión para

lograr así la reducción del consumo de energía en una planta embotelladora de Coca Cola Femsa en Argentina.

Buscaremos responder las siguientes preguntas:

¿Es posible utilizar herramientas de Data mining, para aprovechar la gran cantidad de datos disponibles en la industria del embotellado de bebidas, con el fin de detectar oportunidades de ahorro de energía?

¿Las herramientas de data mining permitirán realizar predicciones en los consumos de energía de manera que se pueda realizar un análisis de sensibilidad ante distintas alternativas para elegir la más conveniente o la que tenga mayor impacto?

¿El análisis de data mining puede reemplazar otros modos de calcular o estimar los consumos de energía más engorrosos y complejos?

La metodología utilizada para abordar estas preguntas es del modelo Cross Industry Standard Process for Data Mining (CRISP-DM) de amplia difusión como metodología para llevar adelante análisis con Minería de datos. En primera instancia explicaremos en más detalle en que consiste esta metodología y daremos una breve introducción a conceptos de minería de datos y herramientas estadísticas que utilizaremos en el proceso de análisis de datos. A continuación, se explicará brevemente como es en la actualidad la industria del embotellado de bebidas, los desafíos que presenta y las oportunidades que enfrenta con el gran avance en el manejo de grandes volúmenes de información. En el capítulo 4 se procederá a aplicar la metodología CRISP-DM tomando datos de los procesos y siguiendo por las distintas etapas de análisis. Para el análisis de la información, además de seguir la metodología descrita, se utilizarán distintas herramientas estadísticas y de Data mining buscando dar respuesta a las preguntas de la investigación. Finalmente se cerrará con una conclusión del trabajo realizado.

OBJETIVO GENERAL

Agregar valor a la información disponible de los procesos productivos de una planta embotelladora, mediante el uso de técnicas de la Ciencia de datos para detectar oportunidades para la reducción el consumo de energía disminuyendo el impacto ambiental de la empresa a la vez de aportar a la sustentabilidad del negocio.

OBJETIVOS ESPECÍFICOS

Los objetivos específicos del presente trabajo son:

- Crear un modelo para pronosticar el consumo de energía eléctrica utilizada en la planta de refrigeración en función de las temperaturas de llenado de los productos
- Armar un plan de trabajo priorizado (con foco en quick wins) para incrementar las temperaturas de llenado para reducir el consumo de energía.
- Otorgarle valor agregado a la información con la que se cuenta de los procesos productivos de manera sencilla y práctica.

CUERPO TEORICO

CAPITULO 1: Modelo CRISP-DM

1.1 Introducción

Para llevar adelante el análisis de datos, utilizaremos como referencia el modelo **CRISP-DM** (del inglés **Cross Industry Standard Process for Data Mining**²) se trata de un modelo estándar abierto del proceso que describe los enfoques comunes que utilizan los expertos en minería de datos. Según una encuesta realizada por el sitio <https://www.kdnuggets.com> es la metodología más usada para analítica, minería de datos o proyectos de ciencia de datos.

En la figura 2 se muestran los resultados de la encuesta sobre metodologías usadas para analítica, minería de datos o proyectos de ciencia de datos.³

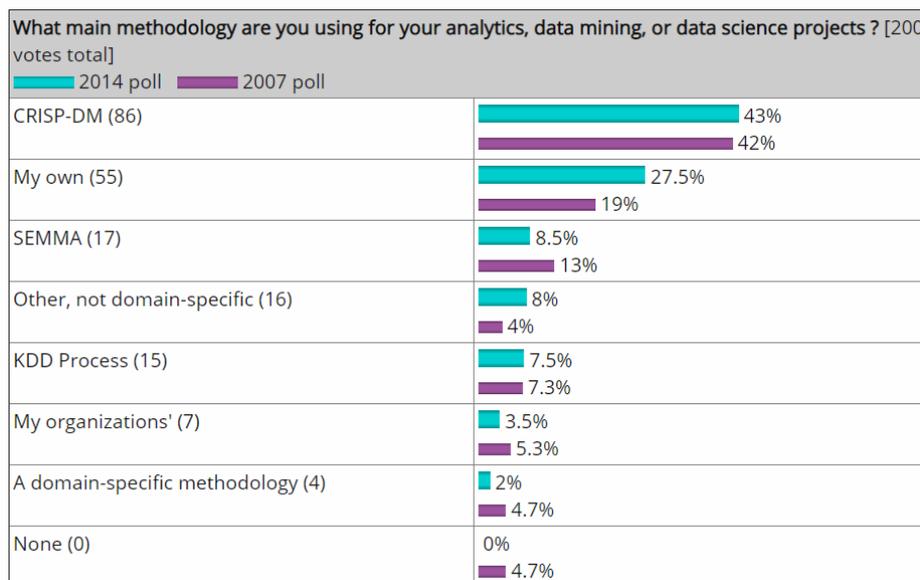


Figura 1: Metodología utilizada para analítica, minería de datos o ciencia de datos 2014 Kdnuggets.

1.2 Modelo Crisp-DM

Este modelo cuenta con 6 fases:^{4 5}

Entendimiento del negocio: Tener un claro entendimiento del problema que se desea resolver, cómo impacta en la organización y los objetivos que se esperan.

Entendimiento de los datos: Inspeccionar, describir y evaluar los datos disponibles.

Preparación de los datos: preparar los datos para que sean aptos para el proceso de análisis.

Modelado: usar técnicas matemáticas para hacer modelos (ecuaciones o funciones lógicas) para soportar las decisiones de negocio.

Evaluación: Evaluar si el modelo es bueno.

Implementación: Integrar el modelo en el día a día del negocio.

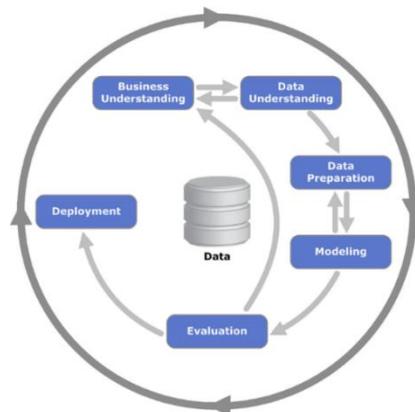


Figura 2: Diagrama del proceso CRISP-DM sobre la relación entre las diferentes fases⁶.

A continuación se describen en detalle cada una de las fases del modelo CRISP-DM⁷

1.2.1 Fase 1: Entendimiento del negocio

En esta Fase se debe realizar una descripción del negocio, comprender la situación actual y realizar un claro entendimiento del problema que se desea

resolver, como así también cómo impacta en la organización y los objetivos que se esperan.

Esta fase cuenta con 4 puntos:

- Determinar los objetivos y criterios de éxito del negocio
- Relevar la situación actual: inventario de recursos disponibles, identificar requerimientos, asunción y restricciones, riesgos y contingencias posibles, y definir los costos y beneficios del proyecto.
- Determinar los objetivos de la minería de datos: definir los objetivos de la minería de datos y los criterios de éxito del proyecto.
- Elaborar un plan para la ejecución del proyecto.

1.2.2 Fase 2: Entendimiento de los datos:

Esta fase cuenta con 4 etapas:

- Recolección inicial de datos.
- Descripción de los datos.
- Exploración de los datos.
- Verificación de la calidad de los datos.

1.2.3 Fase 3: Preparación de los datos

Esta fase cuenta con 4 etapas:

- Selección de datos: consiste en racionalizar datos definiendo cuáles serán incluidos y cuáles excluidos del análisis.
- Construcción de datos: esta etapa incluye la preparación de datos incluyendo operaciones como la producción o derivación de atributos, transformación de valores para atributos existentes, etc. Esta etapa

incluye el pre procesamiento de los datos donde se corrigen 3 tipos de errores comunes: datos incompletos, con ruido e inconsistentes⁸.

- Integración de datos: unir datos de distintas fuentes para su tratamiento.
- Formateo o transformación de datos: dar formato adecuado a los datos. Este proceso incluye tareas de normalización.

1.2.4 Fase 4: Modelado

Esta etapa consiste en:

- Selección de técnicas de modelado
- Diseñar test para los modelos
- Construcción de un modelo: especificar parámetros del modelo y describir el modelo.
- Evaluación del modelo: evaluación del modelo y revisión de parámetros. Una buena selección del modelo se basa en un principio básico denominado “Navaja de Occam” que enuncia: El mejor modelo científico es el modelo más simple que explica los hechos observados⁹. Para el caso de modelos lineales, la navaja de Occam implica el principio de parsimonia: “Un modelo debe tener el menor número de variables necesario para ajustar los datos.”¹⁰

1.2.5 Fase 5: Evaluación

- Evaluar los resultados: aprobar los modelos utilizados y evaluar resultados de la minería de datos.
- Revisión del proceso.
- Determinación de los siguientes pasos: definición de acciones y lista de tareas.

1.2.6 Fase 6: Implementación

- Desarrollo del plan de trabajo
- Mantenimiento y plan de monitoreo.
- Elaboración del reporte final
- Revisión del proyecto: documentar la experiencia adquirida.

CAPÍTULO 2 MINERÍA DE DATOS COMO HERRAMIENTA PARA LA PREDICCIÓN DE DATOS UTILIZANDO TÉCNICAS NO PARAMÉTRICAS

En los últimos años, una enorme cantidad de datos ha inundado casi todos los aspectos de nuestras vidas. Este crecimiento explosivo en la cantidad de datos almacenados o en tránsito han generado una necesidad urgente de técnicas y herramientas automatizadas que puedan ayudar a transformar las enormes cantidades de datos en información útil y conocimiento. Esto ha generado la creación de una nueva disciplina dentro de la informática llamada minería de datos. La minería de datos es el método automatizado o conveniente para la extracción de patrones que representan el conocimiento almacenado o capturado implícitamente en grandes bases de datos, data warehouses, la Web, repositorios de información masivos, o flujos de datos.¹¹

2.1 Tareas básicas de minería de datos.

Mencionaremos algunas de las funciones más comunes de la minería de datos¹²:

- Clasificación

La clasificación asigna los datos a grupos o clases predefinidos. A menudo se le conoce como aprendizaje supervisado, porque las clases se determinan antes de examinar los datos.

- Regresión

La regresión consiste en modelar una función que ajuste de la mejor manera los datos de entrada de una variable, para esta tarea, generalmente se utiliza el criterio de los mínimos cuadrados. La función más utilizada es la lineal, pero también se pueden utilizar otros modelos como la regresión polinómica, logística, etc.

- Análisis de series temporales

Con el análisis de series de tiempo, el valor de un atributo se examina a medida que varía con el tiempo. Los valores generalmente se obtienen como puntos de tiempo espaciados uniformemente (diario, semanal, horario, etc.).

- Predicción

Más que un enfoque de modelado de minería de datos, está orientado a la predicción de valores futuros en función de datos actuales. Este enfoque incluye varios tipos de análisis como el de regresión, clustering, etc.

- Clustering

La agrupación en clústeres es similar a la clasificación, excepto que los grupos no están predefinidos, sino que están definidos únicamente por los datos. La agrupación se denomina también como aprendizaje o segmentación sin supervisión. El agrupamiento generalmente se realiza determinando la similitud entre los datos en atributos predefinidos. Los datos más similares se agrupan en grupos.

- Resumen

Consiste en resumir datos en subconjuntos con descripciones simples asociadas. El resumen también se llama caracterización o generalización. Extrae o deriva información representativa sobre la base de datos. El resumen caracteriza brevemente los contenidos de la base de datos.

- Reglas de asociación

El análisis de reglas de asociación, también conocido como análisis de afinidad o asociación, se refiere a la tarea de extracción de datos para descubrir relaciones entre datos. El mejor ejemplo de este tipo de aplicación es determinar las reglas de asociación. Una regla de asociación es un modelo que identifica tipos específicos de asociaciones de datos. Estas asociaciones se utilizan a menudo en la comunidad de ventas minoristas para identificar artículos que frecuentemente se compran juntos.

- Descubrimiento de secuencia

El análisis secuencial o el descubrimiento de secuencias se utiliza para determinar patrones secuenciales en los datos. Estos patrones se basan en una secuencia temporal de acciones. A diferencia del análisis de una compra en el supermercado, que requiere que los artículos se compren en el mismo tiempo, en el descubrimiento secuencial, los artículos se compran a lo largo del tiempo en algún orden. Por ejemplo, se puede encontrar que la mayoría de las personas que compran reproductores de discos, compran discos en la semana próxima.

Con el objeto de poder priorizar y predecir datos, en el presente trabajo, nos apoyaremos en 2 de estas técnicas que resultan las más apropiadas para este fin: regresión y predicción.

2.2 Técnicas de Data Mining¹³

Podemos clasificar las técnicas más comunes de la minería de datos en 2 tipos:

2.2.1 Paramétricas

Los modelos paramétricos describen la relación entre entrada y salida a través del uso de ecuaciones algebraicas donde no se especifican algunos parámetros. Estos parámetros no especificados se determinan proporcionando como entrada datos de ejemplo. Aunque el modelado paramétrico es útil como modelo teórico, a menudo es demasiado simplista o requiere más conocimiento del disponible sobre los datos involucrados lo que lo hace poco útil para aplicaciones prácticas en el mundo real.

2.2.2 No paramétricas

Las técnicas no paramétricas son más apropiadas para aplicaciones de minería de datos. El modelo no paramétrico está basado en datos. No utiliza ecuaciones explícitas para determinar el modelo. Esto significa que el proceso de modelado se adapta a los datos disponibles. A diferencia del modelado paramétrico, donde se asume un modelo específico de antemano, las técnicas no paramétricas crean un modelo basado en la entrada. Mientras que los métodos paramétricos requieren más conocimiento sobre los datos antes del proceso de modelado, el no paramétrico requiere una gran cantidad de datos como entrada al proceso de modelado en sí. El proceso de modelado luego crea el modelo revisando los datos. Los métodos no paramétricos recientes emplean técnicas de aprendizaje automático para poder aprender dinámicamente a medida que se agregan datos a la entrada. Así, cuantos más datos, mejor será el modelo creado. Este proceso de aprendizaje dinámico permite que el modelo se cree continuamente a medida que ingresan datos a la entrada. Estas características hacen que las técnicas no paramétricas sean particularmente adecuadas para la base de datos y aplicaciones con grandes cantidades de datos que cambian dinámicamente. Ejemplos de técnicas no paramétricas incluyen: árboles de decisión, redes neuronales y algoritmos genéticos.

En función del gran volumen de datos con el que se cuenta, resulta adecuado para nuestro análisis la utilización de técnicas No paramétricas.

2.2.2.1 Árboles de decisión.

“Un árbol de decisión es un árbol donde la raíz y cada nodo está etiquetado con una pregunta. Las ramas que salen de cada nodo representan cada una de las posibles respuestas a la pregunta asociada. Cada nodo de hoja representa una predicción de la solución al problema en consideración.

Un árbol de decisión es un modelo computacional que consiste en de tres partes:

1. Un árbol de decisión
2. Un algoritmo para crear el árbol.
3. Un algoritmo que aplica el árbol a los datos y resuelve el problema bajo consideración.”¹⁴

Por sus características, los arboles de decisión resultan apto para problemas de clasificación, no resultando tan adecuado para problemas de forecasting o de análisis de sensibilidad, por este motivo, no resulta de particular interés para el presente trabajo.

2.2.2.2 Redes neuronales

Las redes neuronales son un campo de la inteligencia artificial (la inteligencia artificial es “la ciencia e ingenio de hacer máquinas inteligentes, especialmente programas de cómputo inteligentes”¹⁵) que crea modelos artificiales que permiten resolver problemas de difícil resolución mediante técnicas algorítmicas convencionales¹⁶. Una RNA (Red Neuronal Artificial) es un modelo matemático inspirado en el comportamiento biológico de las neuronas y la estructura del cerebro animal.¹⁷

Una red neuronal artificial busca simular las propiedades observadas en los sistemas neuronales biológicos a través de modelos matemáticos recreados con mecanismos artificiales, dando respuestas similares a las del cerebro que se caracterizan por su generalización y robustez.

2.2.2.2.1 Estructura de una red neuronal artificial¹⁸

Niveles o capas de neuronas

En una red neuronal la distribución de neuronas se realiza dentro de la red formando niveles o capas con una cantidad de neuronas determinada.

Las neuronas dentro de la red se acomodan en capas pudiéndose distinguir los siguientes tipos de capas:

- De entrada: recibe directamente la información de la fuente externa a la red.
- Ocultas: es una capa interna a la red, no tiene contacto directo con el exterior. El número de capas ocultas puede ser cero o tomar distintos valores. Estas neuronas pueden estar interconectadas de distintas maneras dando lugar a distintas topologías de la red.
- De salida: estas neuronas se encargan de transferir información de la red hacia el exterior.

2.2.2.2 Forma de conexión entre neuronas

La conectividad entre los diversos nodos de una red neuronal se relaciona con la forma en cómo se conecta la salida de una neurona con la entrada de otra/s. La salida de un nodo puede ser la entrada de otro elemento de la red y hasta de sí misma.

En el caso que la salida de una neurona no sea entrada de otra neurona del mismo nivel o precedentes se denomina “de propagación hacia adelante”. Cuando por contrario la salida de las neuronas está conectada con neuronas del mismo nivel o de niveles previos y/o a sí misma, la red se dice que es “de propagación hacia atrás”. Las redes de propagación hacia atrás que cuentan con lazos cerrados se dice que son “sistemas recurrentes”.

2.2.2.3 Características de las redes neuronales.

Las redes neuronales se caracterizan por¹⁹:

- El mecanismo de aprendizaje
- Su topología.

- El tipo de asociación realizada entre la información de entrada y la de salida
- La forma de representación de la información.

2.2.2.2.4 Mecanismos de aprendizaje en una red neuronal.

El aprendizaje consiste en un proceso mediante el cual una red neuronal modifica sus pesos en respuesta a una información de entrada. Un proceso de aprendizaje finaliza cuando los valores de los pesos permanecen estables.

2.2.2.2.4.1 Redes con aprendizaje supervisado

El aprendizaje supervisado se caracteriza por un entrenamiento controlado por un agente externo que determina la respuesta que debería generar la red a partir de una entrada dada. El supervisor verifica la salida de la red, y si esta no coincide con la deseada debe proceder a modificar los pesos de las conexiones para conseguir que la salida se aproxime a la deseada.

En este tipo de aprendizaje hay 3 formas de llevarlo a cabo que pueden ser:

- Aprendizaje por corrección de error: consiste en ajustar los pesos de las conexiones de la red en función del error cometido en la salida. Tres ejemplos de algoritmos con esta forma de aprendizaje son:
 - Regla de aprendizaje de Perceptrón: es la red neuronal más antigua. Es utilizado como identificador de patrones. Tiene algunas limitaciones, como por ejemplo no considerar la magnitud del error global cometido durante el proceso completo y considerar en cambio únicamente los errores individuales. También es incapaz de resolver problemas de la función XOR o de clasificar clases no separables

linealmente. Esta limitación surge porque utiliza un separador lineal como célula de decisión, por lo tanto, no es posible que realice sino una sola separación lineal.

- Perceptrón multicapa (MLP): una manera de superar estas limitaciones del perceptrón simple es incluyendo capas ocultas y obteniendo de esta forma una red neuronal denominada Perceptrón multicapa.²⁰ Este tipo de aprendizaje con una sola capa de neuronas ocultas puede discriminar regiones convexas, en cambio con dos o más capas de neuronas ocultas puede discriminar regiones de forma arbitraria, como puede verse en la figura 4.

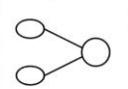
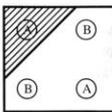
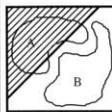
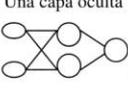
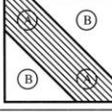
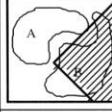
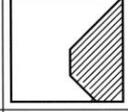
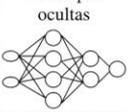
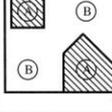
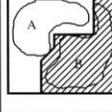
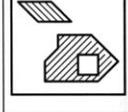
Arquitectura	Región de decisión	Ejemplo 1: XOR	Ejemplo 2: clasificación	Regiones más generales
Sin capa oculta 	Hiperplano (dos regiones)			
Una capa oculta 	Regiones polinomiales convexas			
Dos capas ocultas 	Regiones arbitrarias			

Figura 3: Regiones de decisión obtenidas con el perceptrón simple (arriba), la multicapa con una capa oculta (en medio) y con dos capas ocultas (abajo)⁴⁰

Entre las ventajas de la arquitectura MLP está tener la capacidad de generalización: facilidad para dar salidas satisfactorias a entradas que el sistema no ha visto en su fase de entrenamiento.

Un perceptrón multicapa está compuesto por una capa de entrada, una capa de salida y una o más capas ocultas, como se puede ver en la figura 5:

Simple vs. multilayer perceptron

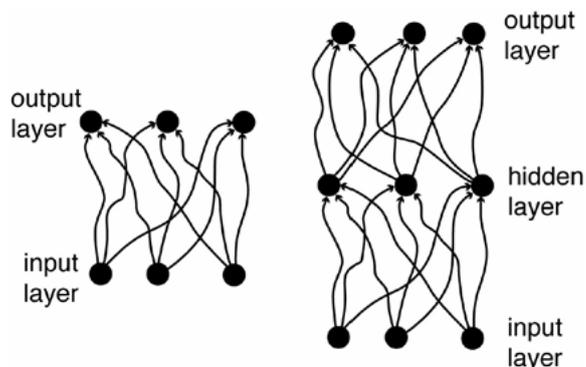


Figura 4: Perceptrón simple y Perceptrón multicapa²¹

Las redes MLP / Neural no hacen suposiciones con respecto a las funciones de densidad de probabilidad subyacentes u otra información probabilística acerca de las clases de patrones bajo consideración en comparación con otros modelos basados en probabilidad²². MLP (Multi-Layer Perceptron) se suele entrenar por medio de un algoritmo de retropropagación de errores o BP (Back Propagation)²³.

Algoritmo de aprendizaje en Retropropagación para Perceptron Milticapa.

“Como el objetivo es que la salida de la red sea lo más próximo posible a la salida deseada, el aprendizaje de la red se formula como un problema de minimización. Como las neuronas de la red están agrupadas en capas, se puede aplicar el método del gradiente, resultando el algoritmo de retro propagación o regla delta.”

“El término retropropagación es debido a la forma en que se implementa en el perceptron multicapa, ya que el error cometido en la salida de la red es propagado hacia atrás y se transforma en un error para cada una de las neuronas ocultas”.²⁴.

Por las ventajas que propone para resolver problemas tanto de clasificación como de generar soluciones no lineales, lo utilizaremos para analizar datos en el capítulo práctico.

- DDA (Dynamic Decay Adjustment)²⁵, es una mejora del algoritmo RCE (Restricted Coulomb Energía).²⁶ Es un clasificador desarrollado en 1974 por Batchelor. Este clasificador tiene mejoras en la capacidad de clasificación sin cambios significativos en el costo computacional. En comparación, una red con este clasificador puede tener una certeza del 93% comparado con una red neuronal multicapa feed-forward de alimentación directa que obtendría 88,4% con los mismos datos⁴⁴.
- Aprendizaje por refuerzo: Es más lento que el anterior, se caracteriza en no disponer de un ejemplo completo del comportamiento deseado y se reduce a indicar mediante una señal de refuerzo si la salida obtenida es la deseada. Un ejemplo de este tipo de algoritmos es el LR-P (lineal de recompensa y penalización).
- Aprendizaje estocástico: consiste en realizar cambios aleatorios en los pesos de las conexiones de la red y evalúa su efecto a partir del objetivo deseado y de distribución de probabilidades.

2.2.2.2.4.2 Redes con aprendizaje no supervisado

Este tipo de redes no necesitan influencia externa para ajustar los pesos de las conexiones entre neuronas. La red no recibe información por parte del entorno que le indique si la salida generada en respuesta a una determinada entrada es correcta o no. Estas redes deben encontrar las características, regularidades, o categorías que se puedan determinar entre los datos de entrada. Como no existe un supervisor que indique la respuesta esperada, existen varias posibilidades respecto a la interpretación de la salida que depende de su estructura y del algoritmo de aprendizaje utilizado.²⁷

2.2.2.2.4.3 Aprendizaje Hebbiano

El aprendizaje Hebbiano consiste en el ajuste de los pesos de las conexiones de acuerdo a las correlaciones de los valores de activación de las dos neuronas conectadas.

2.2.2.2.4.4 Aprendizaje competitivo y cooperativo

En esta red las neuronas compiten unas con otras para llevar a cabo una tarea dada buscando que cuando se presente a la red cierta información de entrada, solo se active una de las neuronas de salida de la red. El objetivo que se busca es categorizar (clusterizar) los datos que se introducen en la red. Así se logra que las informaciones similares sean clasificadas formando parte de la misma categoría y, por lo tanto, deben activar la misma neurona de salida. Las categorías deben ser creadas por la misma red (es un aprendizaje no supervisado) a través de las correlaciones entre los datos de entrada.

2.2.2.2.5 ALGORITMOS DE REDES NEURONALES

A continuación, nombraremos algunos tipos de algoritmos utilizados en redes neuronales

A) Algoritmo Back Propagation

Es un algoritmo de descenso de gradiente en el que los pesos de la red se mueven a lo largo del gradiente negativo de la función de rendimiento.

Para calcular la neurona de entrada, a cada entrada conectada a la neurona se la debe multiplicar por su peso para formar una suma ponderada que se agrega al sesgo asociado con la neurona.

B) Algoritmo de Gradiente Conjugado

Este algoritmo actualiza los pesos a lo largo de la dirección del conjugado y produce convergencia generalmente de manera más rápida que la del descenso más pronunciado en el algoritmo BPNN. En este algoritmo, el tamaño del paso se puede ajustar para cada iteración.

C) Algoritmo RProp

Este algoritmo proporciona un tiempo de entrenamiento y una tasa de convergencia más rápidos y tiene la capacidad de escapar de los mínimos locales. RProp es un algoritmo de primer orden y su tiempo y memoria requeridos son proporcionales al número de parámetros a optimizar.

D) LM Algoritmo

Este algoritmo tiene una rápida convergencia y entrena una red neuronal 10–100 veces más rápida que la BPNN. El algoritmo LM proporciona un buen compromiso entre la velocidad de Gauss-Newton y la convergencia garantizada de los métodos de descenso más pronunciados.

2.2.2.3 Algoritmos genéticos

Los algoritmos genéticos son métodos de computación evolutivos y utilizan algoritmos de tipo de optimización. Dada una población de posibles soluciones, la computación evolutiva expande esta población con nuevas y potencialmente mejores soluciones. Están inspirados en la evolución biológica, donde, con el tiempo, se produce individuos mejores o "más aptos", de la misma manera, esta técnica, busca encontrar los modelos "más aptos" de un conjunto de modelos para representar los datos²⁸.

2.3 Data Mining de texto

“La cantidad de texto que se genera cada día está aumentando dramáticamente. Este tremendo volumen de texto, en su mayoría no estructurado, no puede ser simplemente capturado y procesado por las

computadoras. Por lo tanto, se requieren técnicas y algoritmos eficientes y efectivos para descubrir patrones útiles. La minería de textos es, por lo tanto, la tarea de extraer información significativa de textos.”²⁹

2.4 Herramientas estadísticas

A continuación, mencionaremos algunos conceptos estadísticos que utilizaremos en el análisis con minería de datos:

2.4.1 Descriptores estadísticos:

Algunos de los descriptores estadísticos que utilizaremos son:

Mínimo: el menor valor de una muestra de datos numéricos.

Máximo: el mayor valor de una muestra de datos numéricos.

Promedio: es la suma de los valores de la muestra dividido por la cantidad de datos.

$$\bar{x} \equiv \frac{1}{N} \sum_{i=1}^N x_i.$$

Desviación estándar: es una cantidad que representa la dispersión de una muestra. A mayor desviación estándar, mayor dispersión de la población. La desviación estándar es un promedio de las desviaciones individuales de cada observación con respecto a la media de una distribución. La fórmula para su cálculo es:

$$\sigma = \sqrt{(\sum x^2)/N}$$

“donde $\sum x^2$ representa la suma de las diferencias elevada al cuadrado entre cada observación y la media, y N representa el número total de observaciones.”³¹

2.4.2 Análisis de Regresión

Un análisis de regresión consiste en generar una ecuación para describir la relación estadística existente entre uno o más predictores y la variable de respuesta, y además permite predecir nuevas observaciones³².

Existen distintos tipos de regresiones³³:

- Tipos de regresiones según el número de variables independientes:

Regresión simple: Cuando la variable Y depende únicamente de una variable X.

Regresión múltiple: Cuando la variable Y depende de varias variables (X_1, X_2, \dots, X_r). Los modelos de regresión múltiple pueden ser lineales o no. Un caso que se utiliza con frecuencia en la práctica es el modelo de regresión polinomial, en el cual las variables independientes son potencia de una sola variable.

- Tipos de regresiones según el tipo de función $f(X)$:

Regresión lineal: Cuando $f(X)$ es una función lineal. Para su cálculo generalmente se utiliza el método de estimación de mínimos cuadrados ordinarios, que consiste en obtener la ecuación de una línea recta que permita minimizar la suma de los residuos al cuadrado.

Regresión no lineal: Cuando $f(X)$ no es una función lineal.

2.4.2.1 Estimación de los coeficientes en una regresión³⁴

En cualquier modelo de regresión lineal o múltiple, los coeficientes de la ecuación se calculan por medio de mínimos cuadrados.

2.4.3 Normalización (estadística)

La normalización implica la creación de versiones cambiadas y escaladas de estadísticas donde se busca que los valores normalizados permitan la comparación con conjuntos de datos, de manera que elimina los efectos de influencias³⁵.

La normalización puede mejorar la precisión y eficiencia de la minería con algoritmos que implique medidas de distancias.³⁶

Existen varias clases de normalizaciones; mencionaremos cinco:

Puntuación estándar: Normaliza errores cuando los parámetros de población son conocidos. Funciona bien para poblaciones que están normalmente distribuidas.

T de Student: Normalización residual cuando los parámetros de población son desconocidos.

Momento estandarizado: Normalización de momentos utilizando la desviación estándar como una medida de escala.

Coefficiente de Variación: Normalización de la dispersión utilizando la media como medida de escala. Se utiliza en distribución positiva como la distribución exponencial y distribución de Poisson.

Característica scaling o normalización Min-Max: Es la más utilizada, consiste en una transformación lineal de los datos originales³⁷ ajustando todos los valores a un nuevo rango (p.e. [0,1]). La normalización permite preservar la relación entre los valores originales de los datos. Al establecer los límites debe tenerse presente que si a futuro se agregará un valor fuera del límite, éste generaría en error en el modelo.

2.4.4 Coeficientes de correlación

El coeficiente de correlación (r) es una medida numérica de la fuerza de la relación lineal entre dos variables³⁸. El valor numérico está comprendido entre 1,0 y -1,0³⁹ y nos indica la fuerza de la relación, pero no implica por sí misma ninguna relación de causalidad⁴⁰.

En general, $r > 0$ indica una relación positiva, $r < 0$ indica una relación negativa, $r = 0$ indica que no hay relación (o que las variables son independientes y no están relacionadas). $r = 1,0$ indica una correlación positiva perfecta y $r = -1,0$ una correlación negativa perfecta.

Mientras mayor sea el valor absoluto de los coeficientes, mayor será la fuerza de la relación entre las variables.⁴¹

Las siguientes directrices sobre la fuerza de la relación son útiles como referencia, aunque este criterio puede cambiar dependiendo del autor.

Valor / fuerza de relación:

-1,0 a -0,5 o 1,0 a 0,5: relación fuerte

-0,5 A -0,3 o 0,3 a 0,5: relación moderada

-0,3 A -0,1 o 0,1 a 0,3: relación débil

-0,1 A 0,1: relación débil o nula

Existen diversos coeficientes que miden el grado de correlación. Los más utilizados son:

Coeficiente de correlación de Pearson (se obtiene dividiendo la covarianza de dos variables entre el producto de sus desviaciones estándar), coeficiente de correlación de Spearman y correlación canónica.

2.4.4.1 Coeficiente de correlación de Pearson⁴²

Es una medida lineal entre dos variables aleatorias cuantitativas. La correlación de Pearson es independiente de la escala de medida de las variables.

El coeficiente de correlación de Pearson puede definirse como un índice que puede utilizarse para medir el grado de relación de dos variables siempre y cuando ambas sean cuantitativas y continuas.

2.4.4.2 Coeficiente de correlación de Spearman, ρ (rho)

Es una medida de la correlación (la asociación o interdependencia) entre dos variables aleatorias (tanto continuas como discretas). Para calcular ρ , los datos son ordenados y reemplazados por su respectivo orden.

El estadístico ρ viene dado por la expresión:

$$\rho = 1 - \frac{6 \sum D^2}{N(N^2 - 1)}$$

donde D es la diferencia entre los correspondientes estadísticos de orden de x - y. N es el número de parejas de datos.

La interpretación de coeficiente de Spearman es igual que la del coeficiente de correlación de Pearson. Oscila entre -1 y +1, indicándonos asociaciones negativas o positivas respectivamente, 0 cero, significa no correlación, pero no independencia.⁴³

2.4.4.3 Correlación canónica

“Es un método de análisis multivariante desarrollado por Harold Hotelling. Su objetivo es buscar las relaciones que pueda haber entre dos grupos de variables y la validez de las mismas.”⁴⁴

CUERPO EMPIRICO

CAPÍTULO 3: PRESENTACIÓN GENERAL DE LA EMPRESA

3.1 Coca Cola FEMSA

Coca-Cola FEMSA es el embotellador más grande del sistema Coca-Cola en el mundo. En México embotella las marcas de The Coca-Cola Company en el centro y sur del país, y es una filial de FEMSA.

FEMSA (Fomento Económico Mexicano S.A.B. de C.V.) es una empresa multinacional mexicana fundada en el año 1890 con sede en Monterrey, Nuevo León, México, y opera en 10 países de Latinoamérica, incluida Argentina. También cuenta con operaciones en Asia (Filipinas)⁴⁵.

Las diferentes filiales (Coca-Cola FEMSA, Femsa Comercio, Femsa empaques, Femsa logística) trabajan en sectores tan diversos como: refrescos, jugos, cerveza, tiendas de conveniencia, farmacias, logística, estaciones de servicio y restaurantes de comida rápida. Sus ingresos anuales son de US\$ 21.200 millones (2016) con un beneficio neto de US\$ 1.500 millones (2016). Cuenta con activos por US\$25.503 millones (2014). En 2013, fue la quinta compañía más grande de México por sus ventas, de acuerdo la revista Expansión. La empresa cuenta con 170.000 empleados.

3.2 El sistema Coca Cola⁴⁶

Para operar en los distintos países del mundo, The Coca-Cola Company (KO) desarrolló el Sistema Coca Cola, que cuenta con más de 250 socios embotelladores locales que operan la franquicia. En este esquema, The Coca Cola Company (TCCC) tiene el siguiente rol:

- Producción y venta de concentrados, bases para bebidas y jarabes en cada país a las embotelladoras.

- Es dueña de las marcas y responsable de las iniciativas de mercadeo de la marca para los consumidores (Marketing estratégico).
- Define los criterios, estándares de trabajo y normas que deben cumplir los embotelladores

El rol que cumplen las embotelladoras incluye:

- Licencia para el uso de la marca.
- Fabricación, empaque, comercialización y distribución de bebidas a clientes y distribuidores, que luego venden los productos a los consumidores.
- Aseguran las normas de calidad del producto.
- Realizan el marketing operativo y material P.O.P.

3.2.1 Sistema Coca-Cola en Argentina

El Sistema Coca-Cola está integrado en el país por Servicios y Productos para Bebidas Refrescantes S.R.L. (donde se producen los jarabes y concentrados) y sus socios embotelladores son: Reginald Lee, Femsa, Arca Continental y Andina. Atienden a más de 363.000 clientes en el país de los cuales el 80% son pequeños comerciantes: kioscos, almacenes y autoservicios.

En Argentina se cuenta con 10 Plantas productivas (9 de embotellado y 1 de concentrados).

En la Argentina, la marca ofrece 80 opciones de productos. Entre estas opciones, se encuentran gaseosas con bajas calorías y sin calorías, aguas y aguas saborizadas, jugos, bebidas deportivas, con vitaminas, y bebidas con té.

3.3 Coca Cola Femsa Argentina (KOFAR)

Embotella, produce, comercializa y distribuye los productos de TCCC. Cuenta actualmente con⁴⁷:

2 Plantas de producción: Alcorta y Monte Grande, donde se envasan:

Bebidas carbonatadas, aguas mineralizadas Plain con y sin gas (Kin),

aguas saborizadas (Aquarius).

4 Centros de distribución

3.3.1 Planta Alcorta

Planta Alcorta está ubicada en Nueva Pompeya sobre la calle Amancio Alcorta. En esta planta se producen productos en botellas retornables y no retornables, bidones y Bag in box (utilizados en dispensers de bebida).

En planta Alcorta hay 9 líneas de embotellado, como se detallan en la siguiente tabla:

Tabla 1 Detalle de líneas de embotellado de Planta Alcorta (2018).

Línea	Tecnog.	Capacidad bph	SKUs	Fabricante	Modelo llenadora	Año Fabric	Tipo de llenadora	N° de válvulas
1	RGB	30.000	RGB 0,35 y 1,25lts	H & K	Delta	1988	Isobárica	156
2	PET	36.000	PET 0,25-0,41-0,5-0,6 y 1,5lts	Simonazzi	Eurostar 2000	1995	Isobárica	120
3	REF-PET	27.000	REF-PET 2,0 lts	KHS	Innofill	2014	Isobárica	128
4	PET	24.000	PET 0,6-1,5-2,25 y 2,5lts	KHS	Innofill	2006	Volumétrica	136
5	REF-PET/RGB	20.400	REF-PET 2,0lts RGB 1,25lts	San Martin	O+H 132/14	1992	Isobárica	132
6	PET	26.400	PET 1,5-2,0-2,25 y 2,5lts	Krones	Mecafill	1997	Volumétrica	126
7	BIDONES	3.000	6,0lts	Sacmi	Sacmi	2017	Isobárica	6
8	PET	36.000	PET 0,5-0,6-1,5-2,25-2,5 y 3,0lts	Krones	TK 5760 VODM	2010	Volumétrica	128
9	PET	72.000	PET 0,2-0,25-0,5-0,6 y 1,5lts	KHS	Innofill	2012	Volumétrica	180

Nota: Resumen de información técnica de líneas de embotellado de Planta Alcorta. Ref-Pet: Botella de plástico retornable. RGB: Returnable glass bottle / botella de vidrio retornable, PET: botella de PET. bph: botellas por hora, es la capacidad de llenado horaria de botellas de la llenadora. En una misma llenadora el fabricante define para cada tamaño de botella una velocidad máxima de trabajo. En la tabla se consigna la velocidad máxima de trabajo, por lo cual es posible que en algún formato en particular la velocidad sea menor a la indicada.

3.4 PROCESO DE EMBOTELLADO DE BEBIDAS CARBONATADAS

El proceso de producción de una bebida carbonatada cuenta con distintas etapas, a saber:⁴⁸

3.4.1 Preparación de los ingredientes

La fabricación comienza con las materias primas:

- Jarabe concentrado: provisto por TCCC.
- Agua: además de ser potable, debe cumplir una serie de especificaciones para asegurar la estabilidad, vida y calidad del producto. Para eso es tratada en un tratamiento multibarrera y así logra cumplir los requerimientos de la Organización Mundial de la Salud, legislaciones locales y nacionales y los estándares establecidos por The Coca-Cola Company para garantizar el máximo nivel de calidad. Todas las fases del tratamiento son monitoreadas por rigurosos controles de calidad.
- Azúcar: atraviesa un proceso de purificación donde se mezcla con agua en cantidades adecuadas en función de la fórmula, obteniendo así el llamado jarabe simple, que luego es pasteurizado y filtrado a fin de eliminar cualquier impureza o contaminación microbiológica.
- Dióxido de carbono.

3.4.2 Formulación del jarabe terminado

En la Sala de Jarabe –también conocida como Sala de Elaboración– se efectúa la mezcla del concentrado, del agua y del jarabe simple para dar lugar al jarabe terminado, que luego se utiliza para la preparación final de la bebida.

3.4.3 Agregado de gas carbónico

El Agua Tratada y el Jarabe Terminado se dosifican en proporciones adecuadas en un proceso que puede ser tipo batch o en un proceso continuo (en línea). Luego pasa por un desaireador para eliminar los restos de aire que puedan quedar en la bebida y de esa forma facilitar el proceso posterior de carbonatación.

La bebida sin gas (agua-jarabe) es impulsada por una bomba al carbonatador, donde obtiene la carbonatación final. El proceso de carbonatación puede realizarse en un proceso tipo batch o en un proceso continuo.

En este punto la bebida es considerada Bebida Terminada y es enviada directamente a la llenadora

3.4.4 Envasado y codificado

La bebida terminada se coloca en las botellas y se tapa. Luego se codifica para permitir la trazabilidad del producto desde su etapa de materias primas hasta su entrega en el punto de venta.

3.4.4.1 Proceso de llenado

El proceso de llenado de bebidas carbonatadas se realiza en máquinas llamadas Llenadoras. Estos equipos utilizan principalmente dos tecnologías: llenado Isobárico y llenado volumétrico.

Llenadoras Isobáricas:

En este tipo de equipos el llenado se realiza mediante un mecanismo (válvula de llenado) que permite que el líquido complete el nivel de la botella hasta llegar al pico que tiene la válvula. Cuando la botella ingresa a la llenadora, es colocada en la válvula de llenado que presuriza y conecta la botella con el tanque de la máquina. Una vez igualadas las presiones, el llenado se produce por gravedad hasta llegar al nivel del pico. Ya completado el llenado, se realiza el alivio de la botella despresurizándola como paso previo a desconectarla de la válvula y pasar a la capsuladora donde se le coloca la tapa. Esta tecnología tiene la desventaja que requiere mantenimiento de las partes mecánicas de la válvula y el volumen de llenado es afectado por variaciones de las dimensiones de las botellas.

Llenadoras volumétricas:

A diferencia de la anterior, en esta tecnología de llenado la cantidad de bebida introducida en la botella es medida por un caudalímetro másico, lo que garantiza que la cantidad de producto llenado sea muy preciso (+ - 0,2/0,5%). Estas llenadoras tienen menos partes móviles y la bebida sufre menos agitación durante el proceso de llenado.⁴⁹

3.4.4.1.1 Espumado:

En una bebida carbonatada el envasado de la bebida se hace a baja temperatura y alta presión para que el líquido contenga la mayor cantidad posible de gas disuelto (según la ley de Henry, la disolución de gases en líquido aumenta con la presión y con el descenso de temperatura). En el caso de la presión, al comprimir un gas hacemos que las moléculas estén más juntas aumentando los choques entre las moléculas, lo que produce un aumento en la disolución. De esa manera, para cada temperatura y presión se consigue un equilibrio entre el gas que hay encima del líquido y el gas disuelto en él.⁵⁰ Al

finalizar el proceso de llenado, las botellas se tienen que despresurizan para poder salir de la máquina. Al reducirse la presión, se reduce la solubilidad de los gases en líquido, lo que puede romper el equilibrio y provocar un desprendimiento acelerado del CO₂ disuelto en la bebida denominado Espumado. Cuando esto ocurre, sale de manera abrupta gas y líquido de la botella, haciendo que el contenido neto quede por debajo del contenido declarado en la etiqueta y que la botella tenga que descartarse con la consecuente pérdida para la empresa (de bebida, botella, tapa, etc).

Entre las causas más comunes que pueden provocar el espumado se encuentran:

- Rampa acelerada de despresurización de las botellas.
- Agitación excesiva de la bebida.
- Fallas en el proceso de carbonatación.
- Alta temperatura de llenado.

De estos factores, normalmente el último es el que se utiliza para compensar fallas en los otros. O sea que si hay espumado, una práctica habitual sería uele reducir la temperatura de llenado, aumentando la demanda de frío y, consecuentemente, incrementando el consumo de energía del proceso de embotellado. En estos casos lo que se recomienda hacer es: revisar por completo los equipos y el proceso de llenado para identificar las posibles causas que provocan la aparición del espumado durante el proceso de llenado.

3.4.5 Encajonado/empacado y palletizado

Las botellas retornables se colocan en cajones mientras que las no retornables se acomodan en packs de termocontraíbles. En ambos casos luego se palletizan dejándolas listas para almacenar en la bodega.

3.4.6 Distribución

Los pallets se acomodan en el Área de Bodega para luego ser cargadas en camiones hacia diferentes destinos. ⁵¹

3.5 Consumo de energía en una planta de embotellado

3.5.1 Distribución de consumo por sectores

En nuestro caso analizaremos el consumo de energía de Planta Alcorta de Coca Cola Femsa.

Como es sabido, las plantas de producción de bebidas consumen energía eléctrica y térmica para los distintos procesos productivos.

En la figura 1 podemos observar para Planta Alcorta cómo está distribuido el consumo de energía en los distintos sectores o áreas productivas.

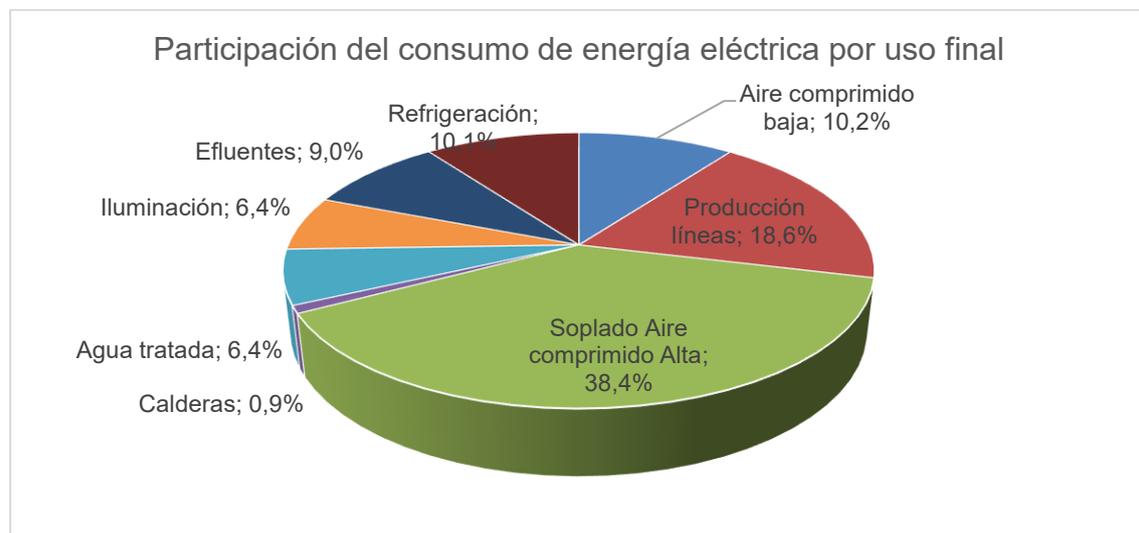


Figura 5: Participación del consumo de energía eléctrica por uso final en Planta Alcorta. Antea Group (2015).

Para nuestro análisis sobre la búsqueda de oportunidades de ahorro de energía, resulta de particular interés el estudio del consumo de energía en Refrigeración porque es un sector que cuenta con datos de medidores del

consumo de energía y variables del proceso. Este consumo de energía en refrigeración representa el 10,1% del total de la planta y se utiliza para enfriamiento de la bebida para el proceso de llenado.

La planta cuenta con un ciclo frigorífico que utiliza amoníaco como fluido refrigerante, que a su vez enfría glicol. El glicol en un circuito secundario enfría la bebida en las llenadoras.

Las líneas de producto carbonatado cuentan con enfriamiento de bebida para el proceso de llenado (Líneas 1, 2, 3, 4, 5, 6, 8 y 9). Al reducirse la temperatura de la bebida se mejora la disolución del gas líquido (ley de Henry), lo que reduce o elimina problemas de espumado mejorando la uniformidad del contenido neto de las botellas. Mientras más baja sea la temperatura de llenado, mayor será el consumo de energía para enfriar la bebida. Por este motivo es clave que el proceso trabaje en óptimas condiciones para que consuma la menor cantidad de energía posible.

3.5.2 Estrategia de sostenibilidad

Coca Cola Femsa tiene una estrategia de sostenibilidad para el 2020 basada en 3 pilares:

Nuestra Comunidad

Nuestro Planeta

Nuestra Gente

El pilar Planeta tiene 3 ejes de trabajo:

Agua

Residuos y Reciclaje

Energía

En el eje de trabajo de Energía hay un compromiso de reducción del 20% de la huella de carbono respecto del año 2010.

3.5.3 Guía para ahorro de energía

Coca Cola Femsa cuenta con una guía para reducción de consumo de recursos compilada en un documento denominado White Book. Para el caso del consumo de energía se definen 20 puntos de trabajo. El punto N° 15 trata sobre “Sistemas de enfriamiento centralizado e incremento de las temperaturas de llenado”. En el paso N°3 de este punto se recomienda preparar un programa para incrementar las temperaturas de llenado.

3.5.4 MES (Manufacturing Execution System)

En la industria alimentaria y en particular la de bebidas de consumo masivo en la actualidad es una industria que se encuentra con altos niveles de automatización debido a sus resultados de costos y productividad, entre otros factores. Por ello, es común encontrar en las plantas un alto nivel de instrumentación, equipos de medición, control y automatización, diversidad de sensores y redes de comunicación industriales⁵².

Generalmente estos equipos son de diferentes fabricantes con diferentes tecnologías, por lo cual también existen oportunidades para interconectar los sistemas y dar un mayor valor agregado a la información con la que se cuenta sobre los procesos productivos. En virtud de esta necesidad es que ha surgido el concepto de MES (Manufacturing Execution System en inglés) que consiste en un software enfocado al Control de la Producción, que monitorea y documenta la gestión de una planta⁵³.

3.5.4.1 MES Planta Alcorta

Planta Alcorta cuenta con un sistema de adquisición de datos de variables de proceso de producción (MES). En este sistema se cuenta con información minuto a minuto proveniente de diferentes sensores e instrumentos de medición concentrada en un unico sistema. Utilizaremos la información proveniente del MES para analizar las temperaturas de llenado y asi lograr definir un plan de trabajo para incrementar las temperaturas de llenado y reducir el consumo de energí, en concordancia con lo recomendado en el punto N°15 del White Book sobre ahorro de energí.

CAPITULO 4: ANÁLISIS DE DATOS PARA REDUCCIÓN DEL CONSUMO DE ENERGÍA EN UNA PLANTA DE EMBOTELLADO

4.1 Metodología para el análisis de datos.

A continuación, realizaremos un análisis de datos en una planta de embotellado para reducir el consumo de energía tomando como referencia la metodología CRISP-DM.

4.1.1 Fase 1: Entendimiento del negocio.

4.1.1.1 Relevamiento de la situación actual:

Adicionalmente a la información presentada en el capítulo 3, se comentan los siguientes puntos:

- Impacto en los costos del consumo de energía:

El consumo de energía está catalogado como un gasto fijo y representa un 10,7% del costo fijo de la planta (2018). Como se indicó en el capítulo 3, dentro de ese consumo de energía, la planta frigorífica representa el 10,1% del consumo, por lo que su impacto en el total de los costos fijos es de aproximadamente el 1% del costo total fijo.

Con relación al consumo de energía por refrigeración, como se indicó en el capítulo 3, el consumo de energía de la planta frigorífica está en relación directa con la temperatura de llenado de la bebida.

Respecto a la temperatura de llenado, del relevamiento de la situación actual se identifica que no existe un programa o proceso dentro de la gestión que defina y controle las temperaturas de llenado de las líneas de embotellado. Estas temperaturas están cargadas en las recetas de cada línea, pero no existe un criterio documentado para definir dichas temperaturas ni tampoco reglas de decisión para actuar ante desviaciones respecto de los parámetros de temperatura definidos.

Se pudo relevar que durante el proceso de llenado es común que el operador del equipo ajuste el setpoint de temperatura y defina un nuevo valor (generalmente hacia abajo) dependiendo del funcionamiento de la llenadora. Las desventajas que genera esta forma de trabajo es que la temperatura de llenado generalmente termina por debajo de los 4°C consumiéndose más energía de la necesaria en el proceso de embotellado y encareciendo los costos de producción.

Si se deseara poder realizar el cálculo del consumo de energía de una planta de refrigeración en función de la demanda de frío, existen métodos teóricos que son complejos y necesitan ser llevados adelante por especialistas en procesos industriales de refrigeración. Así y todo, los modelos que se pueden generar son limitados y requieren de una gran cantidad de datos que no siempre se encuentran disponibles, lo que lleva a hacer suposiciones que incrementan los errores y pueden llevar a sobre valorar o sub valorar oportunidades de mejora. Por este motivo intentaremos buscar maneras alternativas de simular el consumo de energía en la planta de refrigeración en función de la demanda.

Existen datos disponibles de consumos de energía y variables de proceso de la planta de refrigeración que actualmente no se están utilizando y que podrían servir para generar un modelo predictivo del análisis del consumo de energía que nos permita cuantificar el impacto de la modificación de las temperaturas de trabajo.

En paralelo, del relevamiento se pudo detectar que existen gaps en lo referente al soporte con información para la toma de decisiones relacionadas al proceso de refrigeración y las temperaturas de llenado.

- Temperatura de llenado

Los fabricantes de llenadoras de productos carbonatados definen para cada modelo de llenadora la temperatura a la que podrán llenar cada producto en función de su diseño. Estas temperaturas son reflejadas en el manual de cada equipo donde se detallan las temperaturas de trabajo asociadas a cada producto. En el momento de la puesta en marcha inicial de los equipos, estas temperaturas se configuran en recetas que quedan cargadas en la memoria de los PLCs de los preparadores.

En la figura N° 6 se muestran las especificaciones técnicas de la llenadora instalada en la línea 8 marca Krones, tipo volumétrica, Modelo: VOLUMETIC VODM-PET 5.760-128-141, K136628.

Lista de objetos de cliente	
Bien a llenar	1
Grupo de producto a llenar	Refrescos carbonatados
Técnica de llenado	estándar
Temperatura de llenado (° C)	12 °C
CO2 (g/l)	8,5 g/l

Figura 6 Especificaciones técnicas llenadora VOLUMETIC VODM-PET 5.760-128-141, K136628

En la figura N°7 se muestran las especificaciones técnicas de Llenadora línea 9, marca KHS, tipo volumétrica, modelo: Innofill DRV PET180/36SC 36pi

<u>Filling product</u>						
No.	Description	Filling procedure	CO2 content max. (g/l)	Temperatur e min. (°C)	Temperatur e max. (°C)	Comment
1	Coca-Cola	Coca Cola	8.50		15.00	
2	Aquarius	Aquarius	0.00			Filling at ambient temperature
3	Coca-Cola Light	Coca Cola Light	8.50	10.00	12.00	
4	Sprite	Sprite	8.50		15.00	
5	Sprite Zero	Sprite Zero	8.50	10.00	12.00	
6	Coca-Cola Zero	Coca Cola Zero	8.00	10.00	12.00	

Figura 7: Especificaciones de temperaturas de llenado de llenadora Innofill DVR-PET 180/36SC 36pi

No se encuentran disponibles los manuales del resto de las llenadoras.

- Relevamiento de registros históricos de temperaturas de llenado

Se hizo un relevamiento de los registros horarios de temperaturas de llenado en las distintas líneas de producción para tener una línea de base de trabajo (alineada a las normas ISO 50.001) y con dicha información se realizaron histogramas con las distribuciones de frecuencia de las temperaturas de llenado.

Las líneas involucradas en la medición fueron: 2, 3, 4, y 9. No se contó con los registros de las líneas 1, 5, 6 y 8 por fallas en el registro de la información.

En las figuras siguientes se detallan los histogramas obtenidos del relevamiento de datos de abril 2018:

Línea 2: temperatura promedio de llenado: 6 grados centígrados:

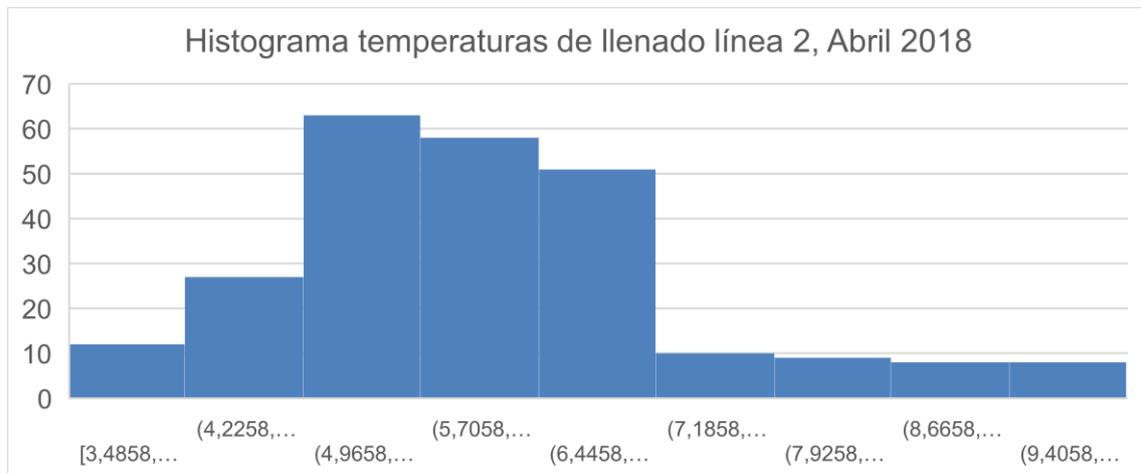


Figura 8: Histograma de temperaturas de llenado en línea 2. Planta Alcorta. Abril 2018.

Línea 3: temperatura promedio de llenado: 5,6 °C.

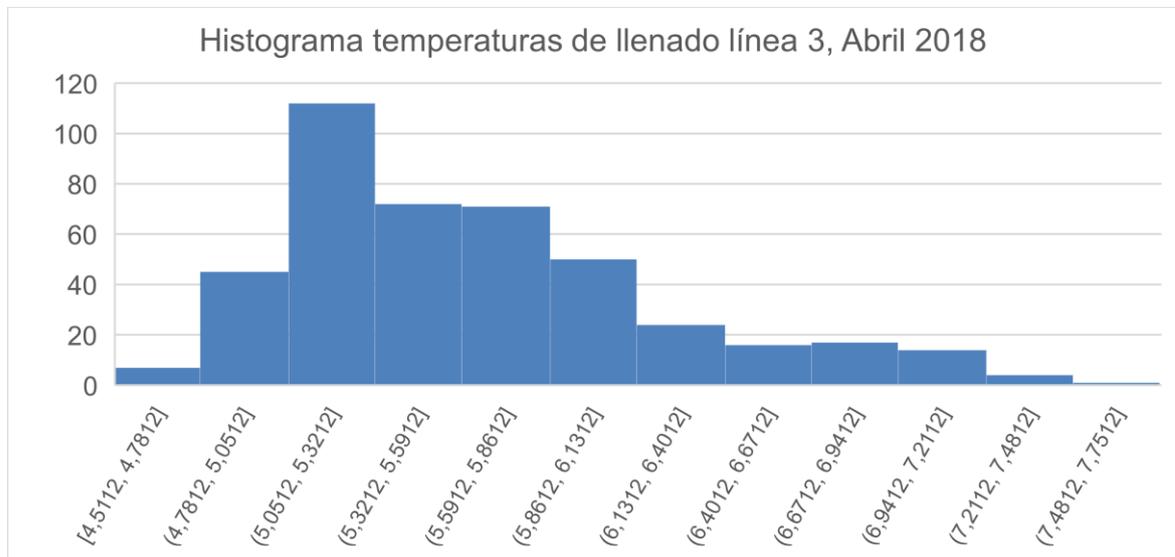


Figura 9: Histograma de temperaturas de llenado en línea 3. Planta Alcorta. Abril 2018

Línea 4: temperatura promedio de llenado: 6,4 °C.

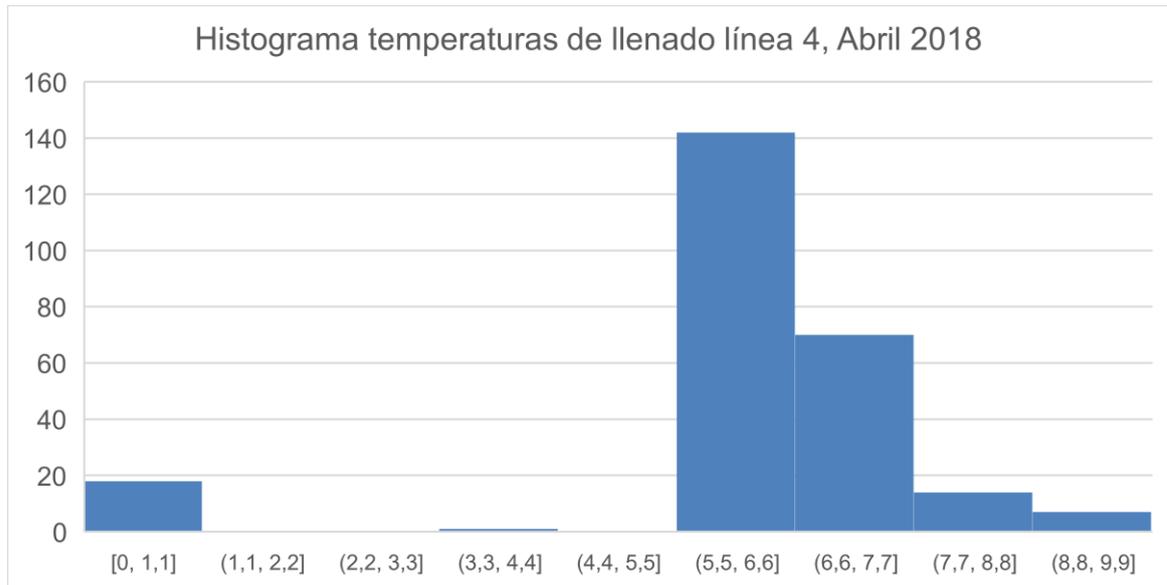


Figura 10 Histograma de temperaturas de llenado en línea 4, Planta Alcorta. Abril 2018

Línea 9: temperatura promedio de llenado: 7,6 °C.

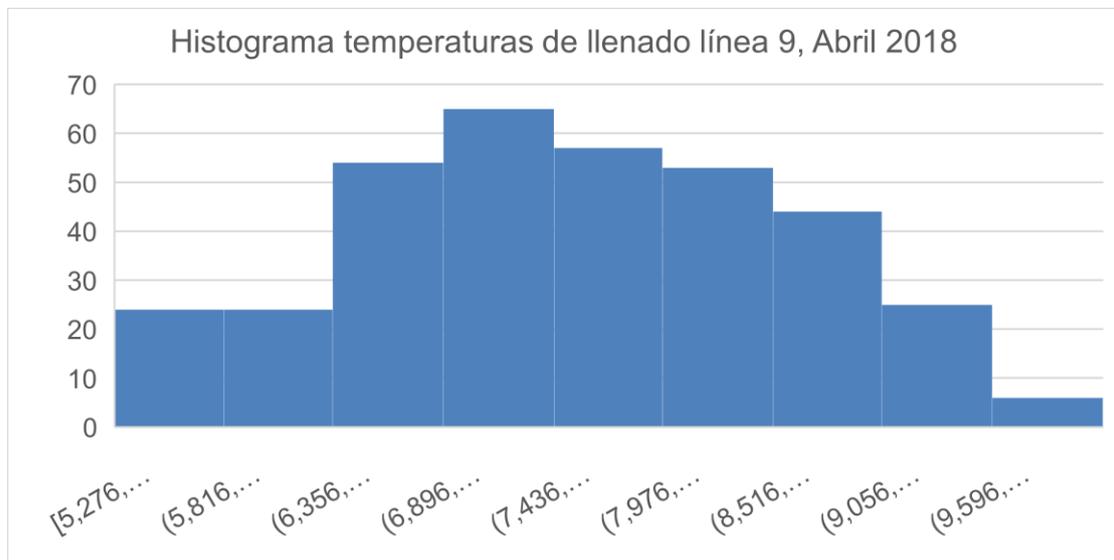


Figura 11: Histograma de temperaturas de llenado en línea 9, Planta Alcorta. Abril 2018

- Espumado

Como parte del relevamiento de la situación actual, relevaremos si existen en la práctica, temas asociados al espumado (en el caso de existir temas importantes con el espumado, esto obligaría a tener que tomar acciones previas, para resolver estos problemas, antes de avanzar con cualquier modificación de las condiciones de llenado), para eso, revisaremos los informes de producción e SAPⁱ para ver si se describe algún problema de este tipo. Para poder analizar ágilmente la información volcada en el sistema (son básicamente descripciones en texto de las causas de paradas con un detalle de los minutos de la duración de los eventos) utilizaremos una herramienta de minería de texto. Analizaremos los textos asociados a las paradas de las máquinas durante los últimos 2 meses (Enero y Febrero de 2019), para realizar este análisis utilizaremos un programa denominado Power BI (Power Business Intelligence) de la firma Microsoft, dicho programa tiene una opción en la que se puede armar nubes de texto agrupando textos similares. De este análisis obtenemos la siguiente información:

Total de minutos de paro por espumado: 469,6 (1)

Los minutos de parada de equipos, por espumado, según el tamaño de producto se distribuye así:

RGB 350 (línea 1) con 411,26 minutos

Botella de plástico retornable de 2 Litros con 35,94 minutos

Pet 2,25 litros (línea 8 +9) con $10+2,4= 12,4$ minutos

En la figura 12 se puede ver los gráficos armados para analizar los minutos de paro de equipo por espumado.

ⁱ En cada producción se notifica en SAP una orden de producción donde se detalla la información de los volúmenes producidos, el producto envasado, los insumos utilizados para la trazabilidad de los procesos, parámetros críticos de funcionamiento de los procesos y eventos de paradas de equipos donde se detallan las causas de dichos eventos.

Esto nos permitirá armar un plan de trabajo priorizado (con foco en quick winsⁱⁱ) para incrementar las temperaturas de llenado y así reducir el consumo de energía contestando además a la pregunta específica de cuánta energía se puede ahorrar por cada °C que se incremente la temperatura de llenado.

4.1.2 Fase 2: Entendimiento de los datos:

4.1.2.1 Recolección inicial de datos:

Para realizar el análisis tomaremos datos del sistema MES instalado en la planta. Como primer paso para entender qué datos necesitamos, describiremos las variables físicas involucradas en el proceso que son necesarias para el análisis.

La demanda de frío de cada línea depende de 3 variables:

$$Q = f(m, c_e, (t_s - t_e)^{54})$$

Donde:

($t_s - t_e$): Gap de temperatura de llenado vs temperatura ambiente

m: Caudal de bebida puesta en juego (m) [l/h].

c_e : Calor específico

El consumo de energía de la planta de frío depende además del rendimiento propio del circuito frigorífico y de la temperatura y humedad ambiental.

Como se comentó anteriormente, la planta cuenta con un sistema MES donde se encuentran monitoreadas variables de proceso que registran información

ⁱⁱ Quick wins: Acciones que permiten obtener resultados rápidamente.

cada 6 segundos. Comenzaremos revisando los tags existentes en el sistema para identificar qué variables de las que necesitamos se encuentran medidas.

Del relevamiento de las variables del sistema de adquisición de datos, se identificaron las siguientes variables:

- Temperatura de llenado [°C]
- Caudal de bebida o, en su defecto, caudal de agua [m³/hr o litros/hr]
- Contador de botellas [Botellas/min]
- Consumo de energía de planta de frío [kWh]

Para el caso de la temperatura del agua a ser enfriada, si bien no se encuentra medida la temperatura de ingreso en cada línea, sí se tiene registrada la temperatura de agua en línea 4 por lo que se utilizará ese dato en sustitución al dato por línea.

En el caso de la planta de refrigeración, se cuenta con el dato de consumo de energía.

En el momento del análisis (enero 2019) en función de los planes de producción se encuentran en marcha las siguientes líneas: 1, 2, 3, 6, 7, 8 y 9. Para nuestro estudio no incluiremos línea 7 porque no utiliza refrigeración para el proceso de llenado. Al envasar agua no carbonatada en bidones, no utiliza CO₂ por lo tanto no es necesario reducir la temperatura para el proceso de llenado.

4.1.2.2. Descripción de los datos

A continuación, resumiremos las líneas y variables con los que contamos en el sistema:

Tabla 2: Detalle de variables de interés para la planta de refrigeración medidas en líneas de envasado

Objeto	Temperatura. de llenado	Caudal de producto	Contador de botellas
Tipo de dato	Número decimal	Número decimal positivo	Número entero positivo
Línea 1	Ok, [°C]	Ok, [Lts/hr]	Ok, [botellas por minuto]
Línea 2	Ok, [°C]	Ok, [m3/hr]	Ok, [botellas por minuto]
Línea 3	Ok, [°C]	Ok, [m3/hr]	Ok, [botellas por minuto]
Línea 6	No	No	Ok, [botellas por minuto]
Línea 8	Ok, [°C]	Solo caudal de agua [Lts/hr]	Ok, [botellas por minuto]
Línea 9	Ok, [°C]	Ok, [m3/hr]	Ok, [botellas por minuto]

En línea 6 no se cuentan con datos de temperatura de llenado y caudal de bebida o agua, pero sí con los datos de las botellas que salen de la llenadora. Debido a ello, es posible que el análisis resulte distorsionado, ya que al no contar con el dato del tamaño de botella que se está llenando, pueden haber diferencias en las correlaciones si hubiera botellas con diferente contenido neto (el tamaño mínimo es de 1,5 Lts y el max de 2,5 lts).

En principio utilizaremos el dato como está y, de ser necesario, revisaremos nuevamente la variable. Entre los procesos de preparación de datos y modelado, como se vio en la figura 2, hay un proceso de ida y vuelta; en ese proceso, de ser necesario, se revisará.

En línea 8 no se cuenta con el dato del caudal del producto, pero si con el dato de ingreso de agua, como la bebida es la mezcla en proporciones definidas de jarabe y agua utilizaremos en su reemplazo el dato del caudal de agua que es proporcional al caudal de bebida, lo que no representa mayores dificultades por el reemplazo de la variable. El resto de los datos se encuentran, en principio, correctos.

El caso de la temperatura de llenado y del caudal de bebida merecen una consideración adicional. Al finalizar el embotellado de una bebida se realiza una limpieza de los circuitos y cañerías para eliminar restos de bebida y

mantener las condiciones microbiológicas adecuadas para garantizar la inocuidad de los productos. Esta limpieza varía dependiendo del producto y los tiempos de producción, y puede ir desde un enjuague hasta una limpieza con productos químicos denominada CIP (Clean in place). Durante este proceso se pasa una solución con productos químicos a temperatura y alto caudal para garantizar una limpieza físico química de las instalaciones.

Para nuestro análisis, este proceso afecta a los datos de temperatura y caudal. Para salvar este punto se agregará al análisis los contadores de botellas, porque en los casos donde se esté realizando una limpieza no hay incrementos en el contador de botellas, por lo cual este dato debe sumarse como complemento al dato de caudal de bebida. Más adelante verificaremos que los datos tengan las dimensiones adecuadas para validar que no tengamos más variables de las necesarias.

Al revisar los datos se verificó que en general se cuenta con una muy buena calidad de datos, ya que prácticamente casi no hay datos faltantes y hay muy poco ruido o valores outliers que afecten a la información, sumado a que los formatos de los datos son bastante consistentes.

4.1.3 Fase 3: Preparación de los datos

4.1.3.1 Exploración de datos

Software para análisis de datos:

Para el análisis de los datos utilizaremos MS Excel y KNIME 3.6.1 (o Konstanz Information Miner) que es una plataforma de minería de datos que permite el desarrollo de modelos utilizando un entorno visual creado bajo la plataforma Eclipse. Está concebido como una herramienta gráfica y dispone de una serie de nodos (que encapsulan distintos tipos de algoritmos) y flechas (que representan flujos de datos) que se despliegan y combinan de manera gráfica e interactiva.

Fue desarrollado originalmente en el departamento de bioinformática y minería de datos de la Universidad de Constanza, Alemania. En la actualidad, la empresa KNIME.com GmbH, radicada en Zúrich, Suiza, continúa su desarrollo a la vez que presta servicios de formación y consultoría.

KNIME integra diversos componentes para aprendizaje automático y minería de datos. La interfaz gráfica de usuario permite el montaje fácil y rápido de nodos para pre procesar, analizar, modelar y visualizar datos⁵⁵. El manejo del software es bastante intuitivo y no requiere de conocimientos de programación. Los nodos vienen pre ajustados con valores por defecto.

Nodos y flujos de trabajo:

En KNIME, las tareas individuales se representan con nodos. Cada nodo se muestra como un cuadro de color que tiene puertos de entrada y salida, así como un indicador de su estado, como se muestra en la figura N° 12.

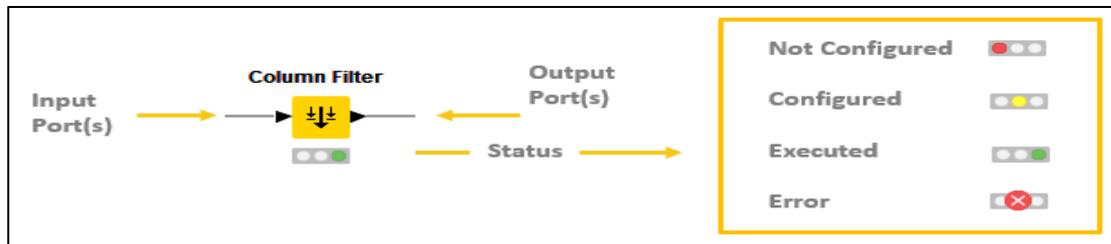


Figura 13: Puertos y estatus de nodos⁵⁶

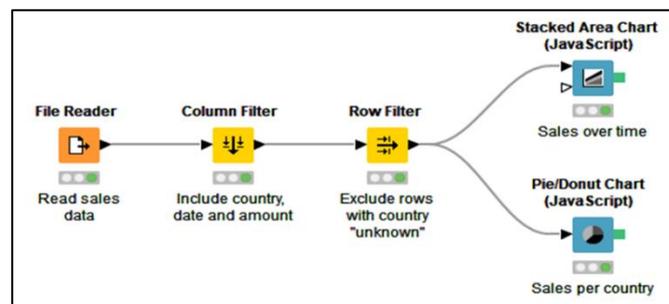


Figura 14: Ejemplo de flujo de trabajo

Las entradas son los datos que procesa el nodo y las salidas son los conjuntos de datos resultantes. Los nodos se configuran de manera individual ajustando los parámetros en diálogos de configuración. Al cambiar la configuración de un nodo, este cambia su estado y necesita ser ejecutado nuevamente. Esto queda indicado con un semáforo de colores debajo de cada nodo. Existen nodos para realizar todo tipo de tareas como lectura / escritura de archivos, transformación de datos, modelado, creación de visualizaciones, entre otros.

Cuando se cuenta con nodos interconectados estamos en presencia de un flujo de trabajo.

4.1.3.2 Exploración inicial

Para realizar una exploración inicial tomaremos una muestra de los datos de las variables ya indicadas por un periodo de 14 días que representan 2 semanas completas de producción abarcando el siguiente periodo: 10/02/2019 07:09 al 24/02/2019 10:07. La muestra contará con datos por cada minuto contabilizándose un total de 20.314 datos por variable. El rango de tiempo (1 minuto) se eligió así porque evitaría que se distorsione el análisis por la posibilidad de que se agrupen eventos (podrían pasar desapercibidos o distorsionados eventos como los CIPs (Clean in place) y las paradas y arranques de las líneas). Además, este rango de tiempo nos permite tener una mayor cantidad de datos para entrenar los modelos y poder experimentar incluso con redes neuronales que requieren de una gran cantidad de datos para su entrenamiento⁵⁷.

Comenzaremos revisando los datos crudos con el objetivo de ajustarlos y prepararlos para ser utilizados para un análisis o minería de datos.

Todos los datos analizados son valores numéricos; no hay valores categóricos para analizar.

Tomaremos los datos de las variables ya indicadas en la tabla 2 y procederemos a analizar valores máximos, mínimos y promedio para tener un mejor entendimiento de las variables. Revisando estos valores determinaremos en primera instancia si existen valores anormales que deberían eliminarse para que no generen ruidos o errores en los análisis.

Con la descripción de las variables podemos armar la siguiente tabla con un resumen de las variables revisadas.

Tabla 3: Valores máximos, mínimos y promedio de variables del circuito de refrigeración de datos sin depurar de una muestra (10/02/2019 al 24/02/2019).

Variable	Min	Max	Promedio
Total Plantafrío	-12.050.640	352.221	289,6493355
AR00-env-LI01-CONT-Botellas1	0	6.837	92,34550825
AR00-env-LI02-CONT-Botellas2	-1	515	78,33590943
AR00-env-LI03-CONT-Botellas2	-3	441	133,7616047
AR00-env-LI06-CONT-Botellas1	0	409	65,47674132
AR00-env-LI08-CONT-Botellas1	0	8.784	170,5441792
AR00-env-LI09-CONT-Botellas1	0	1.099	263,3628846
AR00-env-LI01-PREP01-FLUJO-Producto	-11431	41.988	4917,84993
AR00-env-LI01-PREP01-TEMP-Bebida	-12	246	10,95413959
AR00-env-LI02-PREP02-FLUJO-Producto	0	48	4,411912838
AR00-env-LI02-PREP02-TEMP-Bebida	0	89	18,12812974
AR00-env-LI03-PREP03-FLUJO-Producto	-4	58	16,64748781
AR00-env-LI03-PREP03-TEMP-Bebida	0	89	14,87624398
Temperatura agua de ingreso	0	31	26,23624102
AR00-env-LI08-PREP08-FLUJO-Agua	0	59.599	18199,16054
AR00-env-LI08-PREP08-TEMP-Bebida	0	90	15,41397267
AR00-env-LI09-PREP09-FLUJO-Producto	-7	67	14,57068744
AR00-env-LI09-PREP09-TEMP-Bebida	0	93	18,03162519

Nota: en color amarillo se indican las variables con valores erróneos (p.e., el caudal no puede tener un valor negativo).

5.1.3.3 Construcción de datos: limpieza de datos

Consiste en revisar los datos para eliminar valores erróneos y outliers.

En la figura 15 se muestra un ejemplo de los datos sin depurar.

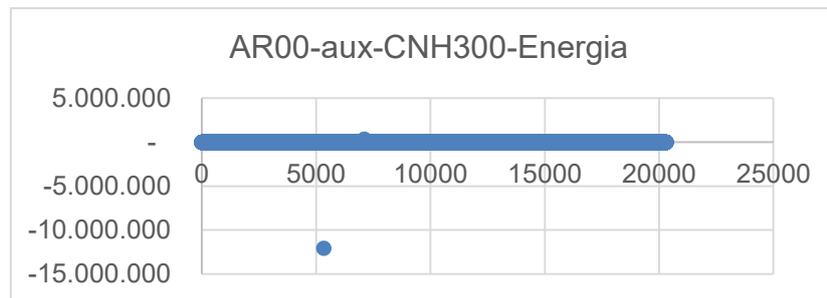


Figura 15: datos de consumo de energía en la planta de refrigeración sin depurar

Graficando las variables es fácil visualizar la presencia de outliers que están distorsionando el análisis de datos.

Se realiza el mismo procedimiento para el resto de las variables, limpiando los datos. De esta manera los parámetros de los datos trabajados quedan como se muestra en la siguiente tabla.

Tabla 4: Valores máximos, mínimos y promedio de variables asociadas al circuito de refrigeración de datos de una nuestra corregida (10/02/2019 al 24/02/2019).

Variable	Unidades	Min	Max	Promedio
Total Planta frío	kWh	0	815,622	284,3201
AR00-env-LI01-CONT-Botellas1	Bpm	0	449	92,01685
AR00-env-LI01-PREP01-FLUJO-Producto	Lt/hr	0	41988,42	4863,41
AR00-env-LI01-PREP01-TEMP-Bebida	°C	0,7721	57,2937	10,22739
AR00-env-LI02-CONT-Botellas2	Bpm	0	515	78,33981
AR00-env-LI02-PREP02-FLUJO-Producto	m3/hr	0	48,0169	4,412184
AR00-env-LI02-PREP02-TEMP-Bebida	°C	0	88,6436	18,12902
AR00-env-LI03-CONT-Botellas2	Bpm	0	441	133,7685
AR00-env-LI03-PREP03-FLUJO-Producto	m3/hr	0	58,1059	16,64908
AR00-env-LI03-PREP03-TEMP-Bebida	°C	0	88,805	14,87698
Temperatura ambiente (Prep L4)	°C	19,4502	31,4873	26,23753
AR00-env-LI06-CONT-Botellas1	Bpm	0	409	65,47996
AR00-env-LI08-CONT-Botellas1	Bpm	0	644	170,1245
AR00-env-LI08-PREP08-FLUJO-Agua	Lt/hr	0	59598,67	18200,06
AR00-env-LI08-PREP08-TEMP-Bebida	°C	0,96	90,4383	15,41473
AR00-env-LI09-CONT-Botellas1	Bpm	0	1099	263,3758
AR00-env-LI09-PREP09-FLUJO-Producto	m3/hr	0	66,5993	14,57477
AR00-env-LI09-PREP09-TEMP-Bebida	°C	3,903	92,6096	18,03251

4.1.4 Fase 4: Modelado

En esta fase utilizaremos técnicas matemáticas para hacer modelos (ecuaciones o funciones lógicas) para soportar las decisiones de negocio.

Tomando los datos ya depurados y limpios, y previa normalización de los mismos, realizaremos un análisis de correlación entre las variables de caudales, temperatura de bebida, temperatura de ingreso de agua, contadores de botellas y el consumo de energía de la planta de refrigeración. Para ello utilizaremos el programa KNIME con el que armaremos un modelo para realizar un análisis de correlación entre las variables.

En la figura 15 se muestra el modelo de nodos realizado en KNIME para el análisis de correlaciones entre datos de la planta de refrigeración.

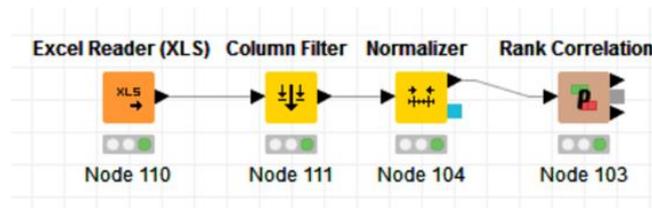


Figura 16: Modelo para el análisis de correlaciones entre datos de la planta de refrigeración

Para nuestro análisis crearemos un flujo de trabajo con 4 nodos:

- **Excel Reader (XLS):** Es un lector de archivos de Excel
- **Column Filter:** Se utiliza para filtrar columnas no necesarias para el análisis, en este caso se filtran los datos de las líneas 4, 5 y 7 que no son necesarios para el análisis.
- **Normalizer:** este nodo normaliza los valores de columnas con valores numéricos. Existen varios métodos posibles de normalización⁵⁸:

- Normalización min-max: Transformación lineal de todos los valores, de modo que el mínimo y el máximo en cada columna sean los valores indicados. En este caso utilizaremos esta opción.
- Normalización Z-score (Gaussian): Transformación lineal tal que los valores en cada columna sean Gaussianos (0,1) distribuidos. Es decir, la media es 0.0 y la desviación estándar es 1.0.
- Normalización por escalado decimal: El valor máximo en una columna (tanto positivo como negativo) se divide j veces por 10 hasta que su valor absoluto sea menor o igual a 1. Todos los valores en la columna se dividen por 10 a la potencia de j.
- Rank Correlation: este nodo calcula para cada par de columnas seleccionadas el coeficiente de correlación de Spearman⁵⁹. Para el modelo generado se define en los parámetros del nodo de normalización la normalización Máxima – mínima para todas las variables con un valor mínimo de 0 y un máximo de 1.

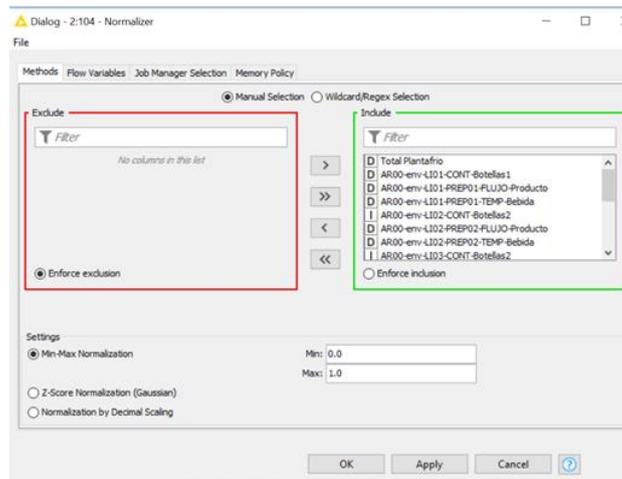


Figura 17: Configuración en KNIME del nodo Normalizer.

En este gráfico se observa una correlación negativa entre la temperatura de llenado y el consumo de energía en la planta frigorífica para las líneas 3 (-0,64), 8 (-0,46), 2 (-0,42) y 9 (-0,31). Esta correlación está alineada a las características del sistema y significan que un aumento en la temperatura de llenado se traducirá en una reducción del consumo de energía.

Para línea 1 esta correlación es muy baja. Con estas conclusiones obtenemos el primer resultado que se buscaba que era poder priorizar las líneas para implementar una estrategia de aumento de la temperatura de llenado. De este modo, las líneas en las que deberá trabajarse en orden de importancia por tener mayor impacto en el indicador son: 3, 8, 2 y 9. En contraposición, línea 3 tiene la mayor correlación positiva entre consumo de frío y caudal de producto y el contador de botellas lo que indica el fuerte peso de esta línea en el consumo de frío de la planta. Le siguen línea 6, 8, 9, 2 y finalmente línea 1 haciendo el peso del caudal un espejo al impacto de la temperatura de llenado de las líneas.

A continuación, se presentan gráficos que representan la relación entre las temperaturas de llenado de cada línea y el consumo global de energía en la planta de frío.

Línea 2

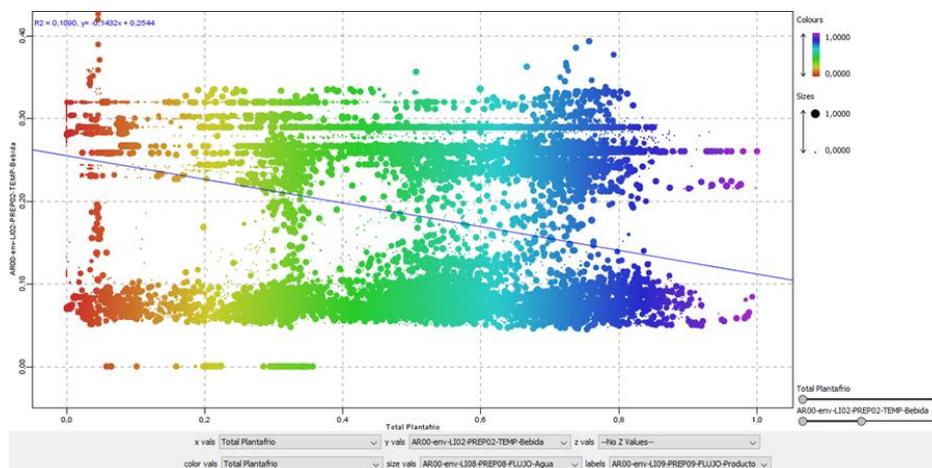


Figura 20: Temperatura de llenado en línea 2 vs consumo de energía en planta de refrigeración

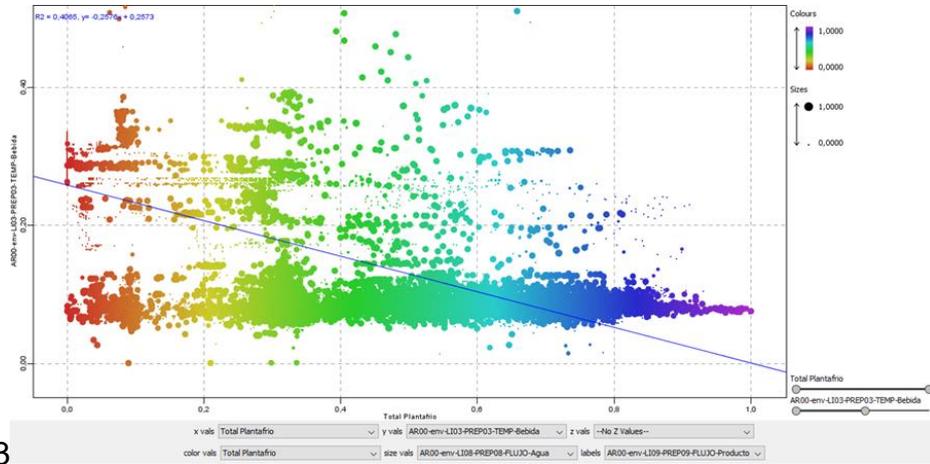


Figura 21: Temperatura de llenado en línea 3 vs consumo de energía en planta de refrigeración

Linea 8

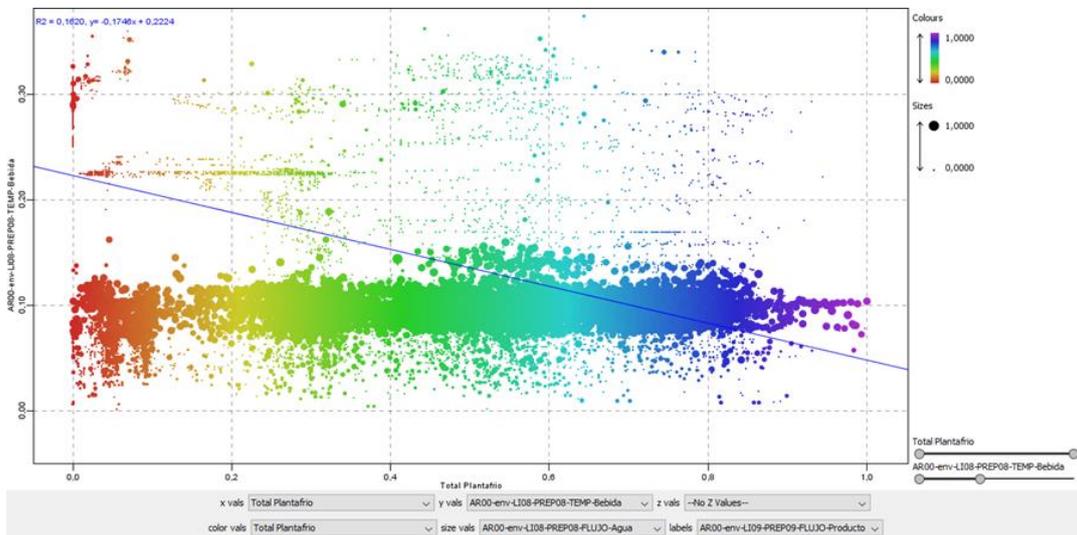


Figura 21: Temperatura de llenado en línea 8 vs consumo de energía en planta de refrigeración

Línea 9

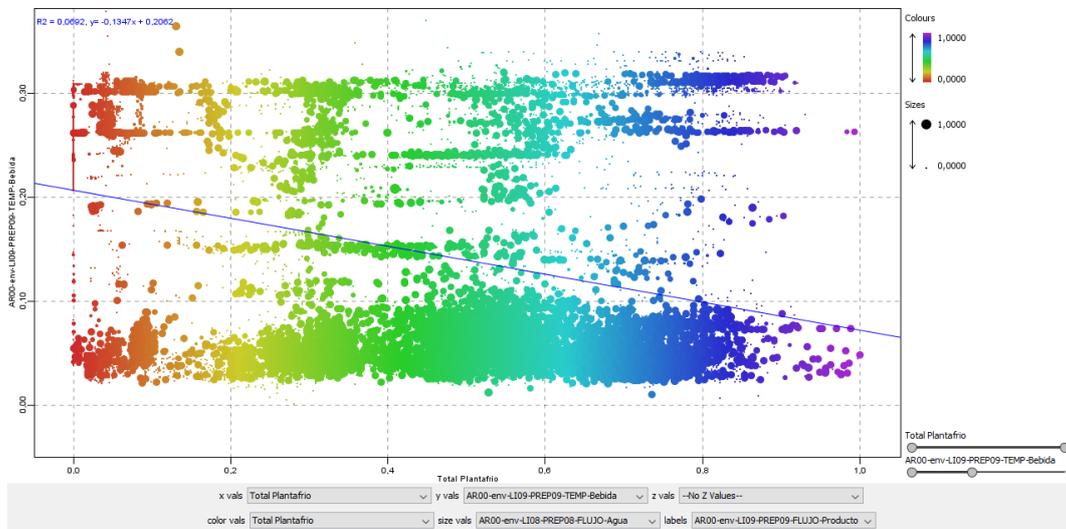


Figura 22 Temperatura de llenado en línea 8 vs consumo de energía en planta de refrigeración

Continuando con el análisis de la matriz de correlación encontramos algunos detalles interesantes:

Para el caso de línea 2, vemos una correlación negativa entre la temperatura de llenado y el caudal de bebida. Esta correlación no es normal porque los preparadores de bebida tienen un lazo de control con la temperatura y la apertura de las válvulas de glicol para que la temperatura de trabajo se mantenga lo más estable posible. Por eso, lo normal en estos casos es que la temperatura de llenado se mantenga estable y no dependa de los caudales de bebida. Analizaremos en más detalle el comportamiento de la temperatura de llenado vs los caudales de bebida en línea 2 para detectar si existe algún comportamiento que pueda indicar el porqué de esta correlación.

Tomaremos para el análisis los datos de línea 2 de un embotellado del día 13/03/2019 en el horario de 19:27 a las 20:48.

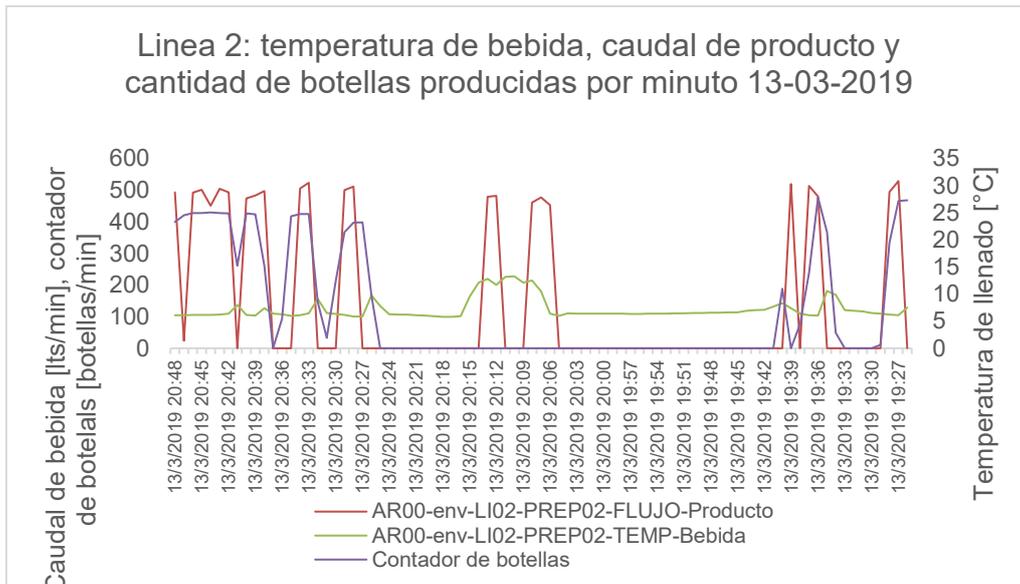


Figura 23 Temperatura de llenado, caudal de producto y cantidad de botellas producidas en línea 2 el 13/03/2019 de 19:27 a 20:48

Revisando las curvas de temperatura y caudales se puede observar que cada vez que arranca una producción se produce un incremento de la temperatura de la bebida. Esto no es algo normal en un proceso de llenado.

Realizaremos un gráfico de dispersión con los datos de temperatura de llenado vs caudal de bebida para ver en más detalle esta variación.

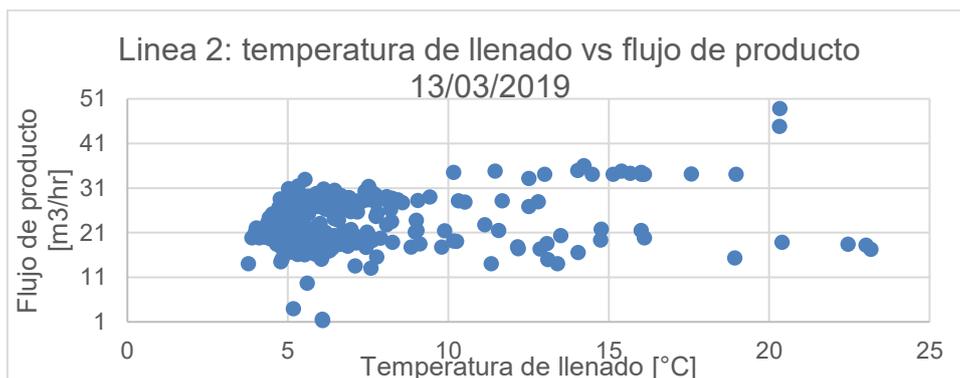


Figura 24: Temperatura de llenado vs caudal de bebida en línea 2 (13/03/2019)

Revisando la figura 23 observamos que existe una fluctuación en la temperatura durante el proceso de llenado con una mayor concentración en el rango de 3°C a 10°C y dispersiones que llegan hasta aproximadamente 23°C.

Los lazos de control del proceso no deberían permitir estas fluctuaciones por lo que se recomienda revisar el funcionamiento del preparador de bebida en más detalle.

Realizamos para la línea 9 el mismo gráfico que el realizado para línea 2 para ver si existe el mismo comportamiento.

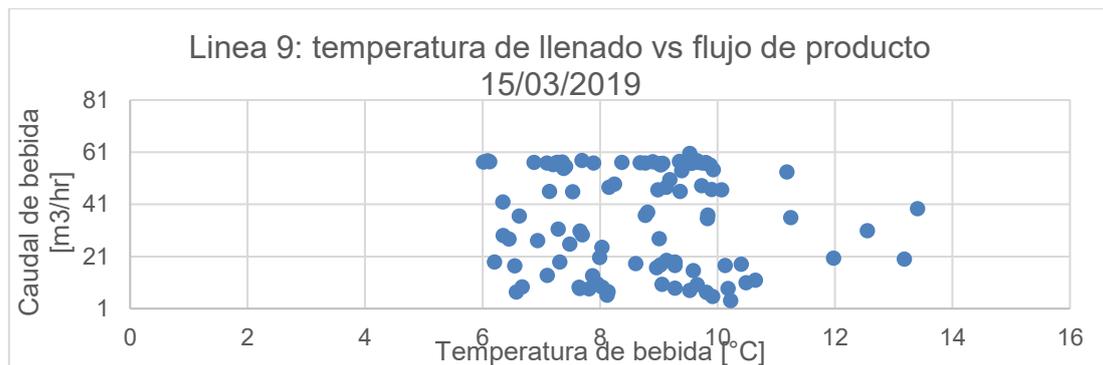


Figura 25: Temperatura de llenado vs flujo de producto en línea 9 15/03/2019

Como vemos en la figura 24, el comportamiento de línea 9 es muy distinto al de línea 2. La fluctuación de temperatura es mucho más acotada y con menor dispersión que la observada en el gráfico de dispersión de línea 2.

Por lo analizado hasta el momento, podemos decir que hemos encontrado una correlación negativa entre el consumo de energía de la planta de frío y las temperaturas de llenado. Esta correlación está alineada con las características del proceso y es lo esperable como resultado de un primer análisis. También encontramos una relación entre las temperaturas de llenado y los caudales de bebida en línea 2, lo que resulta anormal por las características del proceso.

Como paso siguiente, buscaremos responder la pregunta de cuánta energía se puede ahorrar aumentando la temperatura de llenado en cada línea para poder cuantificar los potenciales ahorros y luego poder medir los resultados.

Para ello realizaremos un análisis de regresión y redes neuronales y compararemos los resultados para elegir el mejor modelo para hacer el análisis.

Selección de técnicas de modelado.

Para crear un modelo predictivo del consumo de energía en función de la temperatura de llenado, trabajaremos con modelos de aprendizaje supervisado con aprendizaje por corrección de error, ya que tenemos las variables de entrada y salida, no tenemos con un modelo completo que simule el comportamiento y contamos con datos suficientes como para hacer entrenamiento de los modelos. En este escenario optaremos por probar 3 tipos de modelos: el primero, el más clásico, es un modelo de regresión polinómica (probaremos con distintos grados desde 1 a 5); el segundo, una red neuronal clásica del tipo Perceptrón; y en tercer lugar, una red neuronal del tipo DDA Dynamic Decay Adjustment. Finalizado ese análisis, compararemos los resultados para definir si estos modelos son adecuados para nuestro estudio.

Comenzaremos analizando regresiones polinómicas (entre grado 1 y 5).

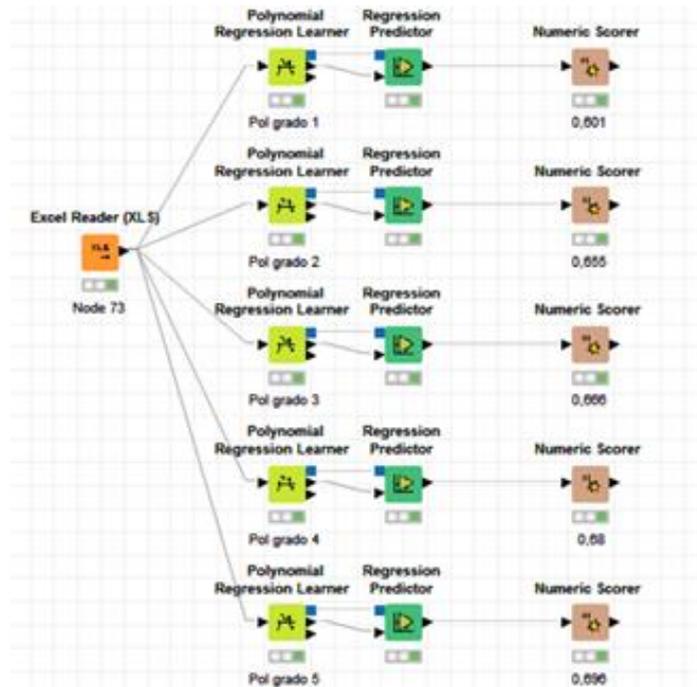


Figura 26 Flujo de proceso de regresiones polinómicas

El segundo análisis lo realizaremos generando una red neuronal del tipo Perceptrón. Como ya se mencionó, esta red es el primer tipo de red neuronal que fue creada y es buena para identificar patrones.

Para utilizar la red neuronal Perceptrón armaremos el modelo con un nodo denominado RProp MLP Learner.^{60 61} El nodo RProp MLP learner (RProp Multi Layer Perceptron Learner) es el nodo de aprendizaje de la red neuronal que realiza con un algoritmo RProp (Retro propagación) un ajuste de pesos de acuerdo con el comportamiento de la función de error (es un método directo de adaptación para un aprendizaje rápido de propagación hacia atrás).⁶²

El nodo RProp MLP Learner fue configurado con los valores por defecto, a excepción del valor de máximo número de iteraciones que se modificó por 99.999 para mejorar la precisión del modelo.

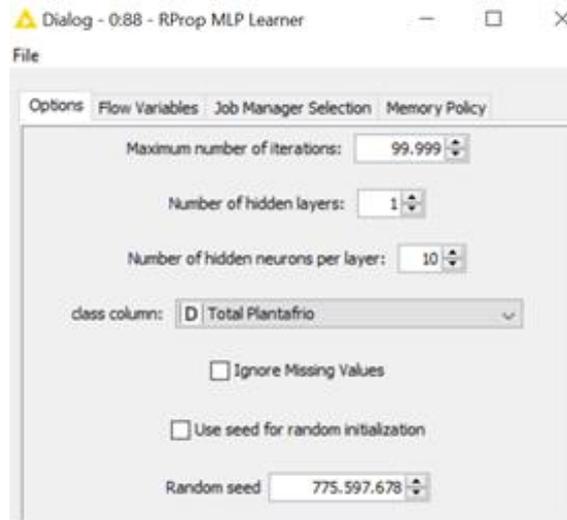


Figura 27: Configuración del bloque RProp MLP Learner

Para utilizar este nodo necesitamos normalizar los datos. En este caso los ajustaremos a un nuevo rango con una escala 0-1 (nodo Normalizer)

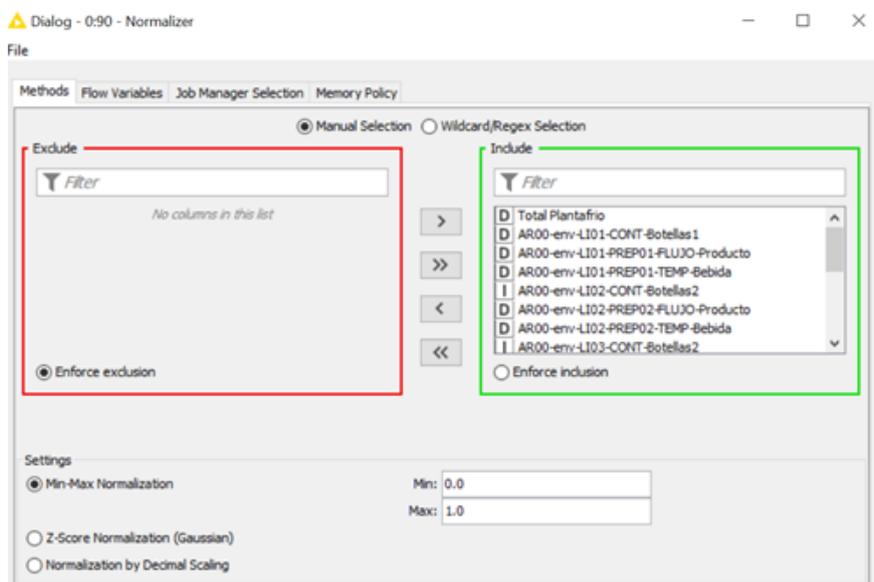


Figura 28: Configuración del nodo Normalizer

Una vez normalizados los datos, procedemos a realizar una partición de los datos con el fin de poder evaluar la efectividad del modelo. Utilizaremos el 50% de los datos para aprendizaje y el 50% para la evaluación.

El 50% de los datos para evaluación será utilizado en el nodo Multilayer Perceptron Predictor que permite realizar una predicción tomando un modelo de red existente (generado en el nodo RProp MLP Learner). Con la salida de este nodo (base de datos inicial más una columna con la predicción) podemos comparar el resultado de la predicción realizada por el modelo y los valores reales. Para esto último utilizaremos el nodo Numeric Scorer.

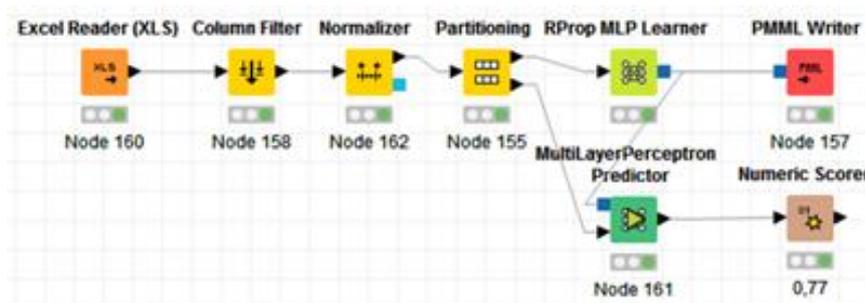


Figura 29: Flujo de tareas para una red neuronal de aprendizaje supervisado del tipo RProp Multilayer Perceptron Predictor

El modelo creado tiene un R^2 de: 0,77.

Finalmente, crearemos un modelo de red neuronal del tipo DDA que tiene como ventaja la rapidez de ejecución (mejor consumo de recursos de cómputo) y con la que se obtienen resultados con errores menores comparado a una red Perceptrón simple que no evalúa el error de manera global sino que lo hace localmente.

Al igual que en el modelo anterior, implementamos una partición de datos dejando un 50% para entrenamiento y un 50% para evaluación del modelo.

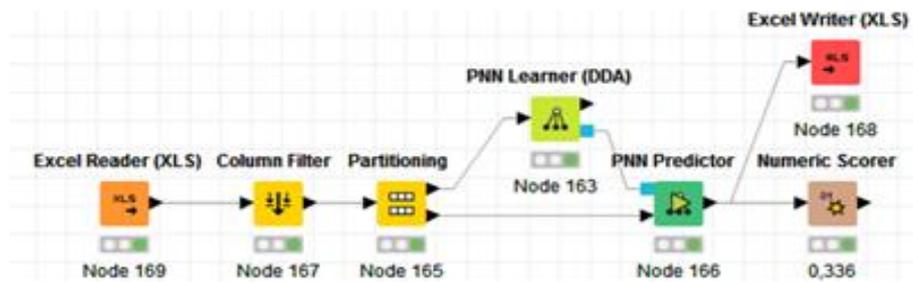


Figura 30. Flujo de trabajo para una red neuronal con nodo PNN Learner

El nodo PNN Learner (DDA) es un nodo basado en el método DDA (Ajuste de Desintegración Dinámica), donde los datos son etiquetados utilizando un entrenamiento constructivo de Redes Neuronales Probabilísticas como el algoritmo subyacente⁶³.

El nodo PNN Learner fue configurado con los valores por defecto como se muestran en la siguiente figura:

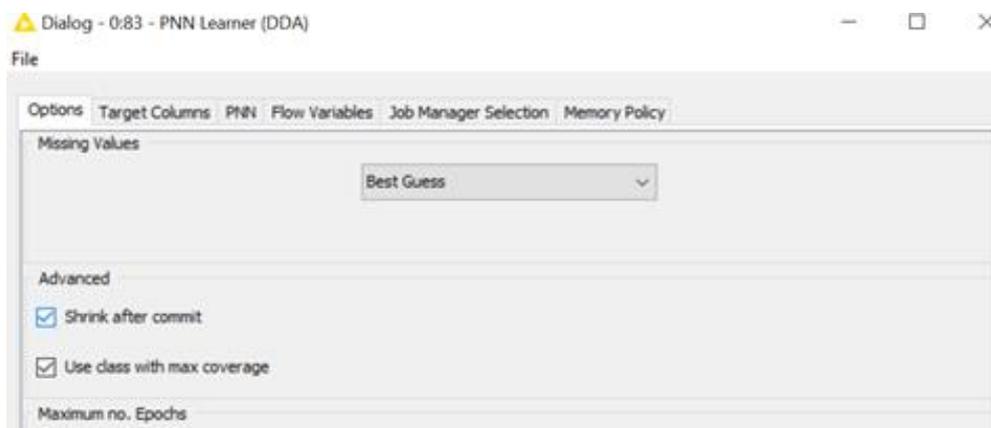


Figura 31: Configuración nodo PNN Learner (DDA)

El modelo tiene, como los anteriores, un nodo para evaluar los resultados.

En la siguiente tabla resumimos los resultados obtenidos con los 3 modelos:

Tabla 5 Comparación de resultados obtenidos por distintos métodos para analizar la correlación entre la temperatura de llenado y el consumo de energía.

Rama ciencia de datos	Modelo	R ²	Mejora relativa R ²
Análisis clásico	Regresión polinómica grado 1	0,601	
Análisis clásico	Regresión polinómica grado 2	0,655	8,99%
Análisis clásico	Regresión polinómica grado 3	0,666	1,68%
Análisis clásico	Regresión polinómica grado 4	0,68	2,10%
Análisis clásico	Regresión polinómica grado 5	0,696	2,35%
Redes neuronales	Rprop MLP, 1 capa oculta	0,77	
Redes neuronales	Rprop MLP, 2 capas ocultas	0,778	
Redes neuronales	DDA (ajuste de decaimiento dinámico)	0,336	

De los modelos evaluados se observa que la red Neuronal RProp MLP es el modelo con el mayor R², superando a las regresiones polinómicas. El modelo DDA es el que tiene menor R² resultado, por lo que resulta el peor de los modelos evaluados.

4.1.4.1 Análisis del error

Para analizar el error, graficaremos el mismo para los 3 modelos evaluados.

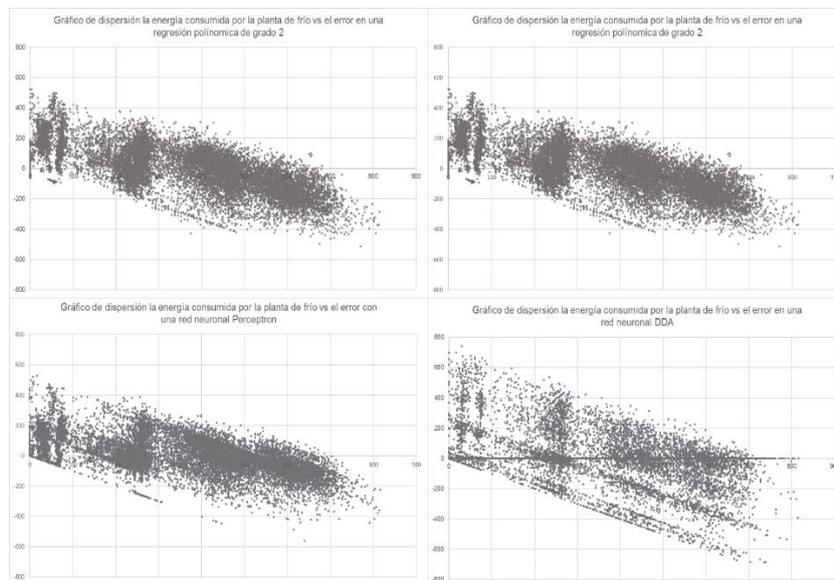


Figura 32 Gráficos del error en la predicción del consumo de energía para distintos modelos

4.1.4.2 Conclusión del análisis del error:

Del análisis del error concluimos que, entre los modelos evaluados, el que mejor funciona es la red neuronal RProp que utiliza un algoritmo de multicapa Perceptrón ya que es el que presenta el menor error y el mejor R^2

Análisis de sensibilidad

Seleccionado el mejor modelo, procederemos a realizar un análisis de sensibilidad para medir cuál es el impacto en el consumo de energía al aumentar la temperatura de llenado. Para esto, construiremos una tabla con datos para simular en el modelo con distintos escenarios de temperatura de llenado. En la tabla, para cada línea, tomamos un valor cualquiera de flujo de bebida y contadores de botellas y, manteniendo estos valores y el del resto de las líneas iguales, modificamos la temperatura de llenado (colocamos 3 alternativas, a 4°C, 5°C y 6°C). Con esto buscamos poder medir la sensibilidad del modelo a cambios de temperatura. Repetimos este proceso para todas las líneas y obtenemos la siguiente tabla:

Tabla 6 Simulación de diferentes escenarios modificando la temperatura de llenado para la determinación del impacto en el consumo de energía.

row ID	AR00-env-LI01-CONT-Botellas1	AR00-env-LI01-FLUJO-Producto	AR00-env-LI01-TEMP-Bebida	AR00-env-LI02-CONT-Botellas2	AR00-env-LI02-FLUJO-Producto	AR00-env-LI02-TEMP-Bebida	AR00-env-LI03-CONT-Botellas2	AR00-env-LI03-FLUJO-Producto	AR00-env-LI03-TEMP-Bebida	Temperatura ambiente (Prep L4)	AR00-env-LI06-CONT-Botellas1	AR00-env-LI08-CONT-Botellas1	AR00-env-LI08-FLUJO-Agua	AR00-env-LI08-TEMP-Bebida	AR00-env-LI09-CONT-Botellas1	AR00-env-LI09-FLUJO-Producto	AR00-env-LI09-TEMP-Bebida
Row0	449	34.685	3	-	-	24	-	-	24	24	-	-	-	24	-	-	24
Row1	449	34.685	4	-	-	24	-	-	24	24	-	-	-	24	-	-	24
Row2	449	34.685	5	-	-	24	-	-	24	24	-	-	-	24	-	-	24
Row3	-	-	24	463	17	3	-	-	24	24	-	-	-	24	-	-	24
Row4	-	-	24	463	17	4	-	-	24	24	-	-	-	24	-	-	24
Row5	-	-	24	463	17	5	-	-	24	24	-	-	-	24	-	-	24
Row6	-	-	24	-	-	24	333	40	3	24	-	-	-	24	-	-	24
Row7	-	-	24	-	-	24	333	40	4	24	-	-	-	24	-	-	24
Row8	-	-	24	-	-	24	333	40	5	24	-	-	-	24	-	-	24
Row9	-	-	24	-	-	24	-	-	24	24	300	-	-	24	-	-	24
Row10	-	-	24	-	-	24	-	-	24	24	350	-	-	24	-	-	24
Row11	-	-	24	-	-	24	-	-	24	24	400	-	-	24	-	-	24
Row12	-	-	24	-	-	24	-	-	24	24	-	480	57.600	3	-	-	24
Row13	-	-	24	-	-	24	-	-	24	24	-	480	57.600	4	-	-	24
Row14	-	-	24	-	-	24	-	-	24	24	-	480	57.600	5	-	-	24
Row15	-	-	24	-	-	24	-	-	24	24	-	-	-	24	1.000	36	3
Row16	-	-	24	-	-	24	-	-	24	24	-	-	-	24	1.000	36	4
Row17	-	-	24	-	-	24	-	-	24	24	-	-	-	24	1.000	36	5

Construida la tabla, armamos el modelo para realizar la simulación.

Para la creación del modelo, tomamos el modelo con el que se analizaron los datos con la red neuronal MProp. A este modelo le sumamos un nodo Multilayer Perceptron Predictor que alimentaremos con el modelo ya creado y la tabla propuesta arriba.

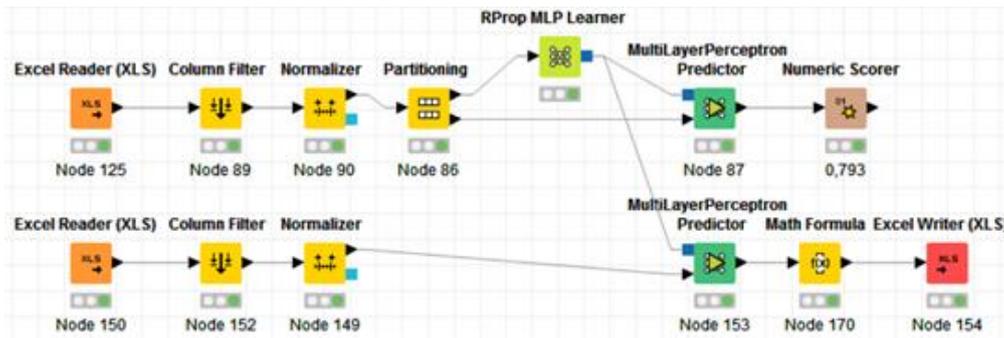


Figura 33 Flujo de proceso para análisis de sensibilidad con una red neuronal RProp MLP

Obtendremos así la siguiente tabla:

Tabla 7: Tabla input para análisis de sensibilidad de variación de la potencia de frío por variaciones en la temperatura de llenado por línea.

row ID	LI01-CONT- Botellas1	LI01-PREP01-FLUJO-Producto	LI01-PREP01-TEMP-Bebida	LI02-CONT- Botellas2	LI02-PREP02-FLUJO-Producto	LI02-PREP02-TEMP-Bebida	LI03-CONT- Botellas2	LI03-PREP03-FLUJO-Producto	LI03-PREP03-TEMP-Bebida	Temperatura ambiente (Prep L4)	LI06-CONT- Botellas1	LI08-CONT- Botellas1	LI08-PREP08-FLUJO-Agua	LI08-PREP08-TEMP-Bebida	LI09-CONT- Botellas1	LI09-PREP09-FLUJO-Producto	LI09-PREP09-TEMP-Bebida	Predicción [kWh]	Reducción consumo de energía por cada °C de aumento de temp [kWh]
Row0	449	34685,25	4	0	0	24	0	0	24	24	0	0	0	24	0	0	24	28,0	
Row1	449	34685,25	5	0	0	24	0	0	24	24	0	0	0	24	0	0	24	26,7	-1,2
Row2	449	34685,25	6	0	0	24	0	0	24	24	0	0	0	24	0	0	24	25,6	-1,1
Row3	0	0	24	463	16,668	4	0	0	24	24	0	0	0	24	0	0	24	145,3	
Row4	0	0	24	463	16,668	5	0	0	24	24	0	0	0	24	0	0	24	133,7	-11,7
Row5	0	0	24	463	16,668	6	0	0	24	24	0	0	0	24	0	0	24	122,4	-11,2
Row6	0	0	24	0	0	24	333,3333	40	4	24	0	0	0	24	0	0	24	544,2	
Row7	0	0	24	0	0	24	333,3333	40	5	24	0	0	0	24	0	0	24	541,9	-2,3
Row8	0	0	24	0	0	24	333,3333	40	6	24	0	0	0	24	0	0	24	539,3	-2,6
Row9	0	0	24	0	0	24	0	0	24	24	300	0	0	24	0	0	24		
Row10	0	0	24	0	0	24	0	0	24	24	350	0	0	24	0	0	24		
Row11	0	0	24	0	0	24	0	0	24	24	400	0	0	24	0	0	24		
Row12	0	0	24	0	0	24	0	0	24	24	0	480	57600	4	0	0	24	80,1	
Row13	0	0	24	0	0	24	0	0	24	24	0	480	57600	5	0	0	24	79,1	-1,1
Row14	0	0	24	0	0	24	0	0	24	24	0	480	57600	6	0	0	24	78,5	-0,536820279
Row15	0	0	24	0	0	24	0	0	24	24	0	0	0	24	1000	36	4	273,3	
Row16	0	0	24	0	0	24	0	0	24	24	0	0	0	24	1000	36	5	255,7	-17,6
Row17	0	0	24	0	0	24	0	0	24	24	0	0	0	24	1000	36	6	235,9	-19,8

Del análisis de sensibilidad del consumo de energía con los cambios de temperatura en base a los resultados de la Tabla 7, podemos obtener las siguientes conclusiones:

Línea 9 es donde hay un mayor impacto en el consumo de energía ante un cambio de temperatura (promedio 18 kWh por cada grado que se aumenta la temperatura de llenado). Le siguen línea 3 con un impacto promedio de 11,5 kWh por cada °C; línea 2 con un promedio de 2,5 kWh por °C; y finalmente línea 8 con un promedio de 0,8 kWh por °C.

Calcularemos el potencial ahorro por aumento de temperatura de llenado considerando el gap entre las temperaturas actuales utilizadas en el proceso y las temperaturas de diseño de los equipos.

Tabla 8: Resumen del análisis de sensibilidad del consumo de energía de refrigeración para distintas temperaturas de llenado

Línea	Temp. de llenado [°C]		Ahorro x °C [kWh]	Costo energía [\$/kWh]	Hs marcha x año [Hr]	Ahorro potencial anual [€]
	Temp promedio de llenado [°C]	Nuevo set point [°C]				
1	5	8	1,16	2,9	4118	41.680
2	6	8	11,43	2,9	2995	198.606
3	5,6	12	2,44	2,9	4118	186.322
8	6	12	0,79	2,9	4118	56.871
9	7,6	12	18,68	2,9	4118	981.706
Total						1.465.185

De los resultados obtenidos de la Tabla 8 podemos determinar que los mayores ahorros se concentran en 3 líneas de embotellado (9, 2 y 3, en orden de importancia).

Por otro lado, y volviendo al punto levantado en el Apartado 6.1.4, se procedió a la revisión del proceso de preparación de bebida en línea 2 donde se detectó que estaba fuera de funcionamiento un sensor que enviaba la señal de corte a la bomba de bebida que envía producto a la llenadora. Esto hacía que la bomba no se detuviera, generando un incremento en la temperatura de la bebida cuando la línea se detenía o cuando funcionaba con bajo caudal. Este

comportamiento anormal era el que generaba esa correlación anormal entre temperatura y caudal de producto en línea 2.

4.1.5 Fase 5: Evaluación

Hasta el momento, con el análisis de datos realizado definimos los siguientes puntos:

Grado de correlación entre variables medidas asociadas al proceso de llenado y el consumo de energía. En este punto se identificó una correlación negativa entre el consumo de energía para refrigeración y la temperatura de llenado.

Se analizaron los datos con regresiones polinómicas y redes neuronales con el objeto de elaborar un modelo que pueda predecir el consumo de energía en función de la temperatura de llenado para cuantificar el impacto de posibles acciones, identificándose que una red neuronal con un algoritmo RProp MLP puede simular el comportamiento del consumo de energía con menor error que el resto de los modelos utilizados.

Se utilizó el modelo generado por la red neuronal RProp Multilayer Perceptron para determinar y cuantificar el impacto en el consumo de energía por el aumento de la temperatura de llenado, logrando priorizar según el ahorro asociado las líneas donde reportará más ahorro trabajar con las temperaturas de llenado: las líneas 9, 2 y 3.

4.1.5.1 Plan de acción:

En función de los resultados obtenidos, la recomendación es: elevar la temperatura de llenado de las líneas realizando pruebas en los equipos para aumentar gradualmente la temperatura de llenado de a 1 grado hasta llegar a los valores recomendados de 8°C para las llenadoras de línea 1, 2 y de 12°C para las líneas 3, 8 y 9. Una vez llegado a estos valores, se recomienda continuar subiendo gradualmente la temperatura de llenado (primero en las

bebidas con menor carbonatación como Fanta y en segundo lugar en las de mayor carbonatación como Coca Cola / Sprite) hasta definir la temperatura en el valor más alto posible, garantizando que la condición de mínima sea al menos la temperatura recomendada en la tabla 8.

4.1.6 Fase 6: Implementación

Para implementar y consolidar el plan de incremento de la temperatura de llenado se desarrollan gráficos para monitorear on-line la temperatura de llenado y la cantidad de botellas producidas por los equipos para poder visualizar en un mismo gráfico si la línea está embotellando y a qué temperatura.

En la siguiente figura podemos ver el monitoreo de la temperatura de llenado y la cantidad de botellas producidas. En la fecha de los datos puede verse que en el intervalo de 10:00 a 20:00 se aumentó la temperatura de llenado con Fanta Naranja a valores entre 14,1 y 25,2°C, a continuación, se produjo un embotellado de Coca Cola regular con temperaturas entre 8,3 y 11,5°C.

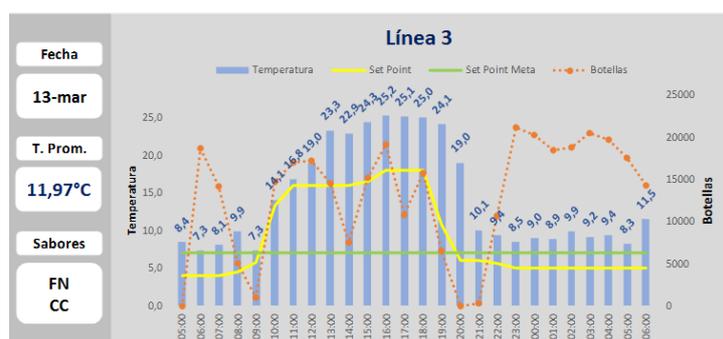


Figura 34 Monitoreo de temperatura de llenado, caudales de bebida y contadores de botella en línea 3.

Adicionalmente graficamos el consumo de energía de la planta de refrigeración y la temperatura de llenado minuto a minuto al momento de realizar el aumento de temperatura durante la prueba en línea 3.

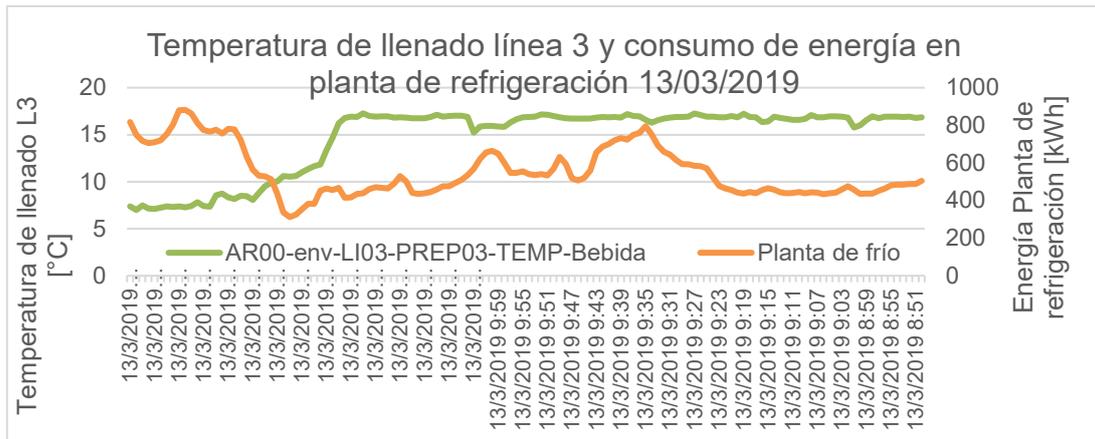


Figura 35 Temperatura de llenado y su relación con el consumo de energía.

En la figura 34 puede observarse como baja el consumo de energía en la planta de refrigeración en contraste con el aumento de la temperatura de llenado en línea 3.

Un punto que debemos verificar es si la línea de producción tuvo problemas en el proceso de llenado por efecto del aumento de temperatura. Para verificar este punto podemos recurrir a la información de las paradas de equipos que es relevada por el departamento de producción y cargada en SAP. Recurriendo a estos datos podemos graficar los paros de las máquinas para determinar si durante la prueba hubo paradas asociadas al aumento de temperatura. En la siguiente figura podemos ver el reporte que elaboramos para analizar los minutos de paro del día 13/03.



Figura 36 Tablero de comando sobre paros de equipos en línea 3 13/03/2019

Podemos ver que no existen paros de equipo asociados a la llenadora de botellas y no se indican paradas por espumado.

Revisión del proyecto: documentar la experiencia adquirida y generar las conclusiones generales.

Conclusiones

En el presente trabajo se ha buscado utilizar técnicas de análisis de datos para detectar oportunidades (insights) para el ahorro de energía en una planta de embotellado de bebidas. La aplicación de técnicas de análisis de datos (incluidas las redes neuronales) hace unos años hubiera estado restringida por la capacidad de cómputo, disponibilidad de software y de información, pero actualmente la situación es muy distinta ya que las fábricas (y en particular las de la industria de las bebidas) se encuentran altamente automatizadas, cuentan además con una gran cantidad de sensores para medir y controlar procesos y disponen de grandes bases de datos donde se registra esta información. En contraste, generalmente esta información no siempre es utilizada o explotada, siendo solamente utilizada para procesos de control pero no para un análisis posterior para lograr su máximo aprovechamiento. A nivel software también ha habido cambios y hoy en día se puede contar con herramientas gratuitas en las que se puede realizar el análisis de la información como por ejemplo Knime, donde, dependiendo del volumen de datos que se quiera manejar, puede ser utilizado sin mayores inconvenientes en computadoras de escritorio de uso general sin la necesidad de recurrir a computadoras más costosas.

Para realizar el análisis se utilizaron diferentes técnicas, incluyendo métodos de la estadística clásica como: Coeficientes de correlación, Regresiones polinómicas múltiples, Diagramas de dispersión, Histogramas de frecuencia, y métodos más modernos como lo son las redes neuronales.

En este último caso se evaluaron 2 tipos de redes, una utilizando un RProp Multilayer Perceptron (método ampliamente difundido y utilizado en la actualidad en diversos campos que incluyen la clasificación de imágenes, este algoritmo tiene ventajas sobre la red Perceptrón clásica ya que permite la

identificación de patrones no solo lineales si no que de cualquier índole) y otra utilizando un método denominado DDA (Ajuste de decaimiento dinámico).

En la comparación de los resultados de los análisis hemos determinado los siguientes puntos:

Las técnicas clásicas como la determinación del coeficiente de correlación son perfectamente válidas y útiles para detectar insights al momento de analizar información y permiten detectar tendencias y anomalías en los procesos funcionando como excelentes disparadores para realizar análisis de datos más profundos. Por otro lado, en los casos donde en el pasado se requería de un know how enorme y donde la realización de análisis solamente podía ser realizado por expertos (como es el caso de los sistemas de refrigeración), ahora es posible generar modelos con datos a veces incompletos que nos permiten poder cuantificar el impacto de las variables de proceso en el consumo de energía. Para esto, las redes neuronales son un excelente aliado por su capacidad de establecer patrones para predecir conductas con datos nunca presentados al modelo. En el caso del MLP su capacidad supera incluso a las técnicas clásicas como la regresión polinomial multivariada, pero para eso es necesario proveer al modelo de grandes volúmenes de datos, lo que con los sistemas existentes no representa mayores problemas.

Por lo analizado, podemos afirmar que las redes neuronales resultan de un excelente aliado, no solo para predecir comportamientos, sino que también para realizar análisis de sensibilidad ante distintos escenarios, los que en nuestro caso nos permitieron cuantificar y valorizar el potencial impacto de las acciones para el aumento de la temperatura de llenado, convirtiéndose de esta manera en una herramienta extraordinaria para poder comunicar dentro de una empresa y comprometer a las personas con los resultados que se pueden obtener si se mejora un proceso o se implementa una práctica (como en este caso es aumentar la temperatura de llenado). Como valor agregado adicional,

este proceso de análisis de datos no solo permite priorizar las acciones, sino que también permite el desarrollo de indicadores y gráficas que se podrían sumar fácilmente a la gestión diaria dándole a la operación indicaciones simples y claras de los parámetros que deben observar y los límites de control a seguir en los procesos para mejorar un indicador.

Referencias

¹ Negocio sustentable: entiende por qué es importante preocuparse por el medio ambiente (n.d.) obtenido el 20/03/2019 de la página oficial de Destino negocio website: https://destinonegocio.com/ar/emprendimiento-es_ar/negocio-sustentable-entiende-por-que-es-importante-preocuparse-por-el-medio-ambiente/

² Cross Industry Standard Process for Data Mining (n.d.), Wikipedia. Obtenido el 20/03/2019 de https://es.wikipedia.org/wiki/Cross_Industry_Standard_Process_for_Data_Mining

³ Piatetsky, G. (2014, Octubre) CRISP-DM, Still the top methodology for analytics, Data mining, or Data science projects, del sitio oficial de KDnuggets website: <https://www.kdnuggets.com/2014/10/crisp-dm-top-methodology-analytics-data-mining-data-science-projects.html>

⁴ Brown, M. S. (2015, Julio 29) What IT Needs To Know About The Data Mining Process del sitio oficial de Forbes website: <https://www.forbes.com/sites/metabrown/2015/07/29/what-it-needs-to-know-about-the-data-mining-process/#2a3a7e0d515f>

⁵ Manual CRISP-DM de IBM SPSS Modeler (n.d.), obtenido el 20/03/2019 de la página oficial de IBM website: <ftp://ftp.software.ibm.com/software/analytics/spss/documentation/modeler/15.0/es/CRISP-DM.pdf>

⁶ Crisp DM_ Process (n.d.). Wikipedia. Obtenido el 20/03/2019 de la página web: https://upload.wikimedia.org/wikipedia/commons/thumb/b/b9/CRISP-DM_Process_Diagram.png/330px-CRISP-DM_Process_Diagram.png

⁷ Manual CRISP-DM de IBM SPSS Modeler (n.d.), obtenido el 20/03/2019 de la página oficial de IBM website: <ftp://ftp.software.ibm.com/software/analytics/spss/documentation/modeler/15.0/es/CRISP-DM.pdf>

-
- ⁸ Britos, P., Hossian, A, Garcia Martinez, R. & Sierra, E. (2005) Minería de datos basada en sistemas inteligentes. Buenos Aires, Editorial Nueva Librería. P. 79.
- ⁹ Navidi, W. (2006) Estadística para ingenieros y científicos. México, Mc Graw Hill. P. 584.
- ¹⁰ Navidi, W. (2006) Estadística para ingenieros y científicos. México, Mc Graw Hill. P. 584.
- ¹¹ Dunham, M. H. (2002) Data Mining, Introductory and Advanced Topics, Prentice Hall, P.3.
- ¹² Dunham, M. H. (2002) Data Mining, Introductory and Advanced Topics, Prentice Hall, P.5-6
- ¹³ Dunham, M. H. (2002) Data Mining, Introductory and Advanced Topics, Prentice Hall, P.46.
- ¹⁴ Dunham, M. H. (2002) Data Mining, Introductory and Advanced Topics, Prentice Hall, P.59-60.
- ¹⁵ What Is Artificial Intelligence? (n.d.) obtenido el 20/03/2019 de la página oficial de Formal Reasoning Group website: <http://www-formal.stanford.edu/jmc/whatisai/node1.html>
- ¹⁶ Redes neuronales (n.d.), obtenido el 20/03/2019 de la página oficial de la Universidad de Salamanca website: <http://avellano.fis.usal.es/~lalonso/RNA/index.htm>
- ¹⁷ Redes Neuronales Artificiales. Tablada, C. J. & Torres, G. A., de la página oficial de FAMAF website: <http://www.famaf.unc.edu.ar/~revm/digital24-3/redes.pdf>
- ¹⁸ Britos et al. (2005) Minería de datos basada en sistemas inteligentes. Buenos Aires, Editorial Nueva Librería. P. 287.
- ¹⁹ Hiler J. R. & Martinez V. J., 1994
- ²⁰ Introducción a las redes neuronales Aplicadas (n.d.), obtenido el 20/03/2019 de la página oficial del departamento de estadística de la Universidad Carlos III de Madrid

website: <http://halweb.uc3m.es/esp/Personal/personas/jmmarin/esp/DM/tema3dm.pdf>

²¹ Introducción a las redes neuronales: Backpropagation learning, Sebastian Seung (2005), de la página oficial del MIT, departamento de ciencias del cerebro y cognitivas website: https://ocw.mit.edu/courses/brain-and-cognitive-sciences/9-641j-introduction-to-neural-networks-spring-2005/lecture-notes/lec20_backprop.pdf

²² Su, M. C., Jean, W. F. & Chang, H. T., 1996, " A Static Hand Gesture Recognition System Using a Composite Neural Network," in Fifth IEEE Int. Conf. on Fuzzy Systems, p. 786-792, New Orleans, U.S.A. (NSC85-2213-E-032-009)

²³ Tema 8. Redes Neuronales, Larrañaga, P., Inza, I. & Moujahid, A., obtenido el 20/03/2019 de la página oficial del Departamento de Ciencias de la Computación e Inteligencia Artificial de la Universidad del País Vasco Euskal Herriko Unibertsitatea website: <http://www.sc.ehu.es/ccwbayes/docencia/mmcc/docs/t8neuronales.pdf>

²⁴ Currea Urcua, M. & Jimenez Moscovitz, L.. Algoritmos de aprendizaje en retropropagación para perceptron multicapa. Fundación Universitaria Konrad Lorenz

²⁵ The Dynamic Decay Adjustment Algorithm, Niels.Mache (1995, Noviembre 28) de la página oficial de la Universidad de Tübingen website: <http://www.ra.cs.uni-tuebingen.de/SNNS/UserManual/node193.html>

²⁶ Hudak, M. J. (1992) RCE Classifiers: Theory and practice. Cybernetics and systems: an International Journal, 23:483-515, 1992.

²⁷ Britos et al. (2005) Minería de datos basada en sistemas inteligentes. Buenos Aires, Editorial Nueva Librería. P. 295-301.

²⁸ Dunham, M. H. (2002) Data Mining, Introductory and Advanced Topics, Prentice Hall, P.67.

²⁹ Allahyari, M., Pouriyeh, S., Assefi, M., Safaei, S., Trippe, E. D., Gutierrez, J. B. & Kochut, K. (2017 Julio, 28). A brief survey of Text Mining: Classification, Clustering and Extraction Techniques.

³⁰ Navidi, W.. (2006) Estadística para ingenieros y científicos. México, Mc Graw Hill. P. 13.

³¹ Navidi, W. (2006) Estadística para ingenieros y científicos. México, Mc Graw Hill. P. 13-14.

³² Tipos de análisis de regresión (n.d.) obtenido el 20/03/2019 de la página oficial de minitab (Soporte de minitab 18) website: <https://support.minitab.com/es-mx/minitab/18/help-and-how-to/modeling-statistics/regression/supporting-topics/basics/types-of-regression-analyses/>

³³ Tipos de regresión (n.d.), obtenido el 20/03/2019 de la página oficial de la Universidad de Barcelona website: <http://www.ub.edu/stat/GrupsInnovacio/Statmedia/demo/Temas/Capitulo13/B0C13m1t2.htm>

³⁴ Navidi, W. Editorial (2006) Estadística para ingenieros y científicos. México, Mc Graw Hill. P. 557.

³⁵ Normalización (estadística) (n.d.). Wikipedia. Obtenido el 20/03/2019 de [https://es.wikipedia.org/wiki/Normalizaci%C3%B3n_\(estad%C3%ADstica\)](https://es.wikipedia.org/wiki/Normalizaci%C3%B3n_(estad%C3%ADstica))

³⁶ Han, J., Kamber, M. & Pei, J. (2012) Data mining Concepts and techniques. Morgan Kaufmann. P.113-115.

³⁷ Britos et al. (2005) Minería de datos basada en sistemas inteligentes. Buenos Aires, Editorial Nueva Librería. P. 79.

³⁸ Navidi, W. Editorial (2006) Estadística para ingenieros y científicos. México, Editorial Mc Graw Hill. P. 476.

³⁹ Han et al. (2012) Data mining Concepts and techniques. Morgan Kaufmann. P.113.

⁴⁰ Correlación (n.d.) Wikipedia. Obtenido el 20/03/2019 de <https://es.wikipedia.org/wiki/Correlaci%C3%B3n>

⁴¹ Navidi, W. Editorial (2006) Estadística para ingenieros y científicos. México, Editorial Mc Graw Hill. P. 478.

⁴² Coeficiente de correlación de Pearson (n.d.) Wikipedia. Obtenido el 20/03/2019 de https://es.wikipedia.org/wiki/Coeficiente_de_correlaci%C3%B3n_de_Pearson

⁴³ Coeficiente de correlación de Spearman (n.d.) Wikipedia. Obtenido el 20/03/2019 de https://es.wikipedia.org/wiki/Coeficiente_de_correlaci%C3%B3n_de_Spearman

⁴⁴ Análisis de la correlación canónica (n.d.). Wikipedia. Obtenido el 20/03/2019 de https://es.wikipedia.org/wiki/An%C3%A1lisis_de_la_correlaci%C3%B3n_can%C3%B3nica

⁴⁵ Fomento Económico Mexicano (n.d.). Wikipedia. Obtenido el 20/03/2019 de https://es.wikipedia.org/wiki/Fomento_Econ%C3%B3mico_Mexicano

⁴⁶ El Sistema Coca Cola (n.d.) obtenido el 20/03/2019 de la página oficial de Coca-Cola Co. website: <https://journey.coca-cola.com/nuestra-compania/el-sistema-coca-cola>

⁴⁷ Coca Cola Femsa en Argentina (n.d.). Obtenido el 20/03/2019 de la página oficial de Coca Cola Femsa website: <https://www.coca-colafemsa.com/presencia/presencia-argentina.html>

⁴⁸ Coca-Cola, de principio a fin (n.d.), obtenido el 20/03/2019 de la página oficial de Coca-Cola Uruguay website: <https://www.coca-coladeuruguay.com.uy/historias/products-coca-coca-de-principio-a-fin>

⁴⁹ Embotelladoras o Máquinas Llenadoras de Botellas (2012, Enero 02) de la página Urbina Vinos Blog website: <http://urbinavinos.blogspot.com/2012/01/embotelladoras-o-maquinas-llenadoras-de.html>

⁵⁰ Al agitar bebidas con gas y abrirlas salpican a todo el mundo ¿Por qué? (2011, Julio 12), de la página Ciencias website: <http://ciencias.com/ciencianuestra/2011/07/12/al-agitar-bebidas-con-gas-y-abrirlas-salpican-a-todo-el-mundo-por-que/>

⁵¹ El proceso de elaboración de Coca-Cola (n.d.) obtenido el 20/03/2019 de la página oficial de Coca Cola España website: <https://www.cocacolaespana.es/content/dam/journey/es/es/private/file-assets/historia/proceso-elaboracion-coca-cola.pdf>

⁵² Evolución de la automatización en la industria alimentaria (2018, Septiembre 28) de la página oficial de Tecnología para la Industria website:

<https://tecnologiaparalaindustria.com/evolucion-de-la-automatizacion-en-la-industria-alimentaria/>

⁵³ ¿Qué es un Sistema MES (Manufacturing Execution System)? (n.d.), obtenido el 20/03/2019 del sitio oficial de Geinfor website: <https://geinfor.com/business/sistema-mes-manufacturing-execution-system/>

⁵⁴ Franco Lijó, J. M.. (2006) Manual de refrigeración. Buenos Aires. Editorial Reverte. P 101.

⁵⁵ Knime (n.d.). Wikipedia. Obtenido el 20/03/2019 de <https://es.wikipedia.org/wiki/KNIME>

⁵⁶ Knime: quick start guide. (n.d.) obtenido el 20/03/2019 de la página oficial de Knime website: https://docs.knime.com/latest/analytics_platform_quickstart_guide/img/03_node_status.PNG

⁵⁷ Inteligencia Artificial: Cuando la ciencia se combina con la ficción, Simons, J.. Principal Evangelist ML/AI, EMEA en Amazon Web Services (22 de octubre de 2018) de la página oficial de Agenda Empresa website: <https://www.agendaempresa.com/94181/opinion-julien-simons-amazon-web-services-inteligencia-artificial-cuando-ciencia-se-combina-ficcion/>

⁵⁸ Normalizer, KNIME Base Nodes version 3.7.1.v201901291053 by KNIME AG, Zurich, Switzerland, obtenido el 20/03/2019 de la página oficial de NodePit: <https://nodepit.com/node/org.knime.base.node.preproc.normalize3.Normalizer3NodeFactory>

⁵⁹ Rank Correlation KNIME Statistic Nodes version 3.7.0.v201811071020 by KNIME AG, Zurich, Switzerland, de la página oficial de NodePit: <https://nodepit.com/node/org.knime.base.node.stats.correlation.rank.RankCorrelationComputeNodeFactory>

⁶⁰ RProp MLP Learner KNIME Base Nodes version 3.7.1.v201901291053 by KNIME AG, Zurich, Switzerland de la página oficial de NodePit: <https://nodepit.com/node/org.knime.base.node.mine.neural.rprop.RPropNodeFactory2>

⁶¹ How to use Knime platform to easily create powerful predictive models – Part 2). Ragona, M., obtenido el 20/03/2019 de la página oficial de IWSConsulting website: <https://www.iwsconsulting.it/wp-content/uploads/2017/02/Utilizzare-la-Piattaforma-KNIME-per-modelli-predittivi-2.pdf>

⁶² Riedmiller, M. & Braun, H., "A direct adaptive method for faster backpropagation learning: theRPROP algorithm" ,Proceedings of the IEEE International Conference on Neural Networks (ICNN) (Vol. 16, pp. 586-591). Piscataway, NJ: IEEE.

⁶³ PNN Learner (DDA) KNIME Base Nodes version 3.7.1.v201901291053 by KNIME AG, Zurich, Switzerland, obtenido el 20/03/2019 de la página oficial de NodePit: <https://nodepit.com/node/org.knime.base.node.mine.bfn.radial.RadialBasisFunctionLearnerNodeFactor>

Bibliografía General

Blum, A., Hopcroft, J. & Kannan, R. (2018) Foundations of Data Science.

Britos, P., Hossian, A, Garcia Martinez, R. & Sierra, E. (2005) Minería de datos basada en sistemas inteligentes. Buenos Aires, Editorial Nueva Librería

Cengel. Y. A., (2007) Transferencia de calor y Masa, un enfoque práctico. Editorial Mc Graw Hill. Impreso en México.

Das, S. R., (2016) Data Science: theories, models, algorithms, and analytics. Editorial S.R. DAS.

Data Mining Case Studies, Proceedings of the First International Workshop on Data Mining Case Studies held at the 2005 IEEE International Conference on Data Mining Edited by Brendan Kitts, iProspect, Gabor Melli, Simon Fraser University, Karl Rexer, Rexer Analytics.

Dunham, M. H., (2002) Data Mining, Introductory and Advanced Topics, Prentice Hall.

Franco Lijó, J. M., (2007) Manual de Refrigeración. Editorial Reverte. Barcelona, España.

Han, J., Kamber, M. & Pei, J., (2012) Data Mining, Concepts and Techniques, Third Edition. Editorial Elsevier.

Hastie, T., Tibshirani, R. & Friedman, J. (2017). The Elements of Statistical Learning Data mining, inference, and prediction. Second edition. Springer Series in Statistics.

Langley, C., (2009) Refrigeración, Principios, prácticas y funcionamiento. Editorial: Paraninfo. Impreso en Madrid, España.

Molina López. J.M. & García Herrero, J. (2006) Técnicas de análisis de datos, aplicaciones prácticas utilizando Microsoft Excel y Weka. Universidad Carlos III de Madrid. España.

Norma ISO 50001:2018 (Versión corregida en fecha 2018-12-19)

Sistemas de gestión de la energía. Requisitos con orientación para su uso. (ISO 50001:2018).

Navidi, W.. Editorial (2006) Estadística para ingenieros y científicos. México, Mc Graw Hill.

Pérez Marqués, M., (2014) Minería de datos a través de ejemplos. Madrid, España. RC Libros.

Zhao, Y. (2012-2015.) R and Data Mining: Examples and Case Studies 1, Published by Elsevier in December 2012..

