



UNIVERSIDAD DE CHILE  
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS  
DEPARTAMENTO DE INGENIERÍA INDUSTRIAL

PREDICCIÓN DE FALLAS EN GRÚAS PORTACONTENEDORES UTILIZANDO  
ALGORITMOS DE MACHINE LEARNING

MEMORIA PARA OPTAR AL TÍTULO DE  
INGENIERO CIVIL INDUSTRIAL

FRANCISCO JAVIER MONTES PADILLA

PROFESOR GUÍA:  
BLAS DUARTE ALLEUY

MIEMBROS DE LA COMISIÓN:  
ALEJANDRA PUENTE CHANDIA  
JOSÉ NALDA REYES

SANTIAGO DE CHILE  
2024

RESUMEN DE LA MEMORIA PARA OPTAR AL  
TÍTULO DE: Ingeniero Civil Industrial  
POR: Francisco Javier Montes Padilla  
FECHA: 2024  
PROF. GUÍA: Blas Duarte Alleuy

## PREDICCIÓN DE FALLAS EN GRÚAS PORTACONTENEDORES UTILIZANDO ALGORITMOS DE MACHINE LEARNING

Prognostics and Health Management, PHM en adelante, es cada vez más utilizado en la industria, siendo parte de la cuarta revolución industrial, la toma de decisiones en base a datos es central y cada vez más solicitada en la industria para lograr mejores resultados y ser un ente más competitivo dentro del mercado. Dentro de PHM se encuentra la predicción de fallas, para esto el uso de diversos modelos de Machine Learning y Deep Learning se han convertido en un elemento fundamental.

El mundo logístico se caracteriza por la rapidez y alta demanda. En este rubro se encuentra SAAM Logistics, un operador logístico cuya actividad gira en torno al almacenaje y transporte de contenedores, actividad en la cual son fundamentales las Grúas Portacontenedores, máquinas capaces de levantar y movilizar los contenedores. Estas grúas se consideran maquinaria pesada y tienen elevados costos de mantención y renovación. El correcto funcionamiento de estas es esencial, por lo que, un plan de mantenimiento adecuado también lo es. Este trabajo se desarrolla entonces para la empresa SAAM Logistics, en concreto en el área de ingeniería, siendo el principal beneficiario al área de Equipos y Mantención.

Con el uso de herramientas de Data Science y Machine Learning se puede crear un plan de mantenimiento predictivo, con el fin de minimizar los tiempos de inactividad de las máquinas y reducir los costos de mantención. A partir de modelos de clasificación se busca predecir el estado de las máquinas en el futuro, con el objetivo de predecir las fallas para poder realizar los mantenimientos necesarios previo a que estas ocurran.

El presente trabajo, desarrolla 3 modelos de predicción de falla a partir de los registros de mantención de las grúas portacontenedores. En específico, se modelan 2 clasificadores de Machine Learning tradicional, utilizando Random Forest y AdaBoost y, una red recurrente LSTM, debido a la naturaleza secuencial de los datos.

Para realizar lo anterior, se debe construir un dataset con el fin de complementar la información proveniente de los mantenimientos, con información de volúmenes operativos a los que las máquinas se enfrentan, para caracterizar de mejor manera el estado actual y nivel de estrés de los equipos. Además, se propone un framework para generar las instancias de entrenamiento y prueba a partir de los registros de mantenimientos.

De esta forma, este trabajo propone una metodología adaptable y robusta para poder modificar la importancia de la temporalidad y ventana de predicción de los resultados.

Los resultados muestran que el modelo Random Forest, con una ventana de observación de 8 períodos y una ventana de predicción de 15 días, supera el rendimiento de los otros modelos en términos de Accuracy, F1-Score y beneficios reportados a la empresa. Por lo que, se convierte en el modelo propuesto como solución.

*“Our future is unwritten. It will be  
shaped by who we choose to be now.”*

- The Future We Choose

# Tabla de contenido

<b>1. Introducción .....</b>	<b>1</b>
1.1. <i>Objetivos</i> .....	2
1.1.1. Objetivo general .....	2
1.1.2. Objetivos específicos.....	2
1.2. <i>Alcances</i> .....	3
1.3. <i>Distribución del texto</i> .....	3
<b>2. Antecedentes.....</b>	<b>5</b>
2.1. <i>Operación SAAM Logistics</i> .....	5
2.1.1. Datos generales .....	5
2.1.2. Grúas portacontenedores .....	6
2.2. <i>PHM</i> .....	9
2.2.1. CBM .....	10
2.2.2. Mantenimiento predictivo .....	11
2.2.3. Costos de inactividad .....	12
2.3. <i>Machine Learning</i> .....	14
2.3.1. Métodos de balance de clases.....	14
2.3.2. Modelos de clasificación tradicionales .....	14
2.3.3. Modelos de clasificación de Deep Learning .....	16
2.3.4. Métricas a utilizar .....	17
<b>3. Metodología.....</b>	<b>20</b>
3.1. <i>Metodología a utilizar</i> .....	20
3.2. <i>Extracción de datos</i> .....	21
3.3. <i>Preprocesamiento</i> .....	23
<b>4. Desarrollo .....</b>	<b>27</b>
4.1. <i>Procesamiento</i> .....	27
4.2. <i>Modelos de clasificación tradicional</i> .....	30
4.2.1. Modelo de diagnóstico .....	30
4.2.2. Modelos de predicción a 15 días sin historia (M=1, Y=15).....	30
4.2.3. Modelo de predicción con ventana de observación 3 (M=3, Y=15).....	31
4.2.4. Modelo de predicción con ventana de observación 8 (M=8, Y=15).....	31
4.3. <i>Modelo de Deep Learning</i> .....	31
4.4. <i>Cálculo de costo de inactividad para evaluación</i> .....	32
<b>5. Resultados.....</b>	<b>34</b>
5.1. <i>Resultados de modelos de clasificación tradicional</i> .....	34
5.1.1. Resultado modelo de diagnóstico.....	34
5.1.2. Resultado modelo de predicción a 15 días sin historia (M=1, Y=15).....	35
5.1.3. Resultado modelo de predicción con ventana observación 3 (M=3, Y=15).....	37
5.1.4. Resultado modelo de predicción con ventana observación 8 (M=8, Y=15).....	38
5.2. <i>Resultado LSTM</i> .....	39
5.3. <i>Comparación y discusión</i> .....	40
<b>6. Conclusiones.....</b>	<b>43</b>

<b>7. Bibliografía.....</b>	<b>46</b>
<b>Anexos.....</b>	<b>48</b>
<i>Anexo A</i> .....	48
<i>Anexo B</i> .....	50
<i>Anexo C</i> .....	52

## Índice de Ilustraciones

Ilustración 1. Grúa portacontenedores.....	6
Ilustración 2. Componentes de la grúa. Grúa Kalmar DRF 450-65S5. Extraído de ficha técnica, Anexo A.....	6
Ilustración 3. Bloque de Contenedores. Extraído de (Guerra R. 2017) [17].	7
Ilustración 4. Cuadro de carga para grúas Kalmar DRF 450-65S5.....	8
Ilustración 5. Curva de bañera (Bathtub Curve) de la probabilidad de falla.....	10
Ilustración 6. Diagrama tipos de mantenimiento. Extraído de (Fink, 2020) [11].	12
Ilustración 7. Red Neuronal Recurrente .....	16
Ilustración 8. LSTM .....	17
Ilustración 9. Matriz de confusión. Elaboración propia.....	18
Ilustración 10. Diagrama metodología CRISP-DM .....	20
Ilustración 11. Intervalo de observación por máquina .....	22
Ilustración 12. Método de generación de instancias, ventana móvil. Extraído de (Wang J. 2017) [16].	25
Ilustración 13. Registros por máquina.....	28
Ilustración 14. Relación entre la antigüedad y horómetros con un ajuste lineal.....	28
Ilustración 15. Muestra del set de datos.....	29
Ilustración 16. Resumen arquitectura LSTM .....	32
Ilustración 17. Matriz de confusión, modelo de diagnóstico.....	34
Ilustración 18. PCA con etiquetas reales (target), modelo de diagnóstico.....	35
Ilustración 19. PCA con etiquetas predichas con Random Forest, modelo de diagnóstico.....	35
Ilustración 20. Matriz de confusión, modelo (M=1,Y=15).....	36
Ilustración 21. PCA con etiquetas reales (target), modelo (M=1,Y=15).....	37
Ilustración 22. PCA con etiquetas predichas con Random Forest, modelo (M=1,Y=15).....	37
Ilustración 23. Matriz de confusión, modelo (M=3,Y=15).....	38
Ilustración 24. Matriz de confusión, modelo (M=8,Y=15).....	39
Ilustración 25. Matriz de confusión, modelo LSTM.....	40
Ilustración 26. Comparación matrices de confusión para el total de instancias.....	41
Ilustración 27. Intervalo de observación con información de horómetros.....	51
Ilustración 28. Tarifario público.....	52

## Índice de Tablas

Tabla 1. Modelos de GPC.....	9
Tabla 2. Registros por categoría.....	27
Tabla 3. Métricas de evaluación, modelo diagnóstico.....	34
Tabla 4. Métricas de evaluación, modelo (M=1,Y=15).....	36
Tabla 5. Métricas de evaluación, modelo (M=3,Y=15).....	38
Tabla 6. Métricas de evaluación, modelo (M=8,Y=15).....	39
Tabla 7. Métricas de entrenamiento, LSTM.....	40
Tabla 8. Resumen de resultados.....	40
Tabla 9. Razón entre TP y FP.....	41
Tabla 10. Profit calculado para los modelos.....	41
Tabla 11. Primer y último registro OM y HO.....	50

## Índice de Ecuaciones

Ecuación (1).....	16
Ecuación (2).....	17
Ecuación (3).....	17
Ecuación (4).....	17
Ecuación (5).....	17
Ecuación (6).....	17
Ecuación (7).....	17
Ecuación (8).....	18
Ecuación (9).....	18
Ecuación (10).....	18
Ecuación (11).....	19
Ecuación (12).....	19
Ecuación (13).....	19
Ecuación (14).....	19
Ecuación (15).....	33
Ecuación (16).....	33
Ecuación (17).....	33
Ecuación (18).....	38
Ecuación (19).....	39
Ecuación (20).....	40

# 1. Introducción

Los sistemas de Prognostic and Health Management (PHM) tienen un rol fundamental en la eficiencia operativa de los procesos industriales modernos. PHM busca disminuir las fallas de los activos industriales a través del mantenimiento con 3 objetivos principales: aumentar la seguridad operativa, aumentar la confiabilidad de los activos y disminuir los costos derivados de las fallas.

Existen dos enfoques de mantenimiento clásicos: correctivo y preventivo. El primero, es un mantenimiento reactivo frente a la falla y el segundo, también conocido como “programado”, establece fechas para realizar las reparaciones, con la esperanza de realizarlos previo a las fallas. Considerar que ambos enfoques incurren en extra costos derivados de los tiempos de parada, recambio de piezas e intervenciones innecesarias.

PHM, como un elemento de la Industria 4.0 [8], busca incorporar información del estado de los sistema, eventos y operaciones a la planificación de los mantenimientos. A través, del uso sistemas inteligentes y tecnología se desea disminuir las fallas, prediciéndolas con exactitud para planificar oportunamente el mantenimiento. En este contexto, el uso de herramientas de Data Science para la detección de fallas está al alza [7, 10]. Los modelos de Machine Learning (ML) y su rápido desarrollo permiten utilizar datos históricos y actuales del comportamiento de los activos para realizar predicciones más precisas y confiables.

De esta forma, PHM se ha instaurado como norma en rubros industriales donde las repercusiones de una falla son muy altas. Por ejemplo, en el sector minero: las cintas transportadoras, camiones, palas mineras y plantas de procesamiento fijas, presentan costos de mantención y renovación elevados [1]; además, la interrupción de las líneas de procesamiento, generan caídas de la capacidad productiva y pérdidas económicas importantes. Es por esto, que técnicas de PHM en la minería de gran escala ya se considera un estándar de la industria [1]. En otros rubros, como la aviación, las probabilidades de desencadenar consecuencias catastróficas a partir de las fallas de componentes de los aviones es tan alta que se utilizan sistemas de PHM para prevenirlas y asegurar el mayor estándar posible [2, 3, 4]. Los modelos de predicción de falla basados en ML son desarrollados para complementar las técnicas de PHM provenientes de otras disciplinas, como físicas-mecánicas, modelos estadísticos o modelos matemáticos del análisis de sistemas (análisis de partes).

Por su parte, la logística terrestre - portuaria, se encuentra en constante cambio y estrés debido a las variaciones en los comportamientos de consumo [5]. El aumento de las importaciones y cierre de grandes puertos internacionales generan ambientes adversos, donde los operadores logísticos, tales como SAAM Logistics, desarrollan sus actividades.

La actividad principal de los operadores logísticos es movilizar y almacenar contenedores, actividad para la cual la maquinaria principal son las grúas portacontenedores o Reach Stacker, máquinas de gran tamaño, consideradas maquinaria pesada, que son las encargadas de movilizar y posicionar los contenedores dentro de los terminales logísticos.

Las grúas portacontenedores tienen altos costos de adquisición, mantención y arriendo (en caso de tercerizarlas). Además, su compra demora varios meses en concretarse. Es debido a lo

anterior que SAAM Logistics no cuenta con máquinas de respaldo, lo que provoca que frente a fallas y tiempos de inactividad derivados de mantenimientos correctivos, se disminuye la capacidad operativa y, por lo tanto, no se logra satisfacer la demanda. Para enfrentar esto, el Área de Equipos y Mantenimiento se encarga de realizar los planes de mantenimientos preventivos. Sin embargo, desde el año 2020 hasta mediados del 2023, el 34,2% de los mantenimientos realizados fueron de carácter correctivo.

Por lo expuesto anteriormente, la presente memoria busca crear un modelo de predicción de falla utilizando métodos de clasificación de Machine Learning para las grúas portacontenedores, enfocado de forma exclusiva en predecir la falla en un período futuro. Esto deja de lado otros enfoques populares, tales como el cálculo de vida remanente (RUL, Remaining Useful Life), detección de anomalías o mantenimiento basado en condición (CBM, Condition Based Maintenance).

## **1.1. Objetivos**

### **1.1.1. Objetivo general**

Este trabajo de memoria tiene por objetivo general:

“Desarrollar un modelo de predicción de fallas para las grúas portacontenedores, con el fin de poder crear un plan de mantenimiento predictivo”.

De esta manera, lograr gestionar de mejor manera los recursos de la organización: activos y personal.

### **1.1.2. Objetivos específicos**

Para lograr lo expuesto, se plantean los siguientes objetivos específicos:

- Calcular el costo de inactividad de las máquinas, compuesto por el costo de mantención, costo de oportunidad y costos compensatorios, para evaluar los modelos.
- Extraer y procesar datos sobre el mantenimiento y uso de las grúas portacontenedores, para crear un set de datos entregable a un modelo.
- Diseñar, desarrollar y evaluar modelos de Machine Learning para predecir fallas con los datos utilizados.
- Entregar a la compañía los resultados obtenidos para que puedan incorporarlo a su planificación de mantenimiento: el modelo propuesto junto con las recomendaciones de implementación.

## 1.2. Alcances

El presente trabajo busca desarrollar un modelo de predicción con la finalidad de poder disminuir los mantenimientos correctivos desarrollados a las grúas portacontenedores. Para esto, se utilizarán los reportes de mantenimiento como insumo principal, acompañado de horómetros, control de costos e información relacionada a los volúmenes operativos a los que se enfrentan las grúas. SAAM Logistics cuenta con 23 máquinas distintas en el período de observación comprendido entre enero del año 2018 a septiembre del año 2023. Donde las marcas de los proveedores son Kalmar, Linde, Liebherr, PPM y Taylor. Finalmente, solo se utilizaron registros de 18 grúas durante la ventana de tiempo, considerando solo máquinas con más de 40 registros durante el período de observación.

Para efectos de esta memoria, se considera una falla el momento donde el personal del área de equipos y mantención deben intervenir la máquina y, debido a esto, genere un tiempo de inactividad para el activo. Los modelos, por su parte, corresponden a modelos de clasificación binaria basados en datos eventuales a partir de los registros de mantenimientos, que generan la predicción para una ventana de predicción previamente definida.

En cuanto a los alcances, se decidió modificar la metodología: la fase 6 de implementación de CRISP-DM. La razón principal para dejar fuera la implementación, es debido a los factores externos no controlados por el memorista. Dentro de la empresa, la implementación tecnológica necesaria, como automatizar el traspaso de información desde los sistemas transaccionales, tiene que ser desarrollada por el Equipo de Sistemas del Área TI, la cual a su vez es un área transversal de SAAM Corporativo. Esto involucra temas de seguridad y costos, dado que integraciones de los sistemas transaccionales con otros software o herramientas tiene un costo de desarrollo más consultas.

SAAM Logistics es una empresa que todavía no se ha desarrollado en cuanto a las decisiones basadas en datos. Los datos no son almacenados de forma sistemática y menos aún analizados, no cuentan con un data warehouses o alguna arquitectura alternativa que cumpla con estas funciones; por lo que, el desarrollo de proyectos en ciencia de datos es complicado y más aún la puesta en marcha para un proyecto en productivo de estas características. Sin embargo, la pertenencia del memorista a la organización permite realizar la puesta en marcha del proyecto, pero esto se escapa de los tiempos necesarios para el desarrollo del proyecto dentro del contexto del trabajo de memoria, es por esta razón que se decidió dejar fuera de los alcances esta última parte.

El resultado principal de este trabajo es entregar un modelo de Machine Learning entrenado, que es capaz de predecir fallas en las grúas portacontenedores, en un formato tipo código, que sea ejecutable por la organización de manera correcta.

## 1.3. Distribución del texto

La sección 1, presenta la introducción del trabajo, donde se relata la motivación, objetivos de la memoria y alcances.

La sección 2 contempla los antecedentes, la revisión bibliográfica y el marco conceptual necesario para el desarrollo de este trabajo de memoria.

La sección 3, detalla la metodología de trabajo a utilizar y el detalle de los pasos a seguidos en este trabajo.

La sección 4, explica en detalle cómo se desarrolló el trabajo de memoria para obtener los resultados. Explicando el procesamiento de datos y modelamiento de los distintos predictores.

La sección 5, expone los resultados obtenidos a partir de los modelos previamente desarrollados y su correspondiente análisis.

Por último, la sección 6 plantea las conclusiones del trabajo desarrollado y propone el trabajo futuro y recomendaciones.

## **2. Antecedentes**

### **2.1. Operación SAAM Logistics**

#### **2.1.1. Datos generales**

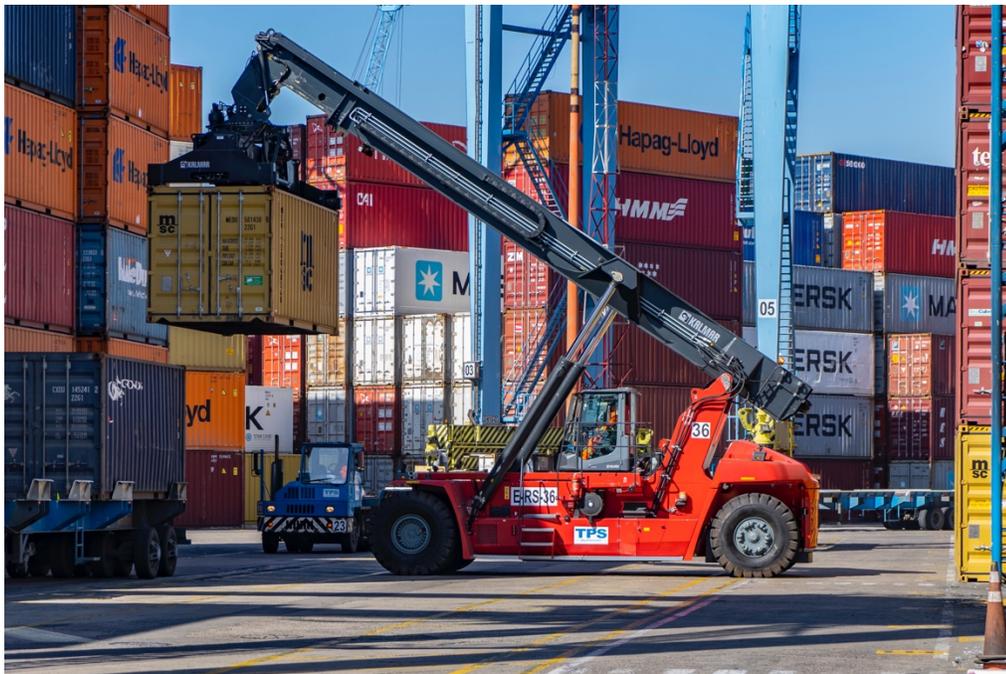
SAAM Logistics es un operador logístico enfocado en el transporte y almacenaje de contenedores, bodegaje y de servicios extraportuarios. La empresa actualmente cuenta con operaciones a lo largo de Chile con terminales en las localidades de San Antonio, Santiago y Puerto Montt, además de poseer operaciones in-houses en Punta Arenas y terminales extraportuarios en Iquique, Valparaíso y San Antonio. En cuanto a personal, posee más de 300 trabajadores distribuidos a lo largo del país [5].

SAAM Logistics nace como una empresa filial de SAAM, una multinacional de origen chileno que se dedica al negocio internacional a través de 3 verticales de negocio: remolcadores, puertos y logística; y es dentro de esta última se encuentra SAAM Logistics. Que por su parte, es uno de los principales operadores logísticos en Chile, movilizandando más del 70% de la carga del mundo del retail, tiene como clientes a grandes grupos como Falabella y Cencosud y, es el mayor prestador de servicios extraportuarios en Chile [5]. Durante el año 2022, se movilizaron aproximadamente 85.000 contenedores, un aumento del 46,5% respecto al año 2021. Además cuenta con 96.100 metros cuadrados de bodegas a lo largo del país [5].

Es importante mencionar que en octubre del año 2022, la empresa Hapag-Lloyd adquirió SAAM Logistics y SAAM Terminals. Esta última pertenece a la vertical de puertos que tiene control de 10 puertos que se disponen en 6 países de Latinoamérica.

Hapag-Lloyd, empresa de origen alemán, es la quinta naviera más grande del mundo y empresa líder de la alianza naviera a la que pertenece. La compra de las filiales de SAAM, se enmarca en una dinámica común dentro del mundo naviero, donde los principales competidores de Hapag-Lloyd ya se encuentran integrados verticalmente con el objetivo de ofrecer un servicio end-to-end, prestando tanto la logística terrestre y portuaria como el de flete naviero.

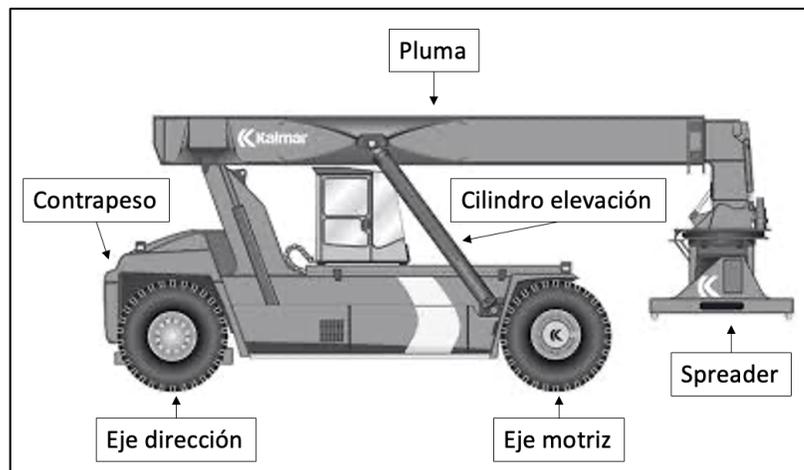
## 2.1.2. Grúas portacontenedores



*Ilustración 1. Grúa portacontenedores.*

Como se menciona en la sección 2.1.1. Datos generales, la actividad principal de SAAM Logistics es el almacenaje y transporte de contenedores, actividad para la cual la maquinaria principal son las grúas portacontenedores (GPC) o Reach Stacker.

Las GPC son altamente eficientes en terminales logísticos y en puertos de menor envergadura debido a su versatilidad, puesto que máquinas más grandes como las grúas STS (siglas en inglés de Ship-to-Shore) utilizadas en los puertos para la carga de buques, no se pueden desplazar.

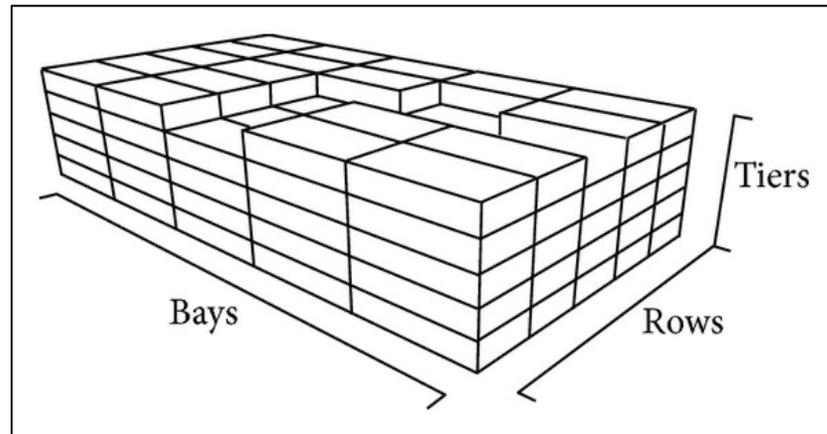


*Ilustración 2. Componentes de la grúa. Grúa Kalmar DRF 450-65S5. Extraído de ficha técnica, Anexo A*

Los contenedores se presentan en medidas de 20 o 40 pies de largo y un ancho de 8 pies y, existen de diferentes tipos: Estándar, High Cube (más altos), Reefer (refrigerados y habilitados para transporte de alimentos), Flat Rack (superficie plana, generalmente utilizado para carga

sobredimensionada), Tanques (especializados para la carga de líquido) y Open top (con techo removible para carga sobredimensionada). Las grúas portacontenedores cuentan con un Spreader superior, que se expone en la Ilustración 2, el cual le permite ajustar el largo para manipular contenedores de 20 o 40 pies.

Para comprender el funcionamiento de las GPC, la Ilustración 3 exhibe un bloque de contenedores:

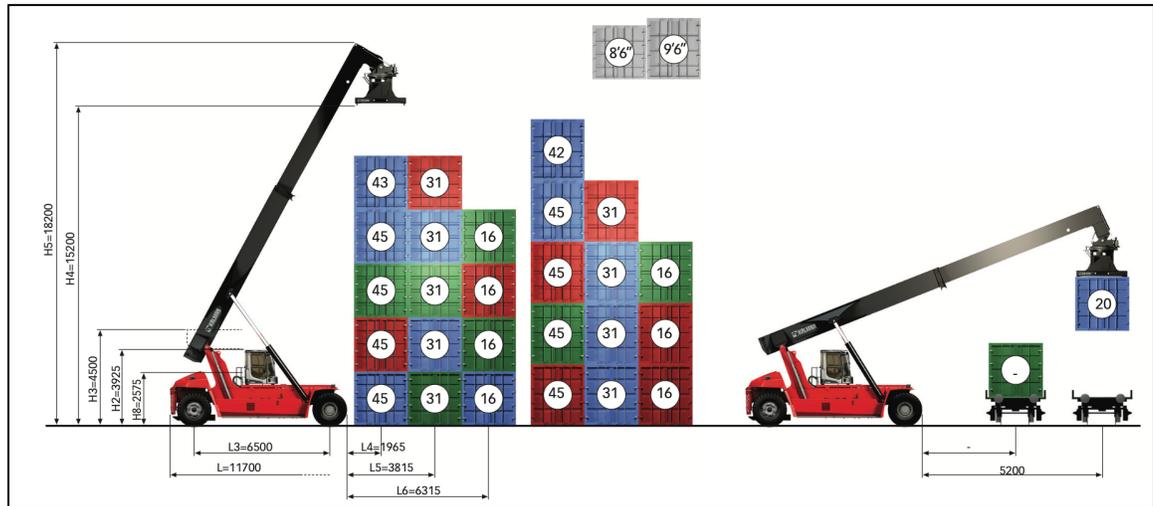


*Ilustración 3. Bloque de Contenedores. Extraído de (Guerra R. 2017) [17].*

Al apilar los contenedores, se forman figuras tridimensionales llamadas bloques (block), cada uno de ellos está constituido por bahías (bay), que representan una figura en 2 dimensiones al observarse desde el frente, compuesta por filas (rows) y altura (tiers). Generalmente, la altura de apilamiento máxima es de 5 unidades, pero en SAAM Logistics por definiciones de seguridad, se apila a un máximo de 4 de altura. Lo anterior en base a contenedores con carga, porque en depósitos de contenedores, que almacenan contenedores vacíos, se utilizan GPC de Spreader lateral que tienen la capacidad de apilar contenedores a 10 de altura.

Las GPC pueden movilizar aproximadamente 45 toneladas como máximo, la capacidad de levante de estas se ve afectada por la altura y distancia del levantamiento. La Ilustración 4 presenta el cuadro de carga de las grúas Kalmar DRF 450-65S5, extraído de la hoja de datos técnicos entregada por el proveedor (visible en el Anexo A). Los contenedores tienen un peso neto máximo de aproximadamente 4 toneladas (varía según tipo de contenedor y tamaño), mientras que tienen un peso bruto máximo de alrededor de 33 toneladas (puede variar según naviera). Además, las grúas cuentan con un peso aproximado de 80 toneladas, por lo que, se consideran maquinaria pesada.

Es importante mencionar que las grúas portacontenedores, no están diseñadas para el transporte de contenedores en tramos superiores de 30 metros, sino que su función es levantar y apilar contenedores en bloques, camiones o trenes. En distancias mayores, se utilizan camiones porteadores; por lo que las GPC se encargan de cargar el camión, estos se trasladan a la nueva locación y en el destino las grúas descargan el contenedor.



**Ilustración 4. Cuadro de carga para grúas Kalmar DRF 450-65S5.  
Diagrama de carga para contenedores estándar y High Cube**

Las GPC tienen un costo aproximado de USD \$500.000 y demora varios meses en concretarse una compra. Dentro de SAAM, cualquier inversión sobre los USD \$200.000 se considera una inversión mayor y debe presentarse a un comité de aprobación de parte de SAAM Corporativo, por lo que, la adquisición de nuevas GPC cae en esta categoría. En cuanto al arriendo de GPC, este tiene un costo de USD \$25.000 mensuales aproximadamente, sin embargo, este tampoco es de disponibilidad inmediata, debiendo confirmar el arriendo meses antes.

Actualmente, SAAM Logistics cuenta con 16 máquinas GPC:

- 5 en el Terminal Extraportuario de San Antonio.
- 3 en el Terminal Extraportuario de Valparaíso.
- 3 en el Terminal Logistics de Santiago.
- 2 en el Terminal Extraportuario de Iquique.
- 2 en operaciones in-houses en Punta Arenas.
- 1 en el Terminal Logistics de Puerto Montt.

La Tabla 1 a continuación presenta los modelos de las grúas portacontenedores de SAAM Logistics:

N°	Centro de emplazamiento	Nombre Terminal	Nombre	Código Interno	Modelo
1	SCL	Santiago	GPC FULL KALMAR 374	QSAGPFSKAL04500374	DRF 450-65S5
2	VAP	Valparaíso	GPC FULL KALMAR 375	QSAGPFSKAL04500375	DRF 450-65S5
3	SAI	San Antonio	GPC FULL KALMAR 391	Q03GPFSKAL04500391	DRU 450-65S5
4	SAI	San Antonio	GPC FULL KALMAR 392	Q03GPFSKAL04500392	DRU 450-65S5
5	VAP	Valparaíso	GPC FULL KALMAR 393	Q03GPFSKAL04500393	DRU 450-65S5
6	SCL	Santiago	GPC FULL LIEBHER 386	QSAGPFSLBH54500386	LRS 545
7	SAI	San Antonio	GPC FULL LIEBHER 387	QSAGPFSLBH54500387	LRS 545
8	PUQ	Punta Arenas	GPC FULL LINDE 311	QSAGPFSLIN04500311	C4531TL 5
9	SCL	Santiago	GPC FULL LINDE 312	QSAGPFSLIN04500312	C4531TL 5
10	SAI	San Antonio	GPC FULL LINDE 339	QSAGPFSLIN04500339	C4531TL 5
11	SAI	San Antonio	GPC FULL LINDE 348	QSAGPFSLIN04500348	C4531TL 5
12	SAI	San Antonio	GPC FULL PPM 18	QSAGPFSPPM04500018	FCH 55
13	IQQ	Iquique	GPC FULL TAYLOR 02	QSAGPFTTAY04300002	TEC 950L
14	IQQ	Iquique	GPC FULL TAYLOR 06	QSAGPFTTAY04300006	TEC 950L
15	PUQ	Punta Arenas	GPC FULL TAYLOR 08	QSAGPFTTAY04300008	TEC 950L
16	PMC	Puerto Montt	GPC FULL TAYLOR 38	QSAGPFTTAY04100038	TYC 920L

*Tabla 1. Modelos de GPC.*

De esta forma, las máquinas pertenecen a las marcas Kalmar, Linde, Liebherr, PPM y Taylor.

## 2.2. PHM

PHM o Prognostic and Health Management es un área de la ingeniería cuyo objetivo es entregar un análisis sobre el estado de las máquinas y sus componentes. De esta forma, PHM utiliza herramientas estadísticas, físicas y de ciencia de datos para detectar eventuales fallas (o detección de anomalías) de los sistemas. Estas herramientas se pueden utilizar para realizar un diagnóstico, lo que corresponde generalmente a detectar y clasificar el tipo de falla, o pronóstico, lo que genera una proyección de cuánto tiempo la máquina va a poder funcionar sin anomalías [7].

En los últimos años, PHM ha tomado cada vez más fuerza y, la literatura lo sitúa como una pieza clave de la cuarta revolución industrial, ayudando a las organizaciones a tomar decisiones en base a datos [7, 8]. Con aplicaciones en diferentes rubros. Un ejemplo importante de esto en este país es la minería, donde el tiempo de inactividad de camiones tiene elevados costos, por lo que, las mineras invierten y desarrollan importantes avances en este aspecto con el fin de poder perfeccionar planes de mantenimientos predictivos adecuados [1].

A continuación se describen los principales enfoques de mantenimiento clásicos. Elegir una correcta táctica para el desarrollo de los planes de mantenimiento es crucial para disminuir el tiempo de inactividad y reducir los costos derivados de esto:

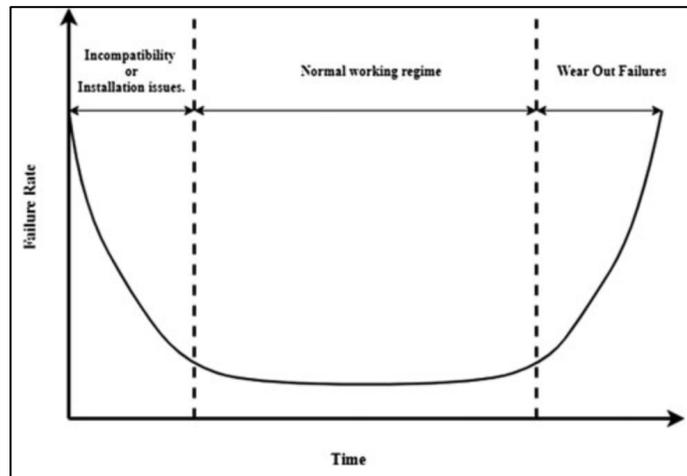
### **Mantenimiento correctivo**

Mantenimiento correctivo o reactivo (RM, Reactive Maintenance) corresponde a arreglar o reemplazar el componente una vez haya fallado, es el enfoque más sencillo y que menos exige al personal de las área de mantención. También, debido a que las máquinas operan hasta la falla, se maximiza el tiempo de utilización.

La desventaja más relevante de este tipo de enfoque es la seguridad, dado que se expone a los sistemas a niveles elevados de estrés y, las fallas puede derivar en otras. Este tipo de mantenimiento es el más costoso y puede inducir en tiempos de inactividad elevados debido a la mayor gravedad de las fallas [7, 9]. Los siguientes enfoques buscan minimizar este tipo de mantenimiento.

### **Mantenimiento preventivo**

Mantenimiento preventivo o programado (PM, Preventive Maintenance) corresponde a ejecutar mantenimientos periódicos programados, tal como su nombre indica, con el fin de anticiparse a las fallas. Este enfoque busca minimizar la probabilidad de fallo del sistema o componente. La Ilustración 5 presenta cómo se comporta la probabilidad de falla respecto al tiempo con la cual se ajustan los mantenimientos bajo este enfoque. La idea es evitar que los equipos entren en la zona de “Wear Out Failures” donde la probabilidad de falla aumenta. En este enfoque estadístico se utiliza generalmente tanto información física como histórica de las máquinas.



*Ilustración 5. Curva de bañera (Bathtub Curve) de la probabilidad de falla.*

La principal ventaja de este tipo de mantenimiento es que disminuye los tiempos de inactividad y tiende a tener costos más bajos que los reportados en mantenimiento correctivo. Sin embargo, este tipo de enfoque puede llevar a ejecutar mantenimientos y reemplazos que no son necesarios. Y debido a que no se incorpora información de los sistemas, diferentes factores pueden generar que las curvas de probabilidad de falla reales se desajusten con las calculadas teóricamente, provocando que la planificación deje de ser la adecuada [7, 9].

El programa de mantenimiento es generalmente desarrollado por expertos y, en específico al caso de estudio, el programa de mantenimiento preventivo que se sigue para las GPC en SAAM Logistics, es el recomendado por el proveedor.

#### **2.2.1. CBM**

Mantenimiento basado en condición (CBM, Condition Based Maintenance) corresponde a un enfoque de mantenimiento propio de PHM, dado que toma en consideración los datos del sistema para la toma de decisiones. CBM es el ejecutado después de haber verificado una o más condiciones del sistema que indican algún grado de degradación [9].

Mediante el monitoreo periódico o continuo del sistema, se permite detectar anomalías para poder intervenir con un mantenimiento. CBM es normalmente alimentado con datos desde sensores, tales como: sensores de temperatura, análisis de vibraciones, análisis de fluidos, ultrasónicos, etc. [1]

Este enfoque normalmente se compone de dos factores importantes: detección de anomalías y diagnóstico. La primera, se encarga de buscar outliers en los datos y la segunda de identificar las causas. Es por esto, que CBM es normalmente un problema de clasificación, que busca identificar un estado anómalo (definido como clase 1) utilizando gran variedad de modelos y técnicas de Data Science y Machine Learning. Métodos de selección y extracción de variables, métodos de preprocesamiento como autoencoders y modelos de clasificación clásicos: SVM, Árboles de Decisión, Regresión Logística, Random Forest, etc.

También, debido a la importancia de la temporalidad en este tipo de análisis, modelos de Deep Learning, tales como redes convolucionales 1D y 2D, redes recurrentes y LSTM (Long Short Term Memory Network) han sido muy utilizados [7, 10]. Sin restar importancia a estos modelos es necesario mencionar que al momento de realizar labores de diagnóstico, los modelos que no incluyen la temporalidad, son mucho más utilizados.

Como fue mencionado previamente, PHM ya es parte del estándar de algunas industrias, los cuales utilizan técnicas de CBM: la gran mayoría de equipos mineros cuentan con análisis de condición y, en plantas industriales, debido a que las maquinarias son estáticas, la instalación de sensores es más sencilla y permite el monitoreo en tiempo real.

### **2.2.2. Mantenimiento predictivo**

Mantenimiento predictivo (PdM, Predictive Maintenance) de forma similar a CBM, utiliza los datos, pero con un enfoque diferente, ya que en vez de detectar si el sistema presenta anomalías, busca predecir cuando este va a presentar una falla. Esta diferencia con CBM, genera que tenga costos menores en comparación, dado que permite aplazar las mantenciones sin perjudicar la seguridad y confiabilidad del equipo [7]. En los procesos de diagnóstico que se realizan con CBM, cuando una anomalía es detectada, los equipos deben ser intervenidos; PdM ofrece la ventaja de poder agregar oportunamente un mantenimiento a la planificación.

Existen 2 enfoques principales para desarrollar mantenimiento predictivo: el primero, corresponde a calcular la vida útil restante o remanente (RUL, Remaining Useful Life) que pertenece a un problema de regresión [1] y es conocido como un enfoque basado en métricas, dado que, más que predecir la falla, lo que ocurre es que se proyecta otra métrica de interés [10]. Es por esto que, para el cálculo de la RUL generalmente se utilizan datos similares a los necesarios para CBM de data sensorial. Para clarificar, el cálculo de la RUL generalmente se realiza de forma indirecta, se entrenan modelos para proyectar otro parámetro del sistema, como: la temperatura, viscosidad, revoluciones del motor, etc. Hasta un punto que se conoce que genera condiciones propicias para alguna falla del sistema. La ventaja de utilizar modelos de ML para esta tarea, es que se pueden encontrar relaciones más complejas con las variables del problema, donde no es solo proyectar el valor de un parámetro, sino combinaciones (lineales o no lineales) de los parámetros.

Otra metodología utilizada consiste en generar un proceso de dos partes: en primer lugar, un regresor que proyecta los parámetros en la componente temporal y, luego estos datos son entregados a un modelos de clasificación de CBM para obtener el estado. La ventaja de este método

radica en que generalmente no se deben desarrollar nuevos modelos de CBM, sino que se utilizan los modelos ya existentes para diagnóstico. De esta forma, esto sigue la misma lógica de cálculo indirecto que realiza la RUL.

El segundo enfoque, corresponde a predecir el estado de la máquina en un período futuro, esto convierte a esta tarea en un problema de clasificación con una ventana de tiempo que puede variar, conocida como ventana de predicción (PW, Prediction Window), que puede ir desde segundos hasta semanas [10]. Este tipo de modelos permite utilizar otro tipo de datos, como mediciones en intervalos de tiempo o datos del tipo eventual, este último, quiere decir que cada registro utilizado para entrenar los modelos son eventos con diferentes tiempos entre cada ocurrencia, en el contexto de PHM normalmente corresponde a los mantenimientos.

Datos del tipo sensorial son difíciles de encontrar en activos móviles, como es el caso de las grúas portacontenedores, dado que se requiere arquitectura dentro de los equipos capaz de registrar estos datos o realizar un seguimiento continuo, que igualmente puede verse interrumpido por factores externos dado la naturaleza móvil de las máquinas. Por otro lado, los registros de mantenimiento son ampliamente encontrados en diferentes industrias. Es por esto que, son datos de interés para poder obtener conocimiento, pero presentan otro desafío. La recolección de este tipo de datos no tiene como objetivo necesariamente el poder ser analizado por modelos de aprendizaje, más bien presentan un propósito de registro y cumplimiento de estándares de calidad. A pesar de esto, el segundo enfoque, permite utilizar este tipo de datos y, de ahí, su relevancia.

En la Ilustración 6, se observa cómo funcionan los diferentes enfoques de mantenimiento y cuáles son las ventajas de utilizar técnicas de PHM. El martillo representa la intervención o mantenimiento que involucra un costo y, en los casos que la falla no pudo ser prevenida, el tiempo de inactividad.

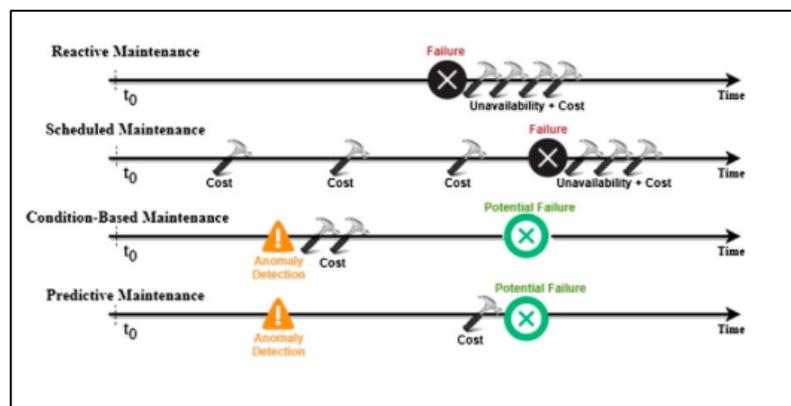


Ilustración 6. Diagrama tipos de mantenimiento. Extraído de (Fink, 2020) [11]

### 2.2.3. Costos de inactividad

El costo de que una máquina presente una falla, se conoce como costo de inactividad y se construye de varias fuentes, algunas más directas que otras [6]:

- Costos de mantención: Reparación de la falla. Son los más directos y se componen del valor de los repuestos, horas de trabajo de mantención y pago a proveedores externos, de ser necesario.
- Costos de oportunidad: Se entiende por estos como a los servicios no realizados por falta de disponibilidad de las máquinas. La baja de la capacidad de movilización de contenedores dentro de los terminales frente a un falla, provoca la cancelación de pedidos de despacho, disminución de desconsolidados y consolidado de contenedores y cualquier otra actividad que requiera movilizar los contenedores por la cual la empresa perciba ingresos. Es un costo no directo de calcular debido a que influye directamente de los volúmenes operacionales del momento en que ocurre la falla.
- Costos compensatorios: Son los asumidos post reparación para suplir la demanda no satisfecha. De forma natural las empresas tienen a aumentar la capacidad productiva luego de períodos de inactividad, con el fin compensar el lapso de demanda no cubierta. Estos también son conocidos como costos ocultos.

Los costos de inactividad, generados a partir de las fallas de los equipos, son usualmente subvalorados por las empresas debido a las dificultades para obtener los costos de oportunidad y los costos compensatorios; de la mano con esto, SAAM Logistics no tiene claridad del costo de inactividad de las GPC.

La importancia de conocer los costos de inactividad es que permite centrar el análisis con foco en el negocio, el mayor objetivo de una estrategia de mantenimiento predictivo es poder reducir los costos derivados de las fallas. En el trabajo de R. Prytz y otros [14] plantean que los beneficios y costos de implementar una estrategia de mantenimiento predictivo provienen de 3 componentes principales: la inversión inicial, el beneficio de predecir una falla y los costos de predecir erróneamente una falla (falsa alarma).

La inversión inicial son los costos de implementación, tanto de desarrollo como la infraestructura tecnológica necesaria para soportar una solución de estas características. El beneficio de predecir una falla se relaciona con los costos de oportunidad, dado que en esta situación se percibirían como beneficios, generando un ahorro de respecto a la situación original. Finalmente, los costos de una falsa alarma, ocurren cuando el modelo genera una alerta de falla cuando realmente no existe, esto desencadena en mantenimientos preventivos que conllevan horas de trabajo del personal, recambio de piezas y tiempo de inactividad de las máquinas.

Dentro de la lógica planteada en el trabajo no consideran las ocasiones donde las máquinas fallan y el modelo no las detecta (falsos negativos en clasificación binaria). Estas efectivamente corresponden a una oportunidad de poder detectar más anomalías, y por tanto, percibir mayores beneficios, pero esta forma de plantear el problema se concentra en implementar un modelo de mantenimiento predictivo en un escenario donde no existe. Es decir, en el caso base las fallas ocurrirían igualmente.

## 2.3. Machine Learning

Machine Learning nace como una rama de la inteligencia artificial la cual se centra en diseñar máquinas capaces de aprender a partir de la experiencia y extrayendo información desde los datos [7], “Learning from experience” (Mitchell, 1997). Los sistemas inteligentes son capaces de procesar la información proveniente de sensores y registros de mantenimiento superando la capacidad humana de percibir patrones y relaciones complejas entre variables del problema [7].

De esta forma, PHM al querer incorporar la información de los sistemas a la toma de decisiones, la utilización de métodos de Machine Learning resulta natural. La capacidad de procesamiento y complejidad de los datos que pueden manejar los hace altamente deseables en estas tareas y los buenos resultados obtenidos, han impulsado que métodos de PHM basados en ML sean cada vez más comunes.

La variedad de modelos de ML son extensos, por lo que solo se revisarán los modelos y herramientas que serán utilizados en este trabajo. Fueron seleccionados según la literatura consultada y, más importante aún, la naturaleza de los datos. Los datos utilizados para este trabajo de memoria son del tipo eventual, siendo la unidad base de cada registro los mantenimientos realizados a las máquinas. De esta forma, los modelos empleados corresponden a modelos de clasificación binaria de ML tradicional y, en adición, métodos de Deep Learning con arquitecturas más complejas, que han demostrado tener buenos resultados con el manejo de la temporalidad, un factor relevante al momento de realizar este tipo de análisis, por lo que se incluirán clasificadores construidos con redes convolucionales y redes recurrentes.

### 2.3.1. Métodos de balance de clases

En predicción de fallas como es esperable los registros con anomalías son menores que los registros donde los sistemas funcionan de forma normal, por lo que utilizar técnicas de balance de clases es bastante común [7, 10], tales como oversampling, subsampling o mixta.

Técnicas como SMOTE (Synthetic Minority Over-Sampling Technique) para generar nuevas observaciones sintéticas a partir de la clase minoritaria, han demostrado tener buenos resultados y son ampliamente utilizados en problemas de clasificación de diferentes índoles. SMOTE genera nuevas observaciones a partir de los  $k$  vecinos más cercanos pertenecientes a la misma clase, este parámetro indica que tan parecido van a resultar la observación sintéticas a sus vecinos y, el otro parámetro de interés, es el porcentaje de nuevas observaciones creadas.

A pesar de lo anterior, el problema de desbalance de clase es complejo de solucionar debido a la naturaleza intrínseca de los datos, donde el estado de falla es minoritario respecto al funcionamiento normal de las máquinas. Además, la generación de nuevas observaciones puede modificar la importancia secuencial de los datos, por lo que, el uso de estas técnicas deben ser aplicadas sobre datos ya preprocesados y estructurados para el entrenamiento del modelo.

### 2.3.2. Modelos de clasificación tradicionales

En el trabajo publicado por J. Leukel y otros [10] en el año 2021, se realiza una revisión extensa de modelos de predicción de falla, de los 34 trabajos seleccionados luego de los filtros, 11

utilizan datos de eventos y el resto, por lo general, emplean datos provenientes desde sensores o mediaciones periódicas provenientes de los sistemas o sus componentes.

Los principales modelos de clasificación utilizados pertenecientes al Machine Learning tradicional, corresponden a Random Forest, Support Vector Machines, Decision Trees, Logistics Regression y K-NN. Se destaca en la literatura el uso de Random Forest y Gradient Boosting, debido a que se encontró que tienden a tener un buen rendimiento con datos desbalanceados.

En el trabajo desarrollado por S. Bonnevey [12], aplican el método Random Forest con datos provenientes desde eventos en un servidor y, para incorporar la importancia de la temporalidad, utilizan Wavelets Transform obteniendo buenos resultados. Este transformador corresponde a una técnica de transformación de dominio que permite expresar datos temporales en un dominio bivariado.

Los algoritmos de ML tradicionales se construyen en su mayoría bajo el supuesto que en los datos de entrenamiento y prueba cada una de las observación son independientes e idénticamente distribuidas, esto genera que la relación existente en las series de tiempo entre un registro y otro no sean detectadas por los modelos. Para incorporar estas relaciones temporales se utilizan técnicas de feature engineering, transformaciones de dominio o estructura de los datos, como Wavelets Transform ya mencionado. La técnica conocida como Bag of Features corresponde a una estrategia de transformación de la estructura de los datos, que se aprovecha de la falta de capacidad de interpretar datos secuenciales de los modelos tradicionales y que consiste en incorporar los valores de las variables dependientes de registros anteriores a la instancia actual.

A continuación describiremos a grandes rasgos el funcionamiento de los algoritmos de clasificación utilizados en este trabajo: Random Forest y AdaBoost.

### **Random Forest**

Random Forest es un estimador que puede ser utilizado para clasificación o regresión que se construye entrenando un número de árboles de decisión (Decision Tree) en subconjuntos de los datos para luego promediar el resultado de cada uno de ellos. Esta estrategia se conoce como Bagging (o Bootstrap Aggregation) y corresponde a una técnica de ensamblaje, esto tienen la ventaja de reducir la varianza evitando el sobreajuste [1].

Este tipo de estimadores se conocen como meta estimadores dado que para su ajuste dependen de ajustar otros modelos, en este caso árboles de decisión. Adicionalmente, para entrenar cada uno de los árboles de decisión no solo se considera un subconjunto de los datos, sino también se puede seleccionar un subconjunto aleatorio de variables que hace el modelo más robusto aun [13].

### **AdaBoost**

AdaBoost Classifier también es un meta estimador que utiliza un clasificador “débil” y luego entrena copias de este estimador con los pesos modificados (boosted) para que tenga mejor desempeño en las instancias que en los entrenamientos previos la clasificación había sido incorrectamente. AdaBoost funciona tradicionalmente con árboles de decisión, pero este clasificador “débil” puede ser cambiado por otro.

A cada uno de los estimadores entrenados se le asigna un puntaje y el clasificador final es construido como una combinación lineal de todos los modelos entrenados. La idea detrás del

proceso iterativo, es que el las siguientes copias “boosted” del clasificador se puedan adaptar mejor a los casos problemáticos para las copias anteriores [15].

### 2.3.3. Modelos de clasificación de Deep Learning

Con la popularización de Deep Learning, nuevos métodos fueron incorporados debido a las facilidades que estos entregan para trabajar con la componente temporal de los datos. Redes Convolucionales en 1 dimensión (1D-CNN) han sido empleados con buenos resultados [7]. Otro método muy utilizado son las Redes Neuronales Recurrentes (RNN), las cuales se caracterizan por trabajar con datos secuenciales, incorporando información de los registros pasados para realizar la predicción [13]. La Ilustración 7, muestra de forma genérica el funcionamiento de las RNN, donde el input recibido es cada período proviene de  $x_t$  y  $h_{t-1}$ , input del período y estado anterior de la neurona, respectivamente.

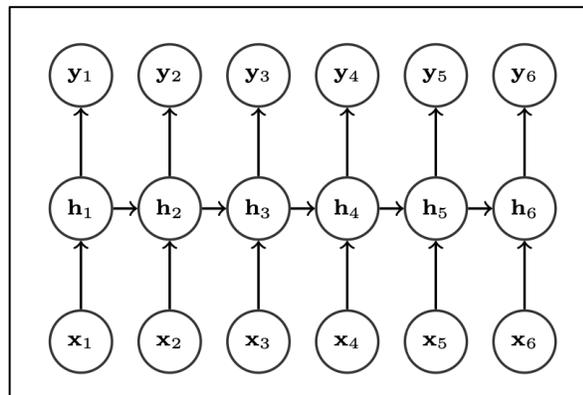


Ilustración 7. Red Neuronal Recurrente

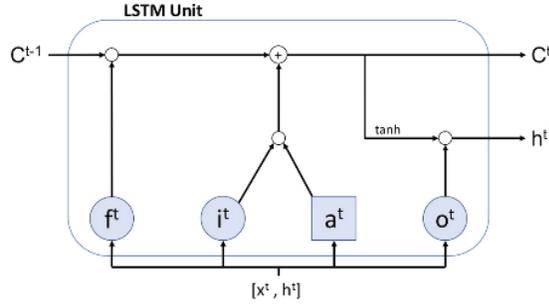
De esta forma el estado actual de la neurona es definido como:

$$h_t = g(h_{t-1}, x_t) \quad (1)$$

Donde  $g()$  representa la función de activación, donde las más comunes son Sigmoid ( $\sigma$ ), Tangente Hiperbólica ( $\tanh$ ) o Softmax.

#### Redes Long Short Term Memory

Long Short Term Memory (LSTM) es un tipo especial de red recurrente, desarrollada por Hochreiter y Schmidhuber con el objetivo de solucionar el desvanecimiento de gradiente, dado que logran controlar mejor el flujo de información desde un período a otro con compuertas de control y olvido [13]. La Ilustración 8, muestra el diagrama general de una LSTM.



*Ilustración 8. LSTM*

En cada celda LSTM  $x_t$ ,  $c_t$  y  $h_t$  representan el input, el estado de la celda y el output respectivamente. Generalmente se asocia la información de largo plazo a  $c_t$  y la memoria de corto plazo a  $h_t$ . Además,  $X^n$  representa una matriz con  $d$  registros de  $p$  features de forma que  $n = d \times p$  que es una instancia que se entrega al modelo.

En cada celda existen 3 puertas de control: puerta de olvido  $f_t$  (forget gate), puerta de ingreso  $i_t$  (input gate) y la puerta de salida  $o_t$  (output gate). La puerta de ingreso decide qué información de  $x_t$  y  $h_{t-1}$  se utiliza para calcular  $C_t$ , luego la puerta de olvido filtra la información de  $C_{t-1}$  y, finalmente, la puerta de salida define que información de  $C_t$  se utiliza para calcular  $h_t$  [13]. Con esto las celdas funcionan de la siguiente forma:

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad (2)$$

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \quad (3)$$

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \quad (4)$$

$$a_t = \tanh(W_a x_t + U_a h_{t-1} + b_a) \quad (5)$$

$$C_t = f_t \circ C_{t-1} + i_t \circ a_t \quad (6)$$

$$h_t = o_t \circ \tanh(C_t) \quad (7)$$

Donde  $W$  y  $U$  representan los pesos y  $b$  el sesgo.

### 2.3.4. Métricas a utilizar

De la mano con los métodos de balance de clases, las métricas a utilizar también son importantes definir las. Al trabajar con datos desbalanceados los modelos pueden tener buen rendimiento en datos de entrenamiento, pero no así en datos de prueba.

Un tema importante es poder medir el rendimiento de los modelos, lo que a su vez los hace comparables. Para esto se utiliza la matriz de confusión que se genera cruzando las predicciones generadas por el modelo con la variable de interés real.

		Valores Reales	
		Positivo (1)	Negativo (0)
Valores Predichos	Positivo (1)	VP	FP
	Negativo (0)	FN	VN

*Ilustración 9. Matriz de confusión. Elaboración propia.*

La Ilustración 9 muestra una matriz de confusión donde en eje X se ubican los valores reales y en el eje Y los valores predichos. Dentro del contexto de este trabajo se define como clase positiva 1 las fallas. Con esto, cuando la clasificación se hace correctamente para la clase positiva se denomina verdaderos positivos (TP, True Positive) y para la clase negativa son verdaderos negativos (TN, True Negative). En los casos cuando la predicción es errada existen dos casos: cuando existe una predicción negativa para un caso positivo, que se denomina falso negativo (FN, False Negative) y corresponde a cuando existe una falla que no es detectada. El segundo caso ocurre cuando la clase negativa se predice como positiva, esto corresponde a un falso positivo (FP, False Positive) y significa que se predijo una falla cuando en realidad la grúa seguiría funcionando de forma normal durante la ventana de predicción.

En conjuntos de datos clases desbalanceadas, comparar los modelos con la métrica Accuracy, que representa la cantidad de aciertos respecto al total, puede llevar a malos predictores, dado que los modelos pueden tender a predecir siempre un correcto funcionamiento (normal) lo que entregaría un Accuracy alto al considerar el desempeño general del clasificador.

Es por esto, que métricas como Recall y Precision son valiosas en estos análisis. Otra métrica útil es F1-Score que es una mezcla entre las dos mencionadas anteriormente para lograr un mejor balance de las predicciones [10]. Estas métricas se definen como:

$$Recall = \frac{TP}{TP + FN} \quad (8)$$

$$Precision = \frac{TP}{TP + FP} \quad (9)$$

$$F1 = \frac{2 \times Recall \times Precision}{Recall + Precision} \quad (10)$$

Con esto, las métricas seleccionadas para comparar los modelos serán Accuracy y F1-Score, de acuerdo a lo presentado en el trabajo de J. Leukel y otros [10] estas son métricas valiosas para medir el rendimiento en este tipo de tareas. Además, permite comparar los modelos de este trabajo no solo entre ellos sino también con modelos desarrollados en otros trabajos.

Ahora bien, con el objetivo de poder comparar los modelos con un foco en el negocio es que se utilizara el criterio de evaluación planteado en R. Prytz y otros [14] que permite transformar los resultados del modelo de clasificación en conjunto con los costos de inactividad de las máquinas en beneficio o pérdida para la empresa.

Como se mencionó en la sección 2.2.3. Costos de inactividad, se plantea que los beneficios de implementar modelos de predicción de falla se construyen con 3 componentes principales: la inversión, el beneficio de detectar una falla, es decir, un verdadero positivo (TP) y los costos de ejecutar un mantenimiento que no correspondía, un falso positivo (FP).

La primera componente, la inversión, corresponde a un monto fijo y que en desarrollo de este trabajo quedara indefino. Por lo que, los beneficios reportados representaran la cota superior de inversión a la que la empresa está dispuesta a invertir para implementar un modelo de predicción de falla. A modo de referencia, los autores en [14] estiman los costos de implementación en USD\$150.000 para el taller mecánico de camiones Volvo.

Los beneficios reportados por predecir una falla (TP) se definen como ECUR (extra cost of unplanned repair), mientras que los costos por realizar un mantenimiento que no corresponde son CPR (cost of planned repair). De esta forma el criterio de evaluación se define como:

$$Profit(TP, FP) = TP \times ECUR - FP \times CPR - Investment \quad (11)$$

También se introduce el termino CUR (cost of unplanned repair) y estos términos se pueden expandir de la siguiente forma:

$$CPR = C_{part}^P + C_{work}^P + C_{downtime}^P \quad (12)$$

$$CUR = C_{part}^U + C_{work}^U + C_{downtime}^U + C_{extra} \quad (13)$$

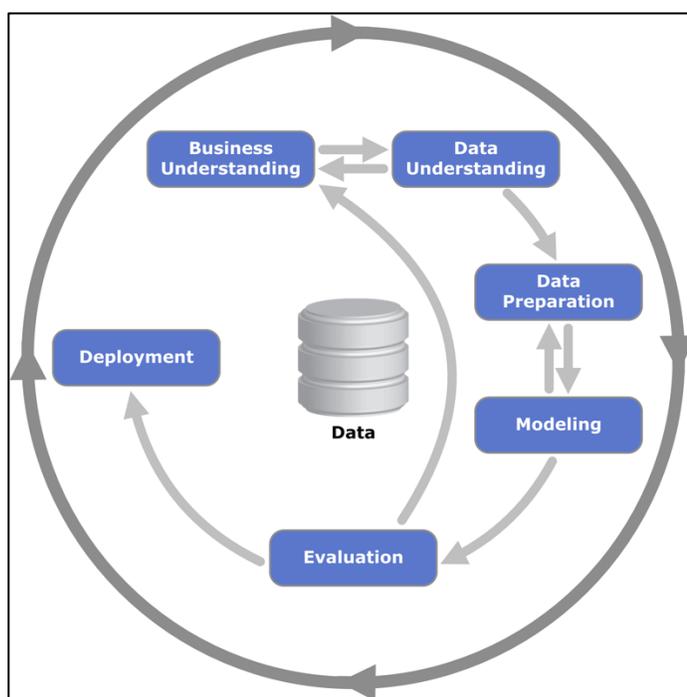
$$ECUR = CUR - CPR \quad (14)$$

Donde el superíndice P hace alusión a “Planned” y U para “Unplanned”, de esta forma, ECUR simboliza los costos extra que se incurre por mantenimientos no planificados. Nos referiremos a esta métrica de evaluación de los modelos como métrica económica o Profit.

## 3. Metodología

### 3.1. Metodología a utilizar

La metodología seleccionada a utilizar para el desarrollo de este proyecto es una modificación de CRISP-DM (Cross Industry Estándar Process for Data Mining), que proporciona una serie de pasos para el desarrollo de proyectos en ciencia de datos. En este caso, se modificará la fase 6, Implementación (Deployment) por temas de alcances del proyecto, excluyendo la implementación en productivo de los modelos y reemplazando esto con la entrega a la organización.



*Ilustración 10. Diagrama metodología CRISP-DM*

Por lo anterior, la metodología CRISP-DM propone 6 fases:

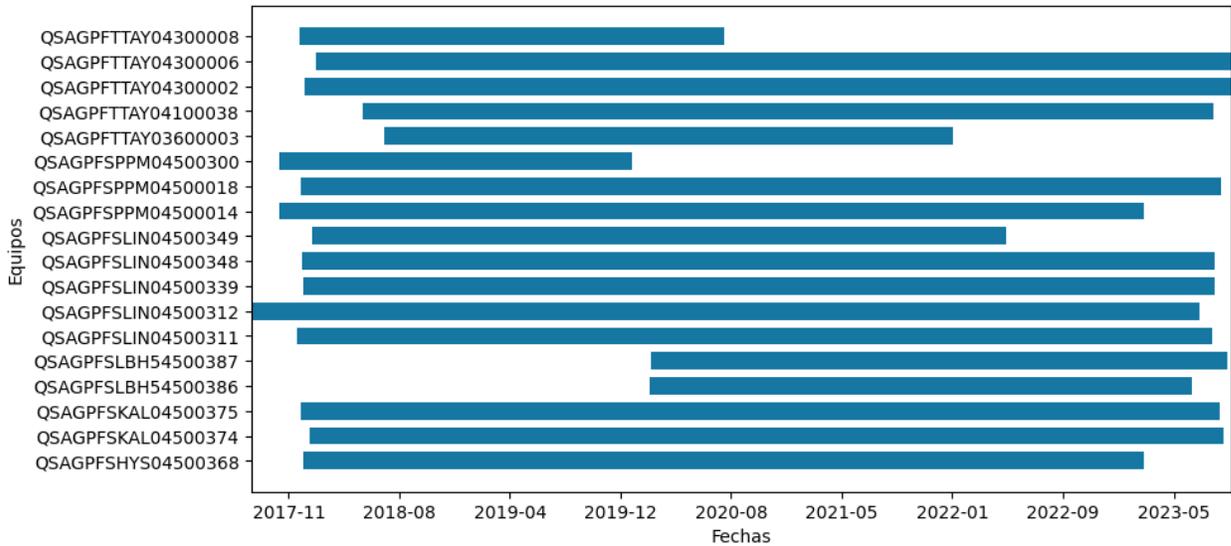
- 1 Fase 1: Comprensión del negocio que corresponde a la componente clave para seleccionar esta metodología por sobre otra. Como se mencionó dentro de los objetivos y los antecedentes, es fundamental poder conocer el costo de tiempo de inactividad, lo que permitirá poder medir de forma clara el resultado del proyecto. Además, se realizó una revisión bibliográfica para conocer el estado del arte de la predicción de falla.
- 2 Fase 2: Entendimiento de los datos. Corresponde a las primeras aproximaciones a los datos y la realización de los análisis iniciales. Para esto, se selecciona una fecha de inicio de los datos, comprendida desde el 2018 a mediados del 2023. Adicionalmente, en este paso se recopila el

resto de información que pueda ser relevante durante el mismo período, como volúmenes operacionales y costos asociados al área de equipos.

- 3 Fase 3: Preprocesamiento y preparación de la data. La información principal proviene de los mantenimientos realizados a las máquinas, lo que se obtiene de 2 tablas diferentes. Además, se obtiene la información de horómetros y contadores de movimientos, que hay que modificar para crear una sola base de datos entregable a un modelo de Machine Learning. En este paso de la metodología, se deberán usar algunas técnicas de feature engineering para crear nuevas variables de la base de datos y también, para agregar más información que pueda ser relevante como flujo de contenedores movilizados, etc. De la misma forma, se deberá trabajar con transformaciones como Bag of Features que permite utilizar información secuencial con modelo de Machine Learning tradicionales.
- 4 Fase 4: El Modelado consiste en crear y entrenar modelos de Machine Learning con los datos previamente trabajados.
- 5 Fase 5: Evaluación. Obtención de métricas relevantes para poder comparar el rendimiento de los modelos. Utilizando criterios propios de la ciencia de datos y del negocio.
- 6 Fase 6: Deployment consiste en analizar los resultados obtenidos de la mano con la empresa, para poder entregar un modelo funcional.

## **3.2. Extracción de datos**

Los datos a utilizar se componen principalmente de los reportes de mantenimiento de 23 GPC entre enero del año 2018 a septiembre del año 2023. Actualmente existen 16 grúas activas en la compañía, de las cuales 3 son arriendos y una incorporación nueva, por lo que, estas 4 máquinas no se consideran dentro del análisis. Además, durante la ventana de observación solo se utilizan los datos de las máquinas con al menos 40 registros de mantenimiento. Con estas consideraciones, durante la ventana de observación se tienen 18 máquinas, 10 con observaciones durante el período completo. Esto se puede observar en la Ilustración 11, donde se observa el intervalo de tiempo con registros de mantenimiento para las 18 máquinas (identificadas por su código ID).



*Ilustración 11. Intervalo de observación por máquina*

Los reportes de mantenimientos son 2: reporte de mantenimientos realizados y reporte de avisos. El reporte de mantenimientos realizados, ordenes de mantenimiento (reporte OM) indica las razones del mantenimiento, costos en repuestos asociado y su clasificación: correctivo, preventivo o mejoramiento. Por su parte, el reporte de avisos (reporte AV) contiene mayores detalles sobre los mantenimientos correctivos, como el tiempo de inactividad que presentó la máquina y una descripción detallada. Estos 2 reportes se obtienen desde el sistema transaccional de gestión de la empresa: SAP ERP. Estos reportes tienen como identificador único la orden de mantenimiento que permite en caso de ser un mantenimiento correctivo genera un aviso, con esto ambos reportes se pueden unir fácilmente. Tanto la orden de mantenimiento como el aviso son documentos de SAP que funcionan como identificadores únicos para estos documentos.

A partir del reporte OM con las máquinas seleccionadas se tiene un total de 3101 registros de los cuales 1318 corresponden a mantenimientos correctivos.

Adicional a esto, sobre el mismo período se tienen los horómetros o reporte HO. Los horómetros son cargados en SAP de forma semanal por el personal de mantención, quienes se encargan de subir el valor del contador que tienen las máquinas. El horómetro es un instrumento que registra el número de horas que el motor de una máquina esta encendido, de esta forma, para saber cuánto tiempo estuvo encendida la GPC entre dos mediciones consecutivas es necesario restar los valores del medidor. También, debido a que el contador de horas al llegar al máximo se reinicia SAP almacena el total de horas que representa la antigüedad de la máquina, esto se conoce como edad. Es importante mencionar esto, dado que si se suma el valor de los horómetros durante la ventana de observación difiere de la suma de las antigüedades de las grúas.

Para los casos donde el primer registro de horómetro era posterior a primer registro de mantenimiento; para las máquinas nuevas, es decir, que no existían al comienzo de la ventana de observación, se fijó el horómetro en 0 en la fecha de puesta en marcha. La puesta en marcha aparece en los registros de mantenimiento como un registro de mejoramiento. En el caso de máquinas que ya estaban en funcionamiento al comienzo de la ventana temporal, se buscó la información de último registro de horómetro previo al primer mantenimiento. En caso de no encontrar información al respecto, se calculó el promedio de horas diarias restando este valor al primer registro de

horómetro hasta coincidir la fecha con el primer mantenimiento. En la Tabla 11 del Anexo B se pueden observar las fechas del primer y último mantenimiento como también la fecha del primer y último registro de horómetro para cada máquina.

De forma similar, también se tienen los contadores de movimientos, que indica la cantidad de contenedores que la máquina movilizo. Cada máquina cuenta con 4 Twistlock (cierres de giro) en el Spreader, son las partes móviles que sujetan el contenedor, un movimiento representa el cierre y apertura de los Twistlocks. Estos se encuentran agregados de forma mensual a partir del año 2020, su registro se lleva de forma manual y solo en los terminales de la zona centro, es decir, solo se tiene registro de 13 de las 18 grúas.

Por último, se tienen los volúmenes operativos que presentaron los terminales durante el período de tiempo, en específico se cuenta con los registros de ingresos de contenedores en los diferentes terminales. Estos son extraídos de los sistema transaccionales y representan los únicos datos que no son capturados por el área de Equipos y Mantenición. Las variables más importantes del registro de ingresos son la fecha, tamaño del contenedor y peso bruto (peso del contenedor más la carga).

### 3.3. Preprocesamiento

La información relevante para este análisis proveniente de los mantenimientos es bastante reducida, por lo que esta sección es de real importancia para poder generar más variables para entregarle al modelo. Los registros de mantenimiento tiene como objetivo principal mantener el historial de intervenciones, reemplazo de partes, correcciones ,etc. La tarea principal con los registros es eliminar las columnas que no aportan información y asignar cada aviso a las órdenes de mantenimiento. En particular, las variables interesantes son la fecha y el tipo de mantenimiento, el equipo afectado, descripción (campo de texto con descripción corta mantenimiento) y la duración de parada en el caso de los mantenimientos correctivos.

Dentro de la definición de los tipos de mantenimiento, esta se identifica en el sistema como “Clase de Orden” y puede tomar los valores:

- PM01: Mantenimiento correctivos que no tienen asociados cambio de partes.
- PM02: Mantenimientos preventivos.
- PM03: Mantenimiento correctivos que requieren de cambio de partes.
- PM06: Mejoramientos, intervenciones programadas para agregar o mejorar una o más componentes de la grúa.

Con estas definiciones no se puede diferenciar entre mantenimientos correctivos causados por fallas por desgaste o daños, los daños son tiempos de inactividad causados por acción de terceros. Pueden ser golpes, choques y malas prácticas en general. Por lo que, se realizó una revisión manual de los registros de mantenimientos con la “Clase de Orden” y la descripción del registro para definir la columna “tipo” que diferencie los mantenimiento en Daños, Correctivos, Preventivos y Mejoramientos. Se utiliza el tipo de mantenimiento para definir el estado normal (clase 0: preventivo, daños y mejoramientos) o falla (clase 1: correctivo).

De forma similar a lo anterior, a partir de las descripciones de los mantenimientos, que corresponden a un campo de texto, se generó una variable categórica para indicar la causa del mantenimiento, esta hace referencia al sistema al que pertenece el componente. Se definió la variable como “Categoría” y consta de 9 valores posibles que se establecieron en conjunto con la opinión experta por parte de la empresa. A continuación se enlistan las diferentes categorías de mantenimiento:

- Tren Motriz: Motor, Transmisión y diferencial.
- Sistema Eléctrico
- Sistema Hidráulico
- Chasis
- Spreader
- Dirección
- Neumáticos
- Frenos
- General: Intervenciones que afectan más de un componente o sistema.

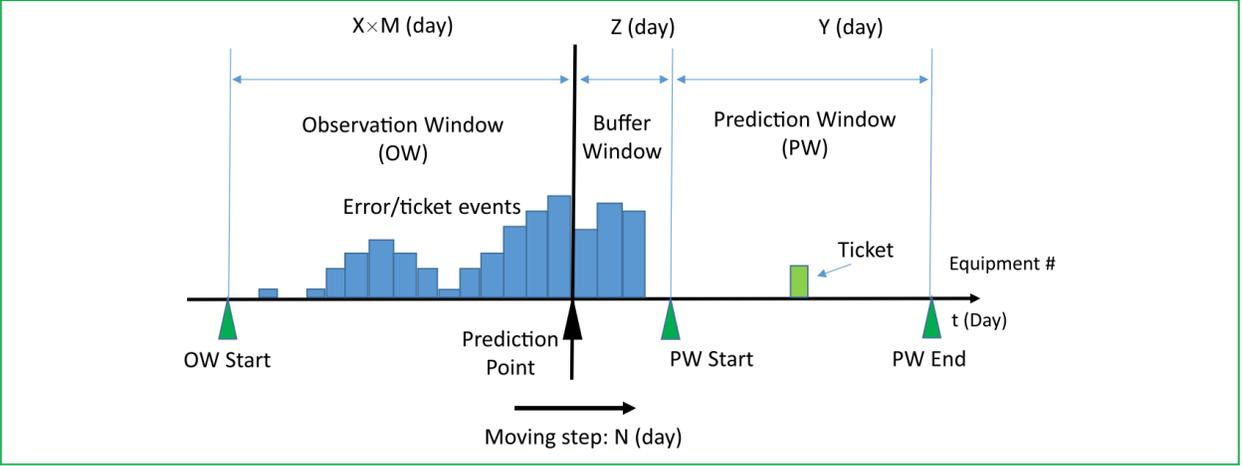
Con el fin de generar nuevas variables para agregar al dataset y estructurarlo para generar las instancias de entrenamiento y testeo, es que el preprocesamiento se divide en 3 partes: crear el dataset, generar las instancias y estandarización.

En la creación del dataset para agregar la información de los horómetros, se insertó la antigüedad de la máquina para cada registro en reporte HO indicando la fecha, código de la GPC y su antigüedad. A partir de esto, interpolando los valores se pueden obtener la antigüedad de la máquina al momento de los mantenimientos. Una vez con la antigüedad de la máquina en cada mantenimiento, se puede calcular fácilmente el horómetro de la máquina entre cada mantenimiento.

Para agregar la información de los movimientos se siguió el mismo procedimiento utilizando los movimientos acumulados, luego para obtener los movimientos durante el intervalo entre mantenimientos se resta el valor con su valor previo.

Por último, para incorporar los volúmenes operativos se utiliza un método diferente dado que los ingresos utilizados para las GPC del mismo terminal son iguales. De esta forma, el paso inicial es agrupar la información de los ingresos por fecha y terminal calculando la cantidad total de contenedores, cuantos de estos corresponden a contenedores de 40 pies y el peso total movilizado (suma). Con esto se aplica el proceso de interpolación no lineal ya descrito, pero diferenciando por terminal.

Es importante mencionar que se utiliza una interpolación que considera la diferencia de tamaño de los intervalos. Luego de generar todas las variables se deben generar las instancias de entrenamiento y prueba.



*Ilustración 12. Método de generación de instancias, ventana móvil. Extraído de (Wang J. 2017) [16]*

La Ilustración 12 presenta un diagrama general de la generación de instancias para poder entrenar un modelo. El punto de predicción (prediction point) representa el punto donde se realiza la clasificación, período  $t$ , hacia atrás del punto de predicción esta la ventana de observación (observation window) de largo  $M$ , también es conocida como sliding window dado que esta ventana son los registros que utilizamos para hacer la clasificación. Este movimiento de deslizamiento se conoce como step o lag que en la ilustración se representa con  $N$  y define principalmente cual es la superposición entre una instancia y otra. Hacia delante de punto de predicción existen dos zonas: buffer y ventana de predicción, de largos  $Z$  e  $Y$  respectivamente.

De los 4 parámetros definidos,  $N$  está definido en 1 para la generación de instancias, debido al tamaño del dataset, utilizar step mayores a 1 genera una disminución sustancial del número de instancias generadas. En segundo lugar  $Z$ , se considera 0, lo que significa que no existe buffer. Desde el punto de vista del negocio este trabajo busca la probabilidad de que la máquina sobreviva hasta su siguiente mantenimiento programado, que en promedio reciben 2 por mes. Extendiendo esta idea a partir del punto de vista del negocio, es que el valor para  $Y$  es definido por defecto en 15 días o en otros casos buscaremos predecir la clase del siguiente mantenimiento.

Este framework es aplicable a gran cantidad de máquinas de diferente índole y en casos donde el tiempo entre registro es pequeño no agrega gran valor predecir que un activo fallara dentro de pocos segundos, es por esto que dependiendo del caso el uso de buffers es recomendado, como ocurre al trabajar con máquinas con componente tecnológico importante en su funcionamiento, como datacenter en [17] o cajeros automáticos en [16]. En este caso, debido a que los tiempos de trabajo son en días y semanas no es necesario agregar un buffer

La gracia de poder definir valores de  $M$  e  $Y$  es que diferentes configuraciones genera que la función del modelo cambie. Si se define el valor de  $Y$  como 0 el problema deja de ser de pronóstico y se convierte en uno de diagnóstico, dado que se está generando la clasificación en el mismo período  $t$ . Por su parte,  $M$  controla los registros secuenciales que se entregaran al modelo, si  $M$  es igual a 1 no agrega información temporal a la clasificación. Para este trabajo se utilizaran instancias con  $M$  igual a 1, 3 y 8.

Las columnas del gráfico en la Ilustración 12 hacen referencia a los features en cada observación, en este caso refieren a las variables previamente creadas. De esta forma, con  $M$  mayores a 1 los datos representan una matriz  $X^{p \times M} = [x^{t-M}, \dots, x^t]$ , donde cada  $x^t = [x_1^t, \dots, x_p^t]$

y  $t=1, \dots, M$  es un vector  $p$ -dimensional de forma  $p \times 1$  donde  $p$  representa la cantidad de features generadas. Esta estructura se conocen como samples o instancias y son compatible para entrenar modelos LSTM ( $M=8$ ) y para modelos de ML tradicional para  $M > 1$  hay que aplicar métodos de preprocesamiento con técnicas basadas en feature engineering para agregar la información histórica.

Una táctica para evitar utilizar feature engineering es explotar la característica no secuencial de los modelos tradicionales de ML. Dado que estos modelos no consideran la temporalidad, se puede transformar la matriz a un vector de largo  $p \times M$ . Esta estrategia es utilizada por K. Chen [13] en su trabajo de predicción de falla de compresores de aire en camiones y es denominaremos Bag of Features como se mencionó en secciones anteriores. Es importante mencionar que no se incluyen en la “bolsa” el identificador de la máquina y la fecha, para estos valores se utilizan los que corresponden al registro que es el punto de predicción.

Por último, para entregar los datos a cualquier modelo se aplica Standar Scaler a las variables numéricas y OneHot Encoding a las variables categóricas (no se cuenta con variables categóricas ordinales).

## 4. Desarrollo

### 4.1. Procesamiento

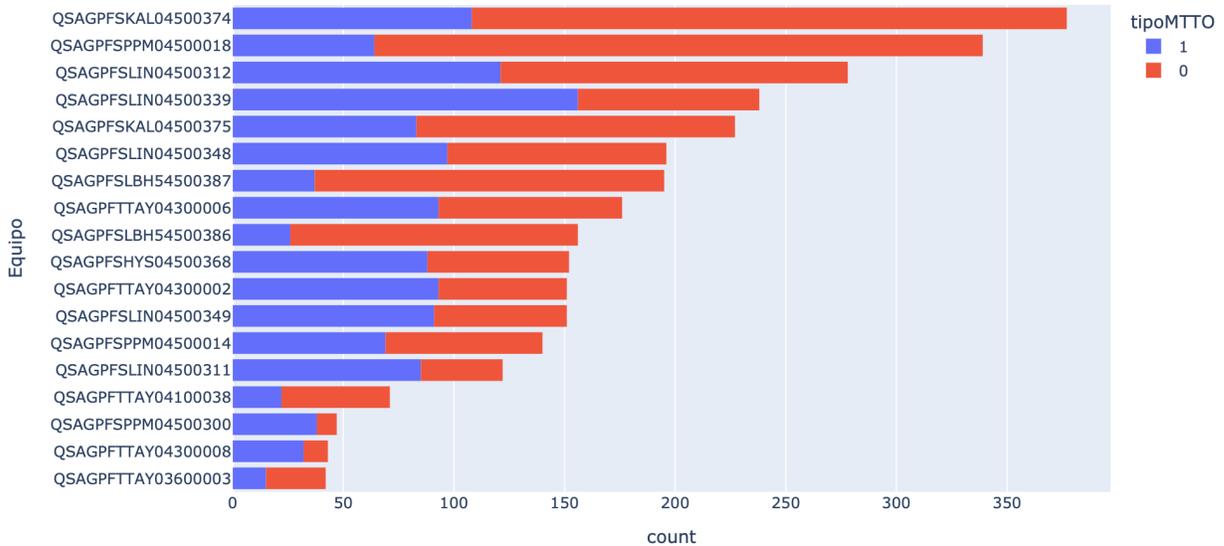
Siguiendo la metodología planteada en la Fase 3, se procedió a la construcción de dataset. Para esto, se aplicó la revisión manual con el fin de definir los campos tipo y categoría de mantenimiento. Los resultados se presentan en la Tabla 2.

En ella, se puede observar que la categoría General es la con mayor desbalance de clases entre mantenimientos y fallas, esto ocurre debido que las revisiones generales como: engrase, revisiones de puntos calientes, limpiezas generales, mantenimientos programados cada X horas de uso, entre otras, nunca van a corresponder a mantenimientos correctivos.

Categoría	Fallas	Mantenimiento	Total	Porcentaje
<b>Motriz</b>	269	573	842	31.9%
<b>Eléctrico</b>	257	108	365	70.4%
<b>Hidráulico</b>	310	107	417	74.3%
<b>Freno</b>	46	64	110	41.8%
<b>Spreader</b>	92	15	107	86.0%
<b>Chasis</b>	106	80	186	57.0%
<b>Neumáticos</b>	84	219	303	27.7%
<b>Dirección</b>	29	31	60	48.3%
<b>General</b>	29	682	711	4.1%

*Tabla 2. Registros por categoría.*

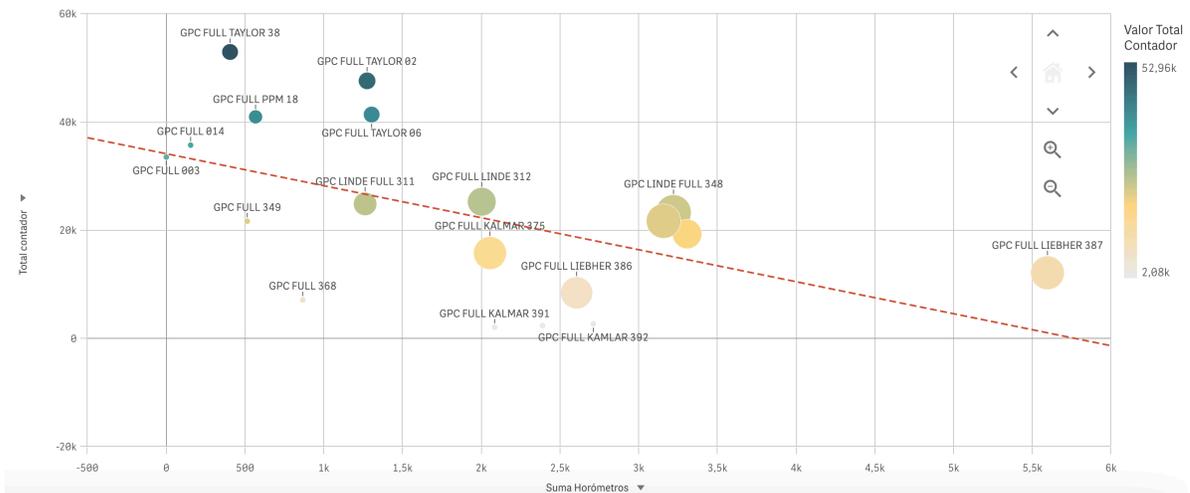
Luego se seleccionaron los registros de las 18 máquinas escogidas. La Ilustración 13 muestra los registros por GPC y la proporción de correctivos (Clase 1) vs normal (Clase 0).



**Ilustración 13. Registros por máquina**

Para generar los valores para antigüedad y movimientos, dado que la fecha de registro de estos datos no corresponde con los mantenimientos necesariamente, se realizó una interpolación utilizando como referencia la fecha del mantenimiento debido a la naturaleza eventual de los datos (intervalos de tiempo desiguales). Debido a que es necesario hacer la asignación por fecha y GPC, se trabajó los datos de cada equipo como un set de datos diferentes para luego volver a concatenar el dataset.

Con lo anterior realizado, se puede calcular la actividad durante el período, particularmente importante, por los intervalos desiguales. Debido a que esto refleja la actividad de la GPC durante el intervalo de tiempo en lugar de su antigüedad operativa. Las máquinas más antiguas son las con menores horómetros, esto se puede observar en la Ilustración 14 y responde a una desviación natural de los datos. El conocimiento experto explica esto debido a la mayor eficiencia y comodidad de las máquinas más modernas. Durante este proceso, se pierde el primer registro de cada GPC lo que reduce el conjunto de datos a 3083 registros con 1301 mantenimientos correctivos.



**Ilustración 14. Relación entre la antigüedad y horómetros con un ajuste lineal.**

Para incorporar información de los volúmenes operativos se realizó una agregación diaria y por terminal calculando la cantidad de contenedores ingresados, cuantos de estos contenedores son de 40 pies y la suma del peso bruto de los contenedores. Una vez generado estos datos se procedió a asignar los valores correspondientes a la fecha del mantenimiento como el valor entre intervalos.

Debido a que los datos de movimientos se tienen desde el 2020 en adelante y existen 3 GPC sin registros, esta columna cuenta con gran cantidad de nulos, para llenar los valores nulos se entrenó un modelo de regresión utilizando como features el horómetro, antigüedad, duración del tiempo de parada (asignando 0 a los mantenimiento preventivos, dado que esto no se considera tiempo de inactividad), ingreso de contenedores y suma sobre el peso. La variables de movimiento tenía un total de 1263 nulos. Los datos existentes se dividieron en entrenamiento y prueba con una proporción del 30%.

Se midió el rendimiento del regresor mediante la métrica R2, y se comparó LinearRegression, Lasso, Ridge, ElasticNet, LinearSVR, GradientBoostingRegressor y BaggingRegressor implementados en la librería Scikit-Learn. El modelo con mejor rendimiento fue GradientBoostingRegressor con R2 de 0.91 en el conjunto de prueba. Gradient Boosting es un método de ensamblaje aditivo de múltiples arboles de regresión. Finalmente, para generar los valores faltantes se aplicó una función ReLu sobre el regresor utilizando como valor el máximo entre la predicción y 0. Con el dataset completo la Ilustración 15 presenta una muestra de cómo se ve el set de datos:

Fecha	tipoMTTO	Tipo	Equipo	Categoria	DuracionParada	Edad	Horometro	Qcnt	peso	Mov	Equipo_Cod
2019-08-16	1	Correctivo	QSAGPFSLIN04500311	Electrico	8.00	21741.646154	83.923077	1118.0	1.691438e+07	1299.180745	5
2019-05-31	0	Preventivo	QSAGPFSLIN04500312	General	1.05	19286.082474	618.556701	1802.0	2.746492e+07	7644.094790	6
2018-05-28	0	Preventivo	QSAGPFSLIN04500348	Neumaticos	3.04	12802.806452	0.000000	0.0	0.000000e+00	47.042383	8
2021-04-26	0	Preventivo	QSAGPFKAL04500375	Chasis	0.00	12492.300000	350.385714	1323.0	1.589811e+07	5899.866667	2
2019-08-01	0	Preventivo	QSAGPFSLIN04500312	Motriz	0.00	19846.032653	0.000000	0.0	0.000000e+00	6.386657	6
2020-08-31	0	Preventivo	QSAGPFSLBH54500386	Motriz	4.01	1069.000000	0.000000	0.0	0.000000e+00	0.000000	3
2018-02-26	0	Daño	QSAGPFSLIN04500349	Chasis	24.00	9933.530303	13.484848	198.0	4.074059e+06	238.062296	9
2019-01-11	0	Daño	QSAGPFSLIN04500339	Chasis	73.00	14859.000000	0.000000	204.0	3.246292e+06	74.108019	7
2019-11-20	1	Correctivo	QSAGPFSPPM04500300	Chasis	0.00	38790.848000	82.600577	6182.0	8.884839e+07	267.506517	12

*Ilustración 15. Muestra del set de datos.*

A partir de esto, se utiliza el framework descrito en la sección 3.3. Para la generación de instancias modificando los valores de  $M$  e  $Y$ . Aplicar este proceso de generación de samples crea un tensor. Un tensor es un objeto matemático para almacenar valores bastante complejos, pero en Python los tensores son arreglos de 3 dimensiones, se puede entender fácilmente como un vector de matrices. Las dimensiones del tensor son la cantidad de instancias, el largo de la ventana de observación  $M$  y la cantidad features de cada observación (samples,  $M$ , features). Con esta estructura para  $M = 1$  cada matriz dentro del tensor corresponde a un único registro por lo que estructurar la data como tensor pierde sentido y es mejor estructurar los datos como una matriz de 2 dimensiones (instancias y features), pero aun así el framework definido es compatible con esta estructura.

De la mano con generar las instancias es necesario crear el etiquetado de cada una de las instancias para realizar el proceso de ajuste del modelo. Para esto, se utiliza la ventana de predicción  $Y$ , para cada registro de mantenimiento se etiqueta como clase 1 si dentro de los próximos  $Y$  días existe un mantenimiento correctivo. Con esto, el vector de etiquetas tiene de dimensiones la cantidad de instancias generadas y solo almacena el valor de la etiqueta (samples, 1) y este se denomina como target.

## 4.2. Modelos de clasificación tradicional

Los modelos descritos a continuación son implementados con la librería Scikit-learn de Python.

### 4.2.1. Modelo de diagnóstico

El primer modelo desarrollado corresponde a una aproximación del problema. Utilizando el set de parámetro ( $M = 1, Y = 0$ ) las instancias creadas no contienen datos secuenciales y se está realizando la clasificación en el mismo período que el punto de predicción. Es por esto que, este modelo está cumpliendo la función de diagnóstico. Con esta configuración el target es igual a la variable de tipo de mantenimiento. Con esta configuración se tienen un total de 3083 instancias donde 1208 corresponden a mantenimientos correctivos.

Se utiliza Random Forest como clasificador y se aplica el preprocesamiento mencionado en la sección 3.3. Preprocesamiento y se presenta Accuracy y F1-Score como métricas.

Para la implementación de Random Forest se utilizaron los parámetro por defecto de la librería Scikit-Learn: número de estimadores 100, criterio de calidad Gini, sin máximo de profundidad, mínimo de muestras para dividir un nodo interno de 2 y Bootstrap para generar las muestras de entrenamiento de cada estimador.

Este modelo representa la variación más simple que se puede crear con el framework propuesto y, de hecho, no cumple el objetivo propuesto de pronóstico. Sin importar lo anterior, este modelo entrega nociones de si es posible generar conocimiento mediando los datos utilizados.

### 4.2.2. Modelos de predicción a 15 días sin historia ( $M=1, Y=15$ )

Pasando a modelos que cumplen funciones de pronóstico, se implementó el set de parámetro ( $M = 1, Y = 15$ ), que corresponde a generar una predicción a 15 días sin incorporar información del estado anterior de la grúa. Esta configuración genera 3065 instancias con 1452 casos de falla.

Para este modelo se aplicó nuevamente Random Forest y el mismo set de variables que el modelo de diagnóstico, agregando la variable de estado del punto de predicción.

Este modelo al no incorporar información temporal del estado de la máquina y como estas evolucionan en el tiempo, la predicción que genera son poco intuitivas, dado que no se puede interpretar el rendimiento del modelo o conocer desde donde está adquiriendo conocimiento para ajustar de mejor forma los datos. En este sentido, este modelo se presenta al igual que el modelo de diagnóstico, como un modelo base para sentar un punto de partida.

### 4.2.3. Modelo de predicción con ventana de observación 3 ( $M=3, Y=15$ )

Para incorporar la ventana de observación se definen los parámetros ( $M = 3, Y = 15$ ). Con estos parámetros el conjunto de samples generado es de dimensiones (3024, 3, 32), con los datos previamente preprocesados. Utilizando la técnica Bag of Features queda un total de 69 features por registro y se tiene con esta configuración un total de 1432 casos de falla.

El modelo utilizado es AdaBoost y además se utiliza el selector de variables SelectPercentile seleccionando el 80% de las variables. Esta configuración demostró ser la con mejores resultados y es la arquitectura propuesta.

Para la implementación de AdaBoost se utilizaron los parámetros por defecto de la librería Scikit-Learn: se utiliza arboles de decisión como estimador base, número de estimadores 50, ratio de aprendizaje 1,0 y algoritmo de boosting SUMME.R.

Este modelo al incorporar la temporalidad en su análisis es relevante poder medir el efecto que este puede generar en la organización, de esta forma, para evaluar este modelo se utilizaran las métricas Accuracy, F1-Score y la métrica de evaluación económica Profit.

### 4.2.4. Modelo de predicción con ventana de observación 8 ( $M=8, Y=15$ )

La última configuración de parámetros para modelos tradicionales de ML es con una ventana de observación de 8 mantenimientos ( $M = 8, Y = 15$ ). El conjunto de samples es de dimensiones (2921, 8, 32) y existen 1371 samples etiquetados como fallas.

Utilizando Bag of Features se generan 149 features y la arquitectura planteada utiliza SelectPercentile al 80% con el clasificador Random Forest.

Al igual que el modelo anterior, se presenta el rendimiento de Accuracy, F1-Score y el Profit obtenido.

## 4.3. Modelo de Deep Learning

Para el modelo de Deep Learning se utiliza el mismo set de samples generados con la configuración ( $M = 8, Y = 15$ ). Esto corresponde a un tensor de dimensiones (2921, 8, 32) y un vector de etiquetas (2921, 1), donde existen 1371 casos de clase 1.

El modelo a utilizar es una red LSTM, implementado en la librería Keras y a continuación se describe la arquitectura propuesta:

- Capa LSTM de 16 unidades.
- DropOut de 20%
- Capa LSTM de 16 unidades
- DropOut de 20%
- Capa Densa con una unidad y función de activación *tanh*.

Como función de pérdida se utiliza binary crossentropy, Adam de optimizador y learning rate de 0,001. Adicionalmente, se calculan las métricas Accuracy y F1-Score durante el entrenamiento. La Ilustración 16 muestra el diagrama general de la arquitectura de la red, la cual cuenta con 5265 parámetros.

Layer (type)	Output Shape	Param #
lstm_255 (LSTM)	(None, 8, 16)	3,136
dropout_214 (Dropout)	(None, 8, 16)	0
lstm_256 (LSTM)	(None, 16)	2,112
dropout_215 (Dropout)	(None, 16)	0
dense_151 (Dense)	(None, 1)	17

**Total params: 5,265 (20.57 KB)**  
**Trainable params: 5,265 (20.57 KB)**  
**Non-trainable params: 0 (0.00 B)**

*Ilustración 16. Resumen arquitectura LSTM*

En cuanto a entrenamiento, se utilizan 40 épocas y se define un EarlyStop que monitorea la pérdida. Se define un tamaño de batch de 64, se utiliza un 15% de los datos para validación y otro 15% para prueba. Para evaluar el rendimiento se utiliza el Accuracy, F1-Score y Profit.

#### 4.4. Cálculo de costo de inactividad para evaluación

El objetivo de esta sección es calcular ECUR y CPR para poder utilizar la ecuación ( 11) para esto necesitamos el valor de  $C_{part}^P$  y  $C_{part}^U$ , que simboliza el costo en partes para las mantenciones. Este se obtiene directamente del reporte OM. Para  $C_{part}^U$  que representa los costos de partes en mantenimientos no planeados, es decir, fallas, se utiliza el costo promedio reportado en repuestos que es USD \$735, mientras que para  $C_{part}^P$  se considera el costo de los mantenimientos preventivos y mejoramientos que tienen un costo promedio de USD \$378.

Para el costo de  $C_{work}$ ,  $C_{downtime}$  y  $C_{extra}$  se necesita información adicional, en específico para  $C_{work}$ , que hace relación a los costos de la mano de obra para realizar las reparaciones y mantenciones, se utilizaron los costos de área de Equipos y Mantenición. Se seleccionaron los centros de costos asociados a las grúas portacontenedores y las cuentas específicas relacionadas al trabajo del personal y mano de obra de mantención y se agrupo de forma mensual para calcular un costo promedio mensual de la mano de obra y para obtener el costo de mano de obra promedio de un mantenimiento se dividió en la cantidad de mantenimientos promedio mensuales. Esto entrega que  $C_{work}$  es aproximadamente USD \$324 por mantenimiento. A diferencia de lo planteado por R. Prytz y otros [14], en este caso  $C_{work}^P$  y  $C_{work}^U$  se consideran iguales dado que no representan tiempos de trabajo para el personal diferentes y el hecho que genera que los tiempos de inactividad de mantenimientos correctivos sea mayor a los preventivos es la espera de repuestos y ese costo esta capturado en  $C_{downtime}$  y  $C_{extra}$ .

Los autores definen  $C_{downtime}$  y  $C_{extra}$  como los costos fijos asociados a tiempo de inactividad y costos esporádicos que puedan ocurrir por demoras de diferentes causas respectivamente. En el caso de este trabajo,  $C_{downtime}$  y  $C_{extra}$  capturan los costos de oportunidad de no poder satisfacer la demanda. Al igual que en el paper  $C_{downtime}^P$  se considera 0 dado que los mantenimientos preventivos son programados, por lo que no se considera como tiempo de inactividad. Por otro lado, para calcular  $C_{downtime}^U$  el promedio de tiempo de inactividad por el ingreso promedio que una máquina genera por hora:

$$C_{downtime}^U = T \text{ prom Parada} * \text{Ingreso prom} \quad (15)$$

A su vez, el ingreso promedio de una máquina por hora se puede calcular como el promedio del ingreso por servicio por el promedio de servicios que realiza una máquina en una hora:

$$C_{downtime}^U = T \text{ prom Parada} * (\text{Ingreso por Servicio} * \text{Tasa Servicios/Hora}) \quad (16)$$

Esta información se puede extraer del consolidado de servicios facturados, el ingreso por servicio corresponde al promedio del valor neto de las facturas emitidas considerando solo los servicios que involucren el uso de las GPC, para definir estos servicios se utilizó las tarifas públicas del terminal extraportuario que se puede ver en el Anexo C.

Para la tasa de servicios por hora, se calculó el número de servicios diarios y se dividió en una jornada laboral de 10 horas, este valor a su vez se divide en la cantidad de GPC del terminal. Para realizar estos cálculos se utilizaron los valores pertenecientes al terminal extraportuario de Valparaíso. Con todas estas consideraciones se tiene que el tiempo de parada promedio es de 35,68 horas, el ingreso por servicio es de USD \$ 343 y la tasa de servicios por hora para una máquina es de 0,87, lo que entrega un  $C_{downtime}^U$  de USD \$10.672 que representa el costo de oportunidad por servicios no realizado.

Reemplazando en las ecuaciones ( 12), ( 13) y ( 14) se obtiene que CPR es igual a USD \$702, CUR es USD \$11.731 y ECUR es igual a USD \$11.029. Por lo que la ecuación ( 11) queda de la siguiente forma:

$$Profit(TP, FP) = TP \times \$11.029 - FP \times \$702 \quad (17)$$

Esto permite evaluar fácilmente los modelos a partir de la matriz de confusión que generan.

## 5. Resultados

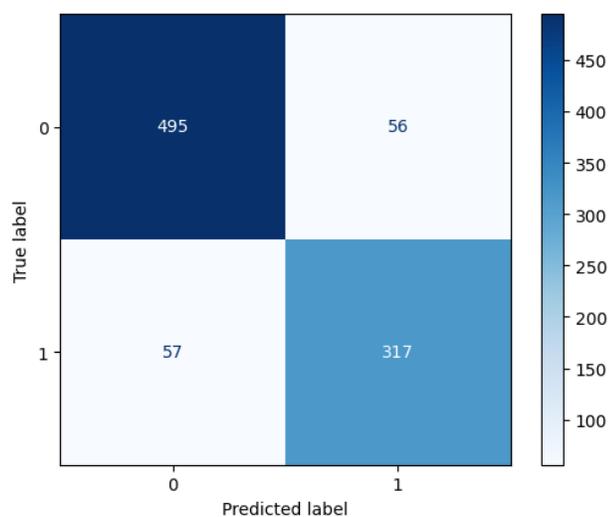
A continuación, se presentan los resultados obtenidos para los modelos planteados en la sección anterior.

### 5.1. Resultados de modelos de clasificación tradicional

#### 5.1.1. Resultado modelo de diagnóstico

Para la implementación de este clasificador se utilizó Random Forest con los parámetros por defecto de la implementación de Scikit-Learn y las instancias se generaron con el set de parámetro ( $M = 1, Y = 0$ ), por lo que, la clasificación se está realizando sobre el mismo período y esto cumple la función de diagnóstico.

Con esta configuración, se entrenó el modelo con el 70% de las instancias generadas y se utilizó el 30% restante para prueba. La Ilustración 17, presenta la matriz de confusión del modelo:



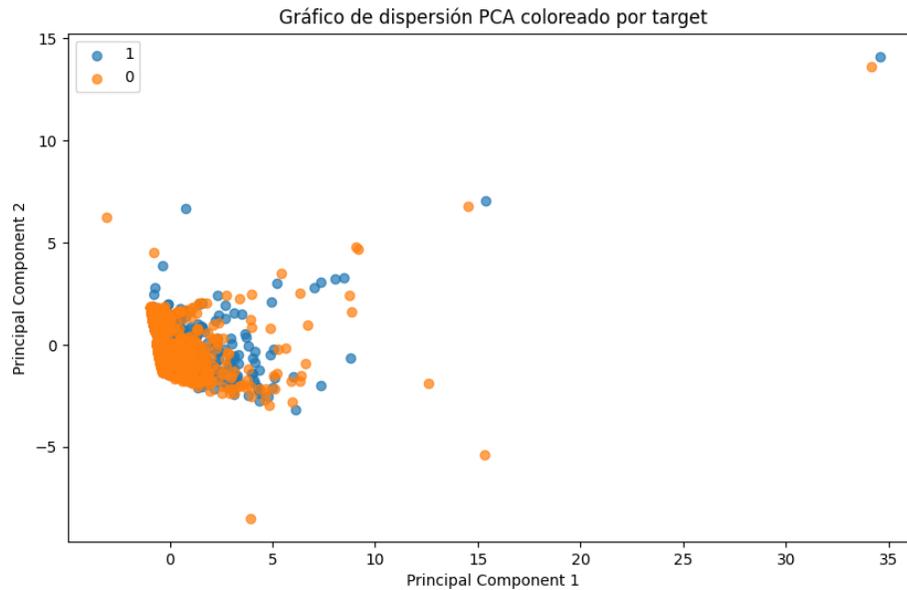
*Ilustración 17. Matriz de confusión, modelo de diagnóstico.*

Con la matriz de confusión de pueden calcular las métricas que se presentan en la Tabla 3:

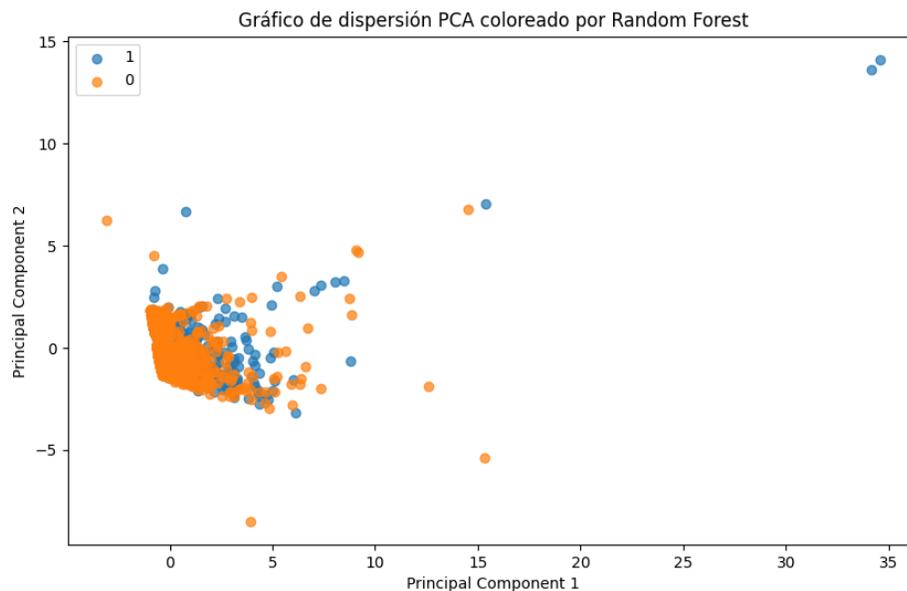
Métrica	Valor
Accuracy	0,88
F1-Score	0,87

*Tabla 3. Métricas de evaluación, modelo diagnóstico.*

Para observar el comportamiento de las clases generadas por el modelo, las siguientes ilustraciones presentan mediante Principal Component Analysis (PCA) la comparación de las etiquetas reales (Ilustración 18) y las generadas por el modelo, esto se muestra en la Ilustración 19.



*Ilustración 18. PCA con etiquetas reales (target), modelo de diagnóstico.*

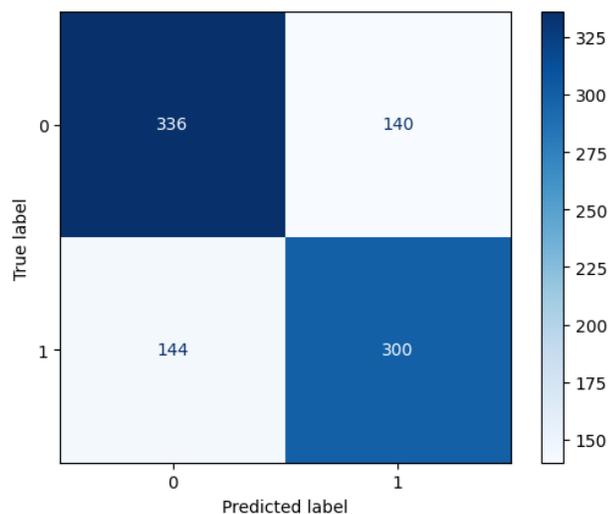


*Ilustración 19. PCA con etiquetas predichas con Random Forest, modelo de diagnóstico.*

### 5.1.2. Resultado modelo de predicción a 15 días sin historia (M=1, Y=15)

Para este modelo nuevamente se utilizó la configuración por defecto de Random Forest, generando las instancias con el set de parámetros ( $M = 1, Y = 15$ ). De esta forma, el modelo se entrena para clasificar un estado de falla en los próximos 15 días y se agrega el estado actual de la máquina como una nueva variable. Se aplicó una separación de entrenamiento y prueba de 70/30%.

A partir de esto, la Ilustración 20 presenta la matriz de confusión generada y las métricas de rendimiento se muestran en la Tabla 4.

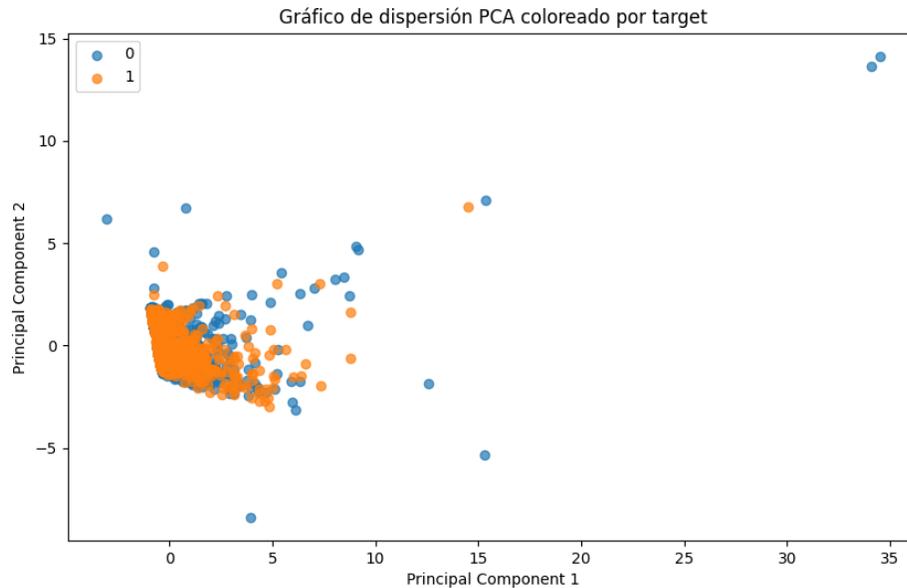


*Ilustración 20. Matriz de confusión, modelo (M=1, Y=15).*

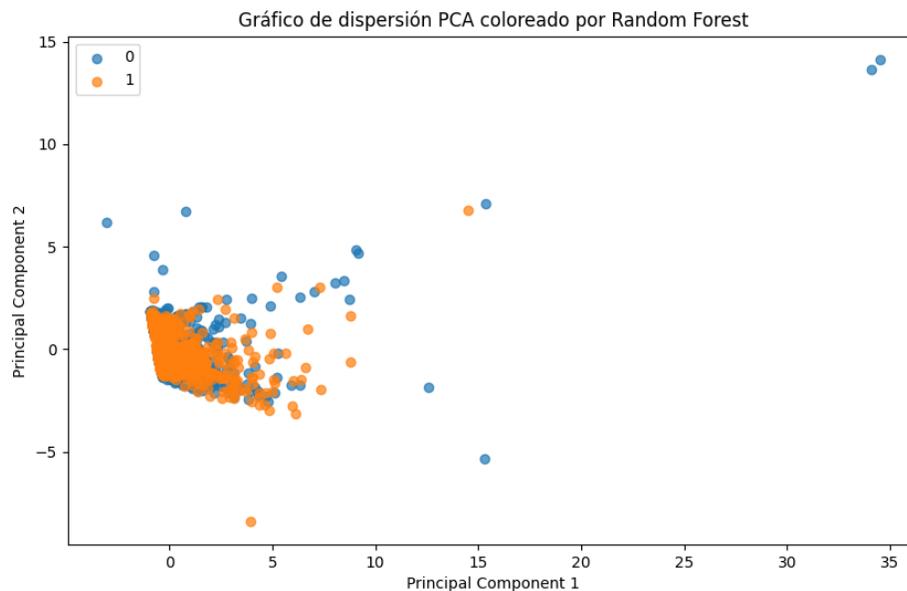
Métrica	Valor
Accuracy	0,69
F1-Score	0,69

*Tabla 4. Métricas de evaluación, modelo (M=1, Y=15).*

A continuación, se presentan los resultados del etiquetado utilizando PCA, la Ilustración 21 muestra los valores reales del target y la Ilustración 22 presenta las etiquetas entregadas por el clasificador.



*Ilustración 21. PCA con etiquetas reales (target), modelo (M=1, Y=15).*

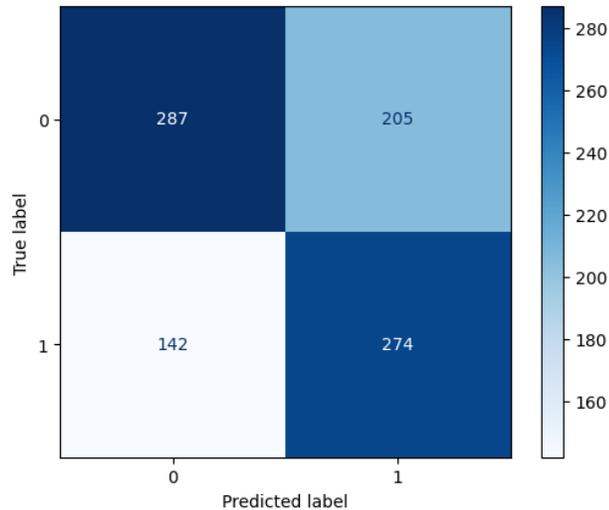


*Ilustración 22. PCA con etiquetas predichas con Random Forest, modelo (M=1, Y=15).*

### 5.1.3. Resultado modelo de predicción con ventana observación 3 (M=3, Y=15)

El modelo utilizado en esta configuración es AdaBoost con SelectionPercentile del 80% y función de puntaje f-classif. Al aplicar Bag of Features a la ventana de observación de 3 periodos, se obtiene un total de 89 columnas que ingresan al pipeline del modelo. Los parámetros seleccionados para presentar los resultados son los que obtuvieron mejores resultados en una grilla de búsqueda con diferentes clasificadores y valores posibles para SelectionPercentile.

Utilizando el 70% de los datos para entrenar el modelo, la Ilustración 23 presenta la matriz de confusión obtenida en el conjunto de prueba:



*Ilustración 23. Matriz de confusión, modelo (M=3, Y=15).*

Las métricas de evaluación en el conjunto de prueba se presentan continuación en la Tabla 5:

Métrica	Valor
Accuracy	0,62
F1-Score	0,62

*Tabla 5. Métricas de evaluación, modelo (M=3, Y=15).*

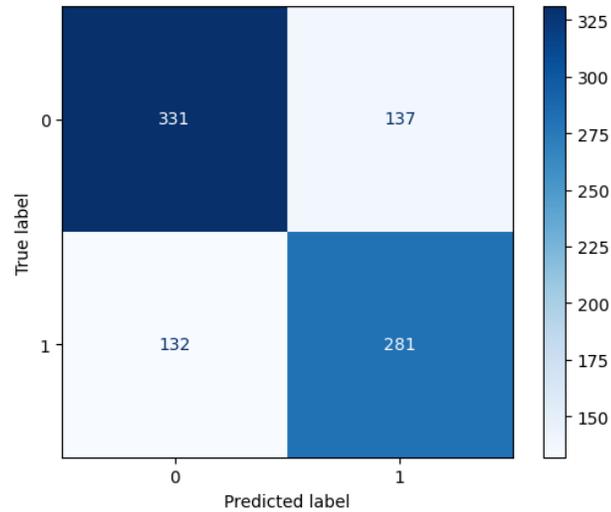
Respecto al Profit, se utiliza la ecuación ( 17) para realizar el cálculo:

$$Profit(TP, FP) = (TP = 274) \times \$11.029 - (FP = 205) \times \$702 = \$2.878.114 \quad (18)$$

#### 5.1.4. Resultado modelo de predicción con ventana observación 8 (M=8, Y=15)

De forma similar al modelo anterior, se emplea una grilla de búsqueda y el clasificador con mejor rendimiento encontrado fue Random Forest con SelectionPercentile al 80% y función de puntaje f-classif. Con la ventana de observación de 8 registros al aplicar Bag of Features resulta en 149 variables y al igual que los casos anteriores se utilizó el 70% de los datos para entrenar y 30% para prueba.

La Ilustración 24 expone la matriz de confusión generada con el dataset de prueba y la Tabla 6 presenta las métricas obtenidas.



*Ilustración 24. Matriz de confusión, modelo (M=8,Y=15).*

Métrica	Valor
Accuracy	0,70
F1-Score	0,70

*Tabla 6. Métricas de evaluación, modelo (M=8,Y=15).*

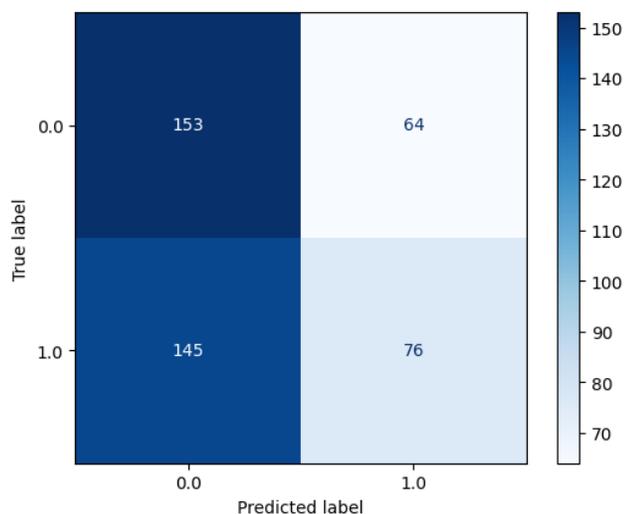
Desde la matriz de confusión se obtiene que TP son 281 y FP 137, reemplazando para obtener el Profit se obtiene:

$$Profit(TP, FP) = (TP = 281) \times \$11.029 - (FP = 137) \times \$702 = \$3.003.055 \quad (19)$$

## 5.2. Resultado LSTM

Para la red LSTM se utiliza la misma ventana temporal de 8 observación de largo, se dejó el 70% de los datos para entrenamiento, 15% para validación y 15% para prueba. El modelo entrena 5 épocas antes de detenerse debido al EarlyStop definido, alcanzando un Accuracy de 0,52 y F1-Score de 0,63 en el conjunto de entrenamiento.

La Ilustración 25 muestra la matriz de confusión generada en el conjunto de prueba:



*Ilustración 25. Matriz de confusión, modelo LSTM.*

De la misma forma, la Tabla 7 muestra las métricas obtenidas por la red en el conjunto de prueba:

Métrica	Valor
Accuracy	0,52
F1-Score	0,50

*Tabla 7. Métricas de entrenamiento, LSTM.*

En cuanto al Profit reportado, este se calcula como:

$$Profit(TP, FP) = (TP = 76) \times \$11.029 - (FP = 64) \times \$702 = \$793.298 \quad (20)$$

### 5.3. Comparación y discusión

La Tabla 8 resume los resultados obtenidos para los modelos de clasificación de ocurrencia de falla con una ventana de predicción de 15 días y que consideran una ventana observación.

Modelo	Accuracy	F1-Score
AdaBoost(M=3,Y=15)	0,62	0,62
RandomForest(M=8,Y=15)	0,70	0,70
LSTM(M=8,Y=15)	0,52	0,50

*Tabla 8. Resumen de resultados.*

En cuanto al Profit(TP,FP) reportado no es correcto comparar el resultado obtenido de los clasificadores tradicionales con la red LSTM. Debido a que se calculó el rendimiento en el conjunto de prueba y este conjunto en la red LSTM es de menor tamaño, lo que genera valores de TP y FP menores sin importar que tan buen ajuste esté realizando el modelo.

Por cómo es propuesto el cálculo de Profit, la relación entre TP y FP es fundamental, la Tabla 9 presenta razón entre estos valores, donde lo ideal es un ratio mayor.

Modelo	TP	FP	Ratio (TP/FP)
AdaBoost (M=3,Y=15)	274	205	1,34
RandomForest (M=8,Y=15)	281	137	2,05
LSTM (M=8,Y=15)	76	64	1,19

Tabla 9. Razón entre TP y FP.

Ahora bien, para poder utilizar Profit como métrica de comparación, se generaron predicciones para todas las instancias con los modelos ya entrenados, esto indica qué fallas podrían haber sido previstas en el caso de que los modelos hubieran estado funcionando.

La Ilustración 26 muestra lado a lado las matrices de confusión obtenidas con el dataset completo para los 3 modelos.

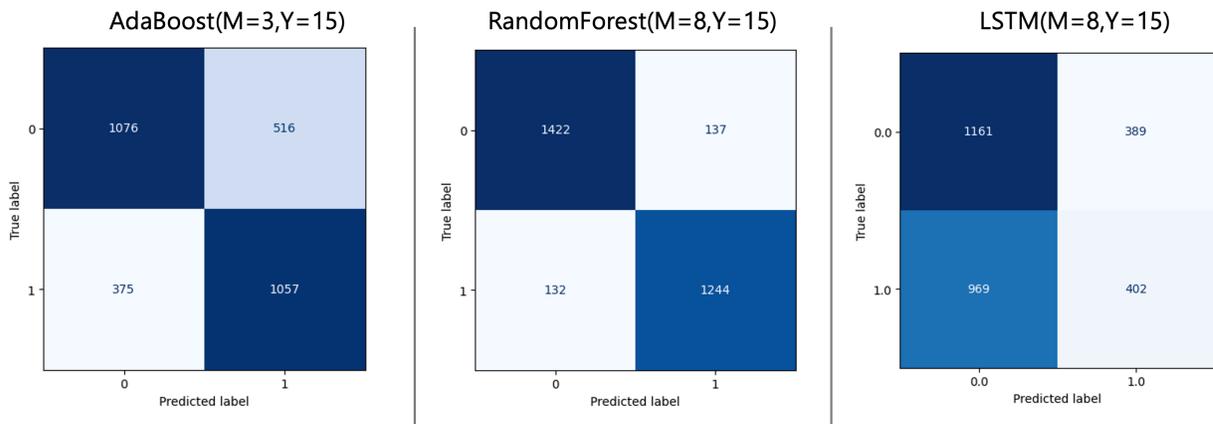


Ilustración 26. Comparación matrices de confusión para el total de instancias.

Con esto se calcula el Profit, que se presenta en la Tabla 10.

Modelo	TP	FP	Profit(TP,FP)
AdaBoost (M=3,Y=15)	1057	516	\$11.295.724
RandomForest (M=8,Y=15)	1244	137	\$13.624.258
LSTM (M=8,Y=15)	402	389	\$4.160.695

Tabla 10. Profit calculado para los modelos.

Comenzando con mencionar que el modelo de diagnóstico, con Accuracy de 0,88 y F1-Score de 0,87, como muestra la Tabla 3, presenta un buen desempeño clasificando el estado de la máquina, pero como se mencionó antes, este modelo no cumple con el objetivo de pronóstico buscado, realizando un diagnóstico del estado actual. A pesar de esto, entrega buenos indicios de que un modelo de Machine Learning puede extraer conocimiento sobre el estado de la máquina a partir de los datos utilizados.

En cuanto al modelo RandomForest (M=1, Y=15), presenta un Accuracy y F1-Score ambos de 0,69. A partir de la Ilustración 21, con la visualización de PCA se puede observar que llevar los registros de mantenimientos a un espacio bivariado no presenta cluster visuales. Respecto a este modelo, como el modelo de diagnóstico, al no incorporar información temporal o predecir hacia el futuro son modelos de naturaleza diferente, pero que igualmente entregan un buen precedente para los modelos siguientes.

De esta forma, al comparar los 3 modelos presentados en la Tabla 8, se observa que RandomForest (M=8, Y=15) es el modelo con mejor rendimiento con un Accuracy y F1-Score de 0,70. También, presenta el mejor ratio TP/FP de 2,05 en el conjunto de prueba (Tabla 9) y mayor Profit, generando USD \$13.624.258 con 1244 aciertos y 137 falsas alarmas.

Respecto de la Ilustración 26, RandomForest (M=8, Y=15) es el modelo que presenta la matriz mejor distribuida respecto a la diagonal. En el caso AdaBoost (M=3, Y=15) se observan más FP, lo que llevaría a un predictor que provoca realizar más mantenimientos preventivos de los necesarios y la red LSTM (M=8, Y=15) clasifica de forma desbalanceada, etiquetando la gran mayoría de instancias como funcionamiento normal (clase 0) y, aun cuando predice una falla, al tener el ratio TP/FP más pequeño, también genera errores de clasificación.

Con el comportamiento observado con AdaBoost (M=3, Y=15) y RandomForest (M=8, Y=15) se puede observar que incorporar más historia del estado de la máquina ayuda en la predicción. Sin embargo, al observar el rendimiento de la red LSTM, es el modelo con peores métricas, aun cuando estos modelos están diseñados para analizar datos con esta estructura. Es importante mencionar, que 2921 samples es un número pequeño para los órdenes de magnitud con que los modelos de aprendizaje profundo son entrenados normalmente.

En base a todo lo anterior, RandomForest (M=8, Y=15) ha demostrado tener un mejor rendimiento en cada uno de los criterios de comparación, por lo que, es el modelo propuesto para responder al objetivo general. De esta forma, el modelo debe generar una predicción cada vez que una GPC salga del taller con el objetivo de ver si la máquina tendrá una falla antes del siguiente mantenimiento preventivo. Para esto se deben utilizar los 7 mantenimientos previos de la máquina más el mantenimiento actual donde se está generando la predicción.

## 6. Conclusiones

Utilizar técnicas de Ciencia de Datos es cada vez más común en problemas de PHM. El mantenimiento predictivo corresponde al enfoque de mantenimiento más eficiente en cuanto a tiempos y costos, pero a la vez, es el más complejo de llevar a cabo. La continua implementación de técnicas de CBM en entornos productivos acelerará rápidamente el desarrollo del mantenimiento predictivo, que hoy en día, sigue siendo un área de desarrollo mayormente ligada a la investigación.

En particular, la predicción de falla en base a registros de mantenimientos en activos móviles, en este caso de grúas portacontenedores, es un dominio particularmente difícil e incluso en la literatura se plantea este problema [14]. Lo anterior, debido a la dificultad de ejecutar un monitoreo constante de las GPC y la naturaleza de los datos, donde los registros de mantenimientos no están diseñados para ser parte de este tipo de análisis, pero aun así son ampliamente encontrados en la industria.

Es por esto que, este trabajo utiliza información adicional relacionada al trabajo de las GPC para construir un set de datos con el cual se puedan predecir fallas. La metodología propuesta es una pieza fundamental del trabajo, la que permite generar un set de datos y luego las muestras (samples) necesarias para ser analizadas por un modelo de Machine Learning.

El modelo propuesto es capaz entonces de cumplir su objetivo utilizando el clasificador Random Forest, con una ventana de observación de 8 mantenimientos y una ventana de predicción de 15 días. El modelo es capaz de predecir un funcionamiento normal o si existirá una falla dentro de la ventana de predicción. Además, el uso de la técnica Bag of Features para la generación de rezagos es exitosa, dado que aumentar la ventana de observación mejora las predicciones.

Si bien el modelo propuesto es RandomForest ( $M=8$ ,  $Y=15$ ), no se descarta la red LSTM debido a la naturaleza de los datos. Las redes de estas características están diseñadas para trabajar datos de esta estructura y, es debido a eso, que son ampliamente utilizadas en este tipo de tareas. A modo de conclusión respecto a este modelo, el bajo rendimiento de la red se le atribuye a la baja cantidad de muestras, lo que no permite entrenar el modelo de forma correcta, lo cual se respalda con el hecho de que el modelo nunca terminó su entrenamiento y era detenido por la detención temprana para evitar el sobreajuste.

En cuanto a la métrica Profit planteada, permite cuantificar de forma rápida y sencilla los resultados obtenidos por los modelos, sin embargo, este valor se debe considerar con cautela. No se descarta estar sobreestimando o subestimando los costos, pero a pesar de esto, por la manera en que es planteada, es robusta a los ajustes, dado que el costo de oportunidad siempre agregará una diferencia positiva a favor de predecir una falla. De la mano con esto, que el modelo planteado tenga un ratio TP/FP mayor a 2, también robustece la viabilidad económica del modelo, debido a que genera más aciertos que falsas alarmas.

### Trabajo Futuro

El desafío principal para el futuro es explorar la sensibilidad de los modelos a cambios en la ventana de observación y predicción. Con ventanas de observación más extensas, es esperable que Bag of Features baje su rendimiento, dado que se generaría demasiadas variables y podría

comenzar a ingresar ruido a los modelos. En esta situación es donde la red LSTM es especialmente importante, debido a que no se enfrentaría a estos problemas. Además, en el desarrollo no se experimentó con ventanas de observación mayores, ya que con el aumento de  $M$ , la cantidad de samples generados es cada vez menor y, la cantidad de samples generados, ya representaba un problema al momento de entrenar la red LSTM.

Por otra parte, sería interesante ver el efecto de aumentar la ventana de predicción y cómo esto afecta al rendimiento de los modelos y el Profit. En el trabajo realizado por R. Prytz y Otros [14] del año 2015, se presenta que los modelos bajan su rendimiento en Accuracy y F1-Score cuando la ventana de predicción es mayor, pero el Profit reportado aumenta. Lo que plantea, que para proponer ventanas de tiempo ideales se deben considerar otras variables, como la funcionalidad de una predicción para los equipos de mantenimiento de la empresa. Es por esto que, en este trabajo se utilizó una ventana de predicción de 15 días, número que representa el tiempo promedio entre mantenimientos y entrega la holgura necesaria para adaptar la planificación. De esta forma, resulta interesante comparar el rendimiento de los modelos con una ventana de predicción de 20 y 30 días, pero ventanas de predicción mayores no desencadenarían acciones reales por parte del equipo de mantención.

Por último, se propone como proyección de trabajo futuro el focalizar el modelo a un componente en específico, para esto se propone utilizar la columna categoría creada. El tren motriz es la categoría de mantenimiento con más intervenciones realizadas con un total de 842, mientras que el Spreader tiene el porcentaje de mantenimientos correctivos más alto con 86%. El sistema hidráulico por ejemplo, es la segunda categoría con más mantenimientos con un total de 417 registros y un porcentaje de fallas del 74%. Elegir una de estas categorías para realizar predicciones de falla específicas a ella generaría mayor valor para el área de Equipos y Mantención, pero las muestras son muy pequeñas y se generarían problemas de desbalance de clases.

## **Recomendaciones**

Entre las recomendaciones dada a la compañía, la principal consiste en estandarizar el ingreso de información al momento de los mantenimientos, como incorporar el contador de movimientos y horómetro de la máquina al momento de su detención en las fichas de mantenimientos disponibles en el sistema, esto facilitaría la construcción del dataset dado que entregaría el mismo nivel de granularidad a los datos.

La segunda recomendación corresponde a diferenciar los mantenimientos correctivos de los daños, puesto que los daños ocurren de forma esporádica y no es posible predecir un evento de estas características. Pero si representan una entrada dentro del conjunto de datos, aportando información sobre el estado y carga operativa de la máquina en ese momento.

Se recomienda implementar arquitectura tecnológica sobre las GPC. Las máquinas tienen gran cantidad de sensores, principalmente en el sistema hidráulico y el tren motriz. Esta información podría ser realmente valiosa para el uso de técnicas de PHM, como CBM y mejoras en modelos de mantenimiento predictivo. Los sensores sobre las máquinas generan avisos en la interfaz del conductor, pero esta información no puede ser extraída fácilmente y no es almacenada.

Por último, relacionado con la implementación de arquitectura tecnología, para la implementación productiva del modelo propuesto, es necesario poder generar una integración directa con el sistema ERP que almacena la información. De forma, que al momento de ingresar una máquina a mantención se pueda recuperar el historial de mantenimiento de la GPC para

ejecutar el modelo y generar la predicción. El Profit reportado del modelo, como se mencionó al momento de plantear la métrica, representa el valor máximo de inversión y este siempre se compara contra el escenario en el cual no se aplica una técnica de mantenimiento predictivo, con lo cual, en el escenario base cada falla desencadena en tiempo de inactividad.

Es importante considerar que la aplicabilidad del modelo, con el framework de generación de samples propuesto, es adaptable no solo a otros equipos de la empresa, como pueden ser las grúas horquillas, sino a maquinaria móvil de otros rubros; pero resulta primordial poder agregar información relacionada al uso y estrés de los equipos operativos. Esto entrega gran adaptabilidad al trabajo y metodología propuestas.

## 7. Bibliografía

- [1] Reveco M. (2019). ANÁLISIS PREDICTIVO DE ACTIVOS MINEROS PARA OBTENCIÓN DE INTERVALO DE FALLA MEDIANTE ALGORITMOS DE MACHINE LEARNING, MEMORIA PARA OPTAR AL TÍTULO DE INGENIERA CIVIL MECÁNICA, Recuperado el 01-07-2023. [https://repositorio.uchile.cl/bitstream/handle/2250/173707/cf-reveco\\_md.pdf?sequence=1&isAllowed=y](https://repositorio.uchile.cl/bitstream/handle/2250/173707/cf-reveco_md.pdf?sequence=1&isAllowed=y).
- [2] Savitha R., Ambikapathi A., Rajaraman K. (2020). Online RBM: growing restricted boltzmann machine on the fly for unsupervised representation. Recuperado el 10-04-2023. <https://doi.org/10.1016/j.asoc.2020.106278>.
- [3] Kaparathi S., Bumblauskas D. (2020). Designing predictive maintenance systems using decision tree-based machine learning techniques. Recuperado el 15-04-2023. <https://doi.org/10.1108/IJQRM-04-2019-0131>.
- [4] Dangut M., Skaf Z., Jennions I. (2020). Rescaled-LSTM for predicting aircraft component replacement under imbalanced dataset constraint. In: Proc. 2020 Adv. Science Eng. Technol. Int. Conf. ASET; 2020. Recuperado el 01-07-2023. DOI: 10.1109/ASET48392.2020.9118253.
- [5] SM SAAM. (2022). Memoria Integrada 2021. Recuperado el 10-04-2023, de SM SAAM Sitio web: [https://www.saam.com/wp-content/uploads/2022/04/SAAM-2021completa\\_web.pdf](https://www.saam.com/wp-content/uploads/2022/04/SAAM-2021completa_web.pdf).
- [6] Hernández Dávila, E., Angulo Guano, B., Fiallos Velasco, P., & Chávez Panamito, V. (s/f). MÉTODO PARA EL CÁLCULO DEL COSTO DE LA INDISPONIBILIDAD EN PROCESOS PRODUCTIVOS. Recuperado el 27-04-2023. <http://ceaa.esPOCH.edu.ec:8080/revista.perfiles/faces/Articulos/Perfiles17Art11.pdf>.
- [7] Biggio L., Kastanis I. (2020). Prognostics and Health Management of Industrial Assets: Current Progress and Road Ahead. Recuperado el 29-05-2023. <https://doi.org/10.3389/frai.2020.578613>.
- [8] Sahal R., Breslin J., Ali M. (2020). Big data and stream processing platforms for Industry 4.0 requirements mapping for a predictive maintenance use case. Journal of Manufacturing Systems. Recuperado el 01-06-2023. <https://doi.org/10.1016/j.jmsy.2019.11.004>.
- [9] Ramos P., Gutiérrez E. (s/f). Framework para la Detección Anticipada de Fallas de Equipos Mineros Mediante el Uso de Machine Learning. Recuperado el 27-04-2023. [https://laccei.org/LACCEI2020-VirtualEdition/work\\_in\\_progress/WP283.pdf](https://laccei.org/LACCEI2020-VirtualEdition/work_in_progress/WP283.pdf).
- [10] Leukel J., González J., Riekert M. (2021). Adoption of machine learning technology for failure prediction in industrial maintenance: A systematic review. Journal of Manufacturing Systems. Recuperado el 27-04-2023. <https://doi.org/10.1016/j.jmsy.2021.08.012>.
- [11] Fink O. (2020). Data-Driven Intelligent Predictive Maintenance of Industrial Assets. Recuperado el 01-07-2023. [https://doi.org/10.1007/978-3-030-11866-2\\_25](https://doi.org/10.1007/978-3-030-11866-2_25).

- [12] Bonnevey S., Cugliari J., Granger V. (2018). Predictive maintenance from event logs using wavelet-based features: an industrial application. Recuperado el 01-07-2023. <https://hal.science/hal-01856309/document>.
- [13] Chen K., Pashami S., Fan Y., Nowaczyk S. (2019). Predicting Air Compressor Failures Using Long Short Term Memory Networks. Recuperado el 01-07-2023. [https://doi.org/10.1007/978-3-030-30241-2\\_50](https://doi.org/10.1007/978-3-030-30241-2_50).
- [14] Prytz R., Nowaczyk S., Rögnvaldsson T., Byttner S. (2015). Predicting the need for vehicle compressor repairs using maintenance records and logged vehicle data. Recuperado el 01-07-2023. <https://doi.org/10.1016/j.engappai.2015.02.009>.
- [15] Zhu J., Zou H., Rosset S., Hastie T. (2006). Multi-class adaboost. *Statistics and its Interface*. Recuperado el 01-07-2023. <http://dx.doi.org/10.4310/SII.2009.v2.n3.a8>.
- [16] Wang J., Li C., Han S., Sarkar S., Zhou X. (2017). Predictive maintenance based on event-log analysis: A case study. In *IBM Journal of Research and Development*. Recuperado el 01-07-2023, DOI: 10.1147/JRD.2017.2648298.
- [17] Guerra Olivares R., Smith N., González Ramírez R., García Mendoza E., Cárdenas Barrón L. (2017). A heuristic procedure for the outbound container space assignment problem for small and midsize maritime terminals. Recuperado el 20-01-2024. DOI: 10.1007/s13042-017-0676-6.
- [18] Kovačević D., Budak I., Antić A., Nagode A., Kosec B. (2013). FEM modeling and analysis in prevention of the waterway dredgers crane serviceability failure. *Engineering Failure Analysis*, 28, 328–339. <https://doi.org/10.1016/j.engfailanal.2012.10.009>.
- [19] Sánchez D. (2021). Mantenimiento Predictivo: Machine Learning para la detección automatizada de fallos, Tesis doble grado en Matemática y Física. [https://eprints.ucm.es/id/eprint/68126/1/TFGMatematicas\\_DiegoJoseSanchezMartin.pdf](https://eprints.ucm.es/id/eprint/68126/1/TFGMatematicas_DiegoJoseSanchezMartin.pdf).
- [20] Xiang S., Huang D., Li X. (2018). A Generalized Predictive Framework for Data Driven Prognostics and Diagnostics using Machine Logs. *IEEE Conference Publication | IEEE Xplore*. <https://ieeexplore.ieee.org/document/8650152>.
- [21] You-Luen Lee, Da-Cheng Juan, Xuan-An Tseng, Yu-Ting Chen, Shih-Chieh Chang (2017). DC-Prophet: Predicting Catastrophic Machine Failures in DataCenters. <https://arxiv.org/abs/1709.06537>.
- [22] Zhang W., Yang D., Wang H. (2019). Data-Driven Methods for Predictive Maintenance of Industrial Equipment: A Survey. <https://doi.org/10.1109/JSYST.2019.2905565>.
- [23] Lee, J. H., Wu, F., Zhao, W., Ghaffari, M., Liao, L., & Siegel, D. S. (2014). Prognostics and health management design for rotary machinery systems—Reviews, methodology and applications. *Mechanical Systems and Signal Processing*. <https://doi.org/10.1016/j.ymsp.2013.06.004>.

# Anexos

## Anexo A

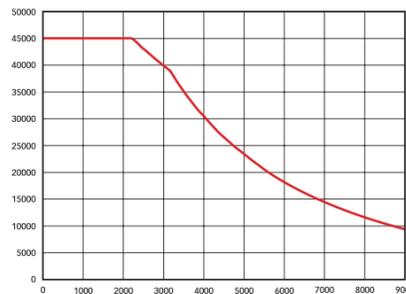
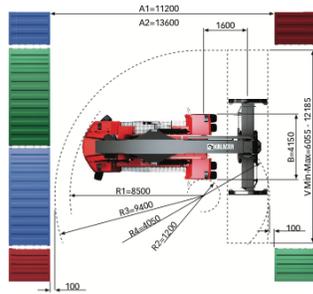
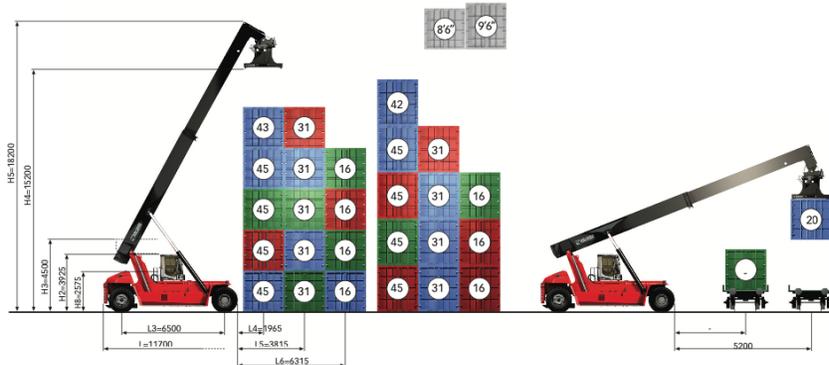
### Extracto Hoja técnica de Grúas Kalmar DRF420-450S

#### TECHNICAL DATA REACHSTACKERS DRF420-450S



#### Kalmar DRF450-65S5

Lifting data	DRF450-65S5
Lifting capacity at load centre L4, rated – at max. lifting height (kg)	45000 - 42000
Lifting capacity at load centre L5, rated – at max. lifting height (kg)	31000 - 31000
Lifting speed, unloaded – at 70% of rated load (m/s)	0,42 - 0,25
Lowering speed, unloaded – at rated load (m/s)	0,36 - 0,36
<b>Driving data</b>	
Travelling speed forward, unloaded – at rated load (km/h)	25 - 21
Travelling speed backward, unloaded – at rated load (km/h)	25 - 21
Gradeability at 2 km/h, unloaded – at rated load (%)	39 - 32
Gradeability max., unloaded – at rated load (%)	34 - 20
Drawbar pull, max. (kN)	362
<b>Weight of truck</b>	
Service weight (kg)	69000
Axle load front at load centre L4, unloaded – at rated load (kg)	35000 - 99400
Axle load front at load centre L5, unloaded – at rated load (kg)	39000 - 92200
Axle load front at driving position according to EN 1459, and rated load (kg)	88500
Axle load rear at load centre L4, unloaded – at rated load (kg)	34000 - 14600
Axle load rear at load centre L5, unloaded – at rated load (kg)	30000 - 7800
Axle load rear at driving position according to EN 1459, and rated load (kg)	25500
<b>Engine</b>	
Manufacturer - type designation	Cummins - QSM11 (Turbo-Intercooler)
Fuel - type of engine	Diesel - 4 stroke
Number of cylinders – displacement (cm <sup>3</sup> )	6 - 16,3:1
Power according to ISO 3046 – at revs (kW – rpm)	261 - 2000
Torque according to ISO 3046 – at revs (Nm – rpm)	1830 - 1100-1400
Alternator, power (V/A)	AC - 2400
Starting battery, voltage – capacity (V – Ah)	2×12 - 140
Fuel consumption, normal driving (l/h)	18
<b>Transmission</b>	
Manufacturer - type designation	Dana – 15.7TE32418
Clutch, type	Torque converter
Gearbox, type	Hydrodynamic Powershift
Number of gears, forward – reverse	4 - 4
Driving axle, manufacturer – type	Kalmar WDB - Differential and hub reduction
<b>Wheels</b>	
Type	Pneumatic
Dimensions, front – rear (inch)	18.00x25 - 18.00x25, PR40 E4
Number of wheels, front – rear (* driven)	4 - 2
Pressure (MPa)	1,0
<b>Miscellaneous</b>	
Steering system, type – maneuvering	Servo assisted - Steering wheel
Service brake system, type – affected wheels	Wet disc brakes - Drive wheel
Parking brake system, type – affected wheels	Spring brake - Drive wheel
Max. hydraulic pressure (MPa)	21,0
Fuel volume (l)	550
Hydraulic oil volume (l)	600
Overload protection	Electronic



**Dimensions**

**DRF450-65S5**

Beam angle (°)	$\alpha$	60
Attachment rotation, CW - CCW (°)	$\beta$	195 - 105
Sideshift $\pm$ (mm)	V1	$\pm 800$
Track (c-c), front - rear	S	3030 - 2600
Ground clearance, min. (mm)		250

The designs and materials specification are subject to alternation without prior notice.  
Tolerances according to K-standard 95430.0008/0009.

Cargotec improves the efficiency of cargo flows on land and at sea – wherever cargo is on the move.  
Cargotec's daughter brands Hiab, Kalmar and MacGregor are recognised leaders in cargo and load handling solutions around the world. Cargotec's global network is positioned close to customers and offers extensive services that ensure the continuous, reliable and sustainable performance of equipment.  
Cargotec's class B shares are quoted on the NASDAQ OMX Helsinki. [www.cargotec.com](http://www.cargotec.com)



**Cargotec Sweden AB**  
Torggatan 3  
SE-340 10, Lidhult, Sweden  
tel. +46 372 260 00  
fax +46 372 263 90  
[www.cargotec.com](http://www.cargotec.com)

2014.07.16

## Anexo B

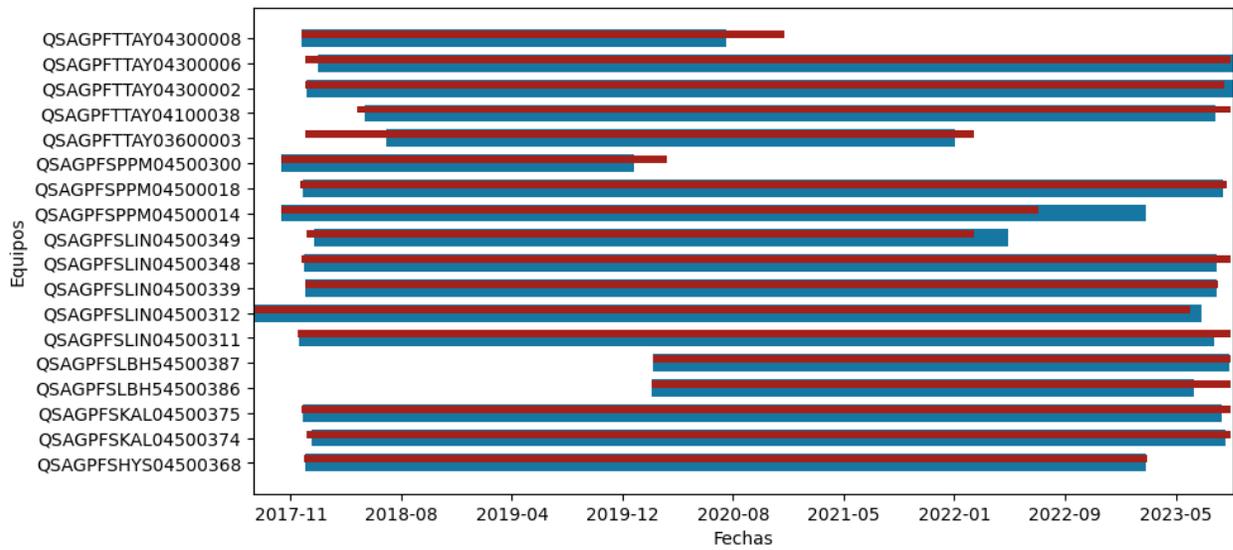
### Horómetros y ordenes de mantención

La siguiente tabla contiene la cantidad de mantenimientos por máquina, indicando la fecha del primer y último mantenimiento dentro de la ventana de observación. También, contiene la cantidad de registros de horómetros realizados durante la misma ventana con la fecha del primer y último registro y los valores totales del horómetro (edad) de la máquina.

Nº	Equipo	MT_count	MT_min	MT_max	HO_count	HO_min	HO_max	HO_horomin	HO_horomax
1	QSAGPFSHYS04500368	152	02-01-18	16-03-23	240	31-12-17	20-03-23	2395.6	7136.2
2	QSAGPFSKAL04500374	377	15-01-18	12-09-23	315	06-01-18	24-09-23	5247.0	19326.5
3	QSAGPFSKAL04500375	227	27-12-17	05-09-23	251	25-12-17	24-09-23	5909.0	15798.8
4	QSAGPFSLBH54500386	156	24-02-20	04-07-23	276	24-02-20	24-09-23	0.0	21099.3
5	QSAGPFSLBH54500387	195	27-02-20	20-09-23	283	27-02-20	24-09-23	0.0	12148.0
6	QSAGPFSLIN04500311	122	20-12-17	17-08-23	181	16-12-17	24-09-23	19568.4	24877.8
7	QSAGPFSLIN04500312	278	08-09-17	20-07-23	273	08-09-17	25-06-23	17680.0	25286.3
8	QSAGPFSLIN04500339	238	03-01-18	25-08-23	309	02-01-18	27-08-23	13016.0	21718.0
9	QSAGPFSLIN04500348	196	29-12-17	25-08-23	343	25-12-17	24-09-23	11578.0	23292.1
10	QSAGPFSLIN04500349	151	23-01-18	09-05-22	215	06-01-18	20-02-22	9685.0	21683.0
11	QSAGPFSPPM04500014	140	08-11-17	16-03-23	46	08-11-17	18-07-22	34039.5	35745.3
12	QSAGPFSPPM04500018	339	26-12-17	06-09-23	95	23-12-17	17-09-23	39598.0	40973.8
13	QSAGPFSPPM04500300	47	10-11-17	14-01-20	32	10-11-17	29-03-20	38550.0	38974.0
14	QSAGPFTTAY03600003	42	03-07-18	10-01-22	261	01-01-18	20-02-22	32438.6	33533.3
15	QSAGPFTTAY04100038	71	17-05-18	21-08-23	201	30-04-18	24-09-23	51089.5	52964.5
16	QSAGPFTTAY04300002	151	05-01-18	29-09-23	532	02-01-18	10-09-23	45059.2	47626.9
17	QSAGPFTTAY04300006	176	30-01-18	29-09-23	558	02-01-18	24-09-23	38177.6	41398.9
18	QSAGPFTTAY04300008	43	25-12-17	10-08-20	117	25-12-17	20-12-20	35516.3	37487.5

*Tabla 11. Primer y último registro OM y HO.*

En los enunciados de la tabla, MT hace referencia a mantenimiento y HO a horómetro. La Ilustración 27 muestra una representación gráfica de la información de la tabla. La barra azul representa los mantenimientos y la barra roja los registros de horómetros.



*Ilustración 27. Intervalo de observación con información de horómetros.*

# Anexo C

## Tarifario público AEP

Extracto del tarifario público del terminal extraportuario donde se especifica los servicios a contenedores. Los servicios excluidos para el cálculo del ingreso promedio por servicio y la tasa de servicios por hora son (indicando la glosa servicio - condición): Apoyo Usuario – Unidad Directa, Conexión Energía – Refrigerada, Etiquetado – Peligrosa, Reconocimiento – General, Reconocimiento – Peligrosa y Sellado. El tarifario público se puede encontrar en el sitio web SAAM Extraportuarios: <https://www.aep.cl/tarifas-publicas/>

Servicios a Contenedores					
GLOSA SERVICIO	CONDICIÓN	CÓDIGO SERVICIO	UNIDAD	TARIFA US\$	DESCRIPCIÓN SERVICIO
ALMACENAJE	GENERAL	AL01-CNGN	cntr/día	100	Servicio correspondiente a la permanencia y custodia de contenedores de descarga de nave en el caso de la importación y de contenedores para pre embarque en el caso de la exportación.
	PELIGROSA	AL01-CNPL	cntr/día	250	
	REFRIGERADA	AL01-CNRF	cntr/día	100	
	SOBREDIMENSIONADO	AL01-CNSB	cntr/día	390	
	VACIO	AL20-CNSA	cntr/día	30	
APOYO USUARIOS	SMDA	AP05-CNSA	cntr	80	Corresponde al cobro por gastos asociados al tramite documental de cambio de almacén
	INSPECCION SAG	AP02-CNSA	cntr	280	Corresponde a la actividad operativa y documental que permite que los contenedores con condición de fiscalización cumpla con la realización de la misma.
	INSPECCION SNS	AP03-CNSA	cntr	280	
	INSPECCION SAG AD	AP19-CNSA	cntr	560	Servicio correspondiente a la visación documental de contenedores en condición de retiro directo desde puerto
	UNIDAD DIRECTA	AP14-CNSA	cntr	60	
	MEDICIÓN DE GASES	AP15-CNSA	cntr	40	Servicio de detección de gases fumigantes en contenedores inspeccionados dentro del terminal.
CAMBIO CONDICION	GENERAL	CM01-CNGN	cntr	150	Este servicio corresponde a la movilización de contenedores que cambian su condición de retiro directo a condición de retiro indirecto.
	PELIGROSA	CM01-CNPL	cntr	150	
	REFRIGERADA	CM01-CNRF	cntr	150	
	SOBREDIMENSIONADO	CM01-CNSB	cntr	250	
CONEXIÓN ENERGÍA	REFRIGERADA	CX01-CNRF	hora	5,5	Este servicio corresponde al suministro a la red eléctrica para contenedores refrigerados.
CONSOLIDADO	GENERAL	CS01-CNGN	cntr	450	Este servicio corresponde al conjunto de actividades necesarias para la disposición segura de bultos dentro de un contenedor.
	PELIGROSA	CS01-CNPL	cntr	550	
	SOBREDIMENSIONADO	CS01-CNSB	cntr	650	
DESCONSOLIDADO	GENERAL	DC01-CNGN	cntr	450	Este servicio corresponde al conjunto de actividades necesarias para el retiro seguro de las bultos desde el interior del contenedor.
	PELIGROSA	DC01-CNPL	cntr	550	
	SOBREDIMENSIONADO	DC01-CNSB	cntr	650	
DESPACHO	GENERAL	DP01-CNGN	cntr	100	Este servicio corresponde a las actividades operativas y documentales para la disposición de contenedores sobre una unidad de transporte con objeto de hacer retiro de la mercancía desde el terminal.
	PELIGROSA	DP01-CNPL	cntr	180	
	REFRIGERADA	DP01-CNRF	cntr	100	
	SOBREDIMENSIONADO	DP01-CNSB	cntr	360	
DIVISION	GENERAL	DV01-CNGN	cntr	200	Corresponde a las actividades operativas y documentales que permiten apoyar la separación de bultos en zona primaria con el objeto de nacionalizar partidas específicas.
	PELIGROSA	DV01-CNPL	cntr	250	
ETIQUETADO	PELIGROSA	ET01-CNPL	set etiquetas	25	Servicio corresponde a la actividad operativa de pegado de etiquetas en contenedores cualquiera sea su tipología o tamaño.
EXAMEN FISICO Y AFORO	GENERAL	AF01-CNGN	cntr	280	Servicio correspondiente a la actividad operativa y documental de inspección y verificación de contenedores según la disposición del ente fiscalizador.
	PELIGROSA	AF01-CNPL	cntr	380	
	REFRIGERADA	AF01-CNRF	cntr	560	
MANIPULEO	S/A	MN01-CNSA	cntr	50	Corresponde a la actividad de subir y/o bajar contenedores en el terminal a través de medios mecánicos.
MOVILIZACION	GENERAL	MV01-CNGN	cntr	150	Este servicio corresponde al traslado de contenedores entre zonas primarias, sean estos recintos portuarios o recintos de depósito aduanero.
	PELIGROSA	MV01-CNPL	cntr	350	
	REFRIGERADA	MV01-CNRF	cntr	350	
	SOBREDIMENSIONADO	MV01-CNSB	cntr	750	
	INTERNA	MV02-CNSA	cntr	80	
PREPARACION, PRONTO DESPACHO	S/A	PR01-CNSA	movimiento	100	Este servicio corresponde a la actividad operativa de selección y ordenamiento de contenedores para su pronto despacho fuera de su programación normal.
RECEPCION	GENERAL	RC01-CNGN	cntr	100	Este servicio corresponde a las actividades operativas y documentales para recibir contenedores desde una unidad de transporte con objeto de almacenarla en el terminal.
	PELIGROSA	RC01-CNPL	cntr	180	
	REFRIGERADA	RC01-CNRF	cntr	100	
	SOBREDIMENSIONADO	RC01-CNSB	cntr	360	
RECONOCIMIENTO	GENERAL	RN01-CNGN	cntr	150	Corresponde al servicio de actividades operativas y documentales que apoyan la verificación de bultos físicos contra los documentos bases que amparan las mercancías.
	PELIGROSA	RN01-CNPL	cntr	200	
SELLADO	S/A	SL01-CNSA	cntr	25	Corresponde a la actividad operativa de poner sellos en una unidad (contenedor/rampa).
TRASVASIJE	GENERAL	TR01-CNGN	cntr	500	Esta actividad corresponde a la actividad de desconsolidar un contenedor y trasladar su contenido a otra unidad mediante la consolidación. Para el caso de unidades flexitank, la actividad operativa del servicio está relacionada con los manipuleos de las unidades y el uso de área donde se realizará el trasvasije a través de empresas autorizadas para tales efectos.
	PELIGROSO	TR01-CNPL	cntr	650	
	REFRIGERADO	TR01-CNRF	cntr	500	
	LIQUIDO	TR02-CNSA	cntr	650	
USO DE BATEA	EMERGENCIA GENERAL	BT01-CNGN	cntr/día	1.600	Utilización de personal y equipos para contener el derrame de residuos de carga. Servicio incluye recibir y posicionar el contenedor con filtración sobre la batea y posterior levantamiento. No incluye almacenamiento, retiro o destrucción de residuos ni permisos de la autoridad.
	EMERGENCIA PELIGROSA	BT01-CNPL	cntr/día	2.800	
VENTILACION, USO DE AREA	S/A	VN01-CNSA	cntr	180	Corresponde a la actividad operativa que permite el proceso de ventilación natural de contenedores con residuos fumigantes.

Ilustración 28. Tarifario público.