



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

**MÉTODOS DE PRONÓSTICO DE FALLAS EN MOTORES DIÉSEL DE
CAMIONES MINEROS EN BASE A INDICADORES DE DEGRADACIÓN
PROBABILÍSTICOS**

TESIS PARA OPTAR AL GRADO DE MAGÍSTER EN CIENCIAS DE LA INGENIERÍA,
MENCIÓN ELÉCTRICA

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL ELÉCTRICO

MARTÍN NICOLÁS VALDERRAMA ILLESCA

PROFESOR GUÍA:
Marcos Orchard Concha

MIEMBROS DE LA COMISIÓN:
Jorge Silva Sánchez
Viviana Meruane Naranjo

SANTIAGO DE CHILE
2022

RESUMEN DE LA TESIS PARA OPTAR AL
GRADO DE MAGÍSTER EN CIENCIAS DE LA INGENIERÍA, MENCIÓN ELÉCTRICA
y MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL ELÉCTRICO
POR: MARTÍN NICOLÁS VALDERRAMA ILLESCA
FECHA: 2022
PROF. GUÍA: Marcos Orchard Concha

MÉTODOS DE PRONÓSTICO DE FALLAS EN MOTORES DIÉSEL DE CAMIONES MINEROS EN BASE A INDICADORES DE DEGRADACIÓN PROBABILÍSTICOS

En la minería el control de los tiempos de mantenimiento preventivo es crítico para la gestión de los costos. La disponibilidad de datos en la operación a partir de mantenimientos y sensores con datos en tiempo real, motiva la generación de análisis y estimaciones para la gestión de activos. En esta tesis se desarrolla una metodología para determinar de forma probabilística el tiempo de falla del motor diésel de un conjunto de camiones mineros de extracción. Para ello se cuenta con información de la operación del motor en tiempo real a partir de sensores, análisis de laboratorio del aceite usado en la operación, y registros de fallas y mantenimientos programados.

La metodología consiste en el tratamiento de los datos para la generación de algoritmos no supervisados de aprendizaje que permiten encontrar conjuntos de estados de operación, a los cuales se asocian a una tasa de desgaste a partir de la información en los análisis de laboratorio. Estos estados se utilizan para la estimación del tiempo de falla a partir de simulaciones del modelo de la operación utilizando filtros de partículas y la Cadena de Markov generada a partir de las transiciones histórica entre estados del camión.

A mi madre

Agradecimientos

Agradezco a mi madre que por su esfuerzo y enseñanzas me permitieron progresar en la vida, salir adelante y llegar a esta instancia tan decisiva en mi vida, y por la buena crianza que obtuve de ella.

A Catalina, mi pareja por su fuente de apoyo y buenos momentos compartidos en todo el proceso universitario. Por todos los días que estudiamos juntos, los que no, y los que me enseñó lo bella que puede ser la vida.

A mi profesor guía Marcos Orchard por su mentoría, consejos, palabras de aliento y crítica que me ayudó a culminar el trabajo de tesis. Además, y sin dejar fuera al equipo de analítica de Contac, sin los cuales no habría sido posible terminar este trabajo ni otros en los cuales me he visto envuelto.

A los profesores de mi comisión de magíster, la profesora Viviana Meruane y Jorge Silva, cuyas revisiones me dieron el empujón final para afinar detalles y la confianza de que estaba haciendo las cosas bien.

A mis amigos por las palabras de ánimo y los buenos momentos compartidos, por los carretes memorables y las conversaciones de la vida. A Jou Hui por ser tan buena amiga y persona, por su inspiradora actitud hacia la vida y ser un ejemplo a seguir. A Lucas Rojas por su ejemplo de perseverancia en la vida y también del disfrute. A Jorge Fabry, Pablo Ilabaca, Bárbara Rocco y Bryan Foden por el apañe en todos estos años en eléctrica. Sin olvidar a mis amigos de la 3R que son y seguirán siendo los primeros que hice en la universidad, de los cuales agradezco seguir teniendo buenos carretes e ir incorporando gente al grupo.

Tabla de Contenido

1. Introducción	1
1.1. Problema	2
1.2. Hipótesis	2
1.3. Objetivos	3
1.3.1. General	3
1.3.2. Específicos	3
1.4. Descripción del trabajo realizado	3
2. Marco Teórico	5
2.1. Métodos de reducción de dimensionalidad	5
2.1.1. Análisis de Componentes Principales (PCA)	5
2.1.2. t-distributed stochastic neighborhood embedding (t-SNE)	6
2.1.3. Uniform Manifold Approximation and Projection for Dimension Reduction (UMAP)	8
2.2. Algoritmos de clustering	10
2.2.1. K-means	10
2.2.2. Density Based Spatial Clustering of Applications with Noise (DBSCAN)	10
2.3. Degradación de aceites de motor	11
2.4. Filtros Bayesianos	12
2.5. Estimación de Tiempo de Falla	15
3. Clustering de Modos de Operación	17
3.1. Objetivo	17
3.2. Procedimiento para obtener el clustering	18
3.2.1. Agregación de los datos	19
3.2.2. Estandarización de los datos	19
3.2.3. UMAP	19
3.3. Resultados del clustering	19
3.3.1. Agregación a 5 minutos	20
3.3.2. Agregación a 1 hora	22
3.3.3. Agregación a 4 horas	25
3.4. Problemáticas del clustering	26
4. Indicador de desgaste del motor fuera de línea	29
4.1. Datos disponibles	29

4.2. Datos tribológicos	30
4.3. Creación del indicador	33
4.4. Proceso de Optimización para encontrar la Hazard Zone	35
4.5. Consideraciones	36
5. Estimación de tasas de degradación	38
5.1. Algoritmo de estimación	38
5.2. Resultados	40
5.3. Discusión	42
6. Estimación de Tiempo de Falla	43
6.1. Algoritmo a implementar	43
6.2. Resultados	47
6.3. Discusión	49
7. Conclusiones	50
7.1. Trabajo Futuro	51
Bibliografía	52

Índice de Tablas

2.1.	El origen de ciertos elementos de desgaste en el aceite de motor generada en [15].	13
5.1.	Parámetros establecidos para la búsqueda de tasas de degradación.	39
6.1.	Tabla de estimación de Tiempo de Falla de varios activos.	48
6.2.	Tabla de errores en la estimación del Tiempo de Falla de los activos en revisión.	49

Índice de Ilustraciones

2.1.	Imagen del algoritmo de Density Based Spatial Clustering of Applications with Noise (DBSCAN) tomado de [13]	11
2.2.	Algoritmo de estimación de ToF en zona de peligro probabilística junto a visualización del algoritmo tomado de [21]	16
3.1.	Proyección PCA de principales variables operacionales del camión.	20
3.2.	Experimento con reducción de dimensionalidad con t-SNE. Se observa cómo al cambiar el parámetro de <i>perplexity</i> se divisan clusters más definidos.	21
3.3.	Proyección en umap utilizando las mismas variables que en PCA y t-SNE. . .	21
3.4.	Mapa de calor de variables importantes en el modelo, donde se nota una clara separación en 3 modos de operación entre ellas.	22
3.5.	Proyección PCA de variables agregadas a 1 hora. Algunas variables son: tendencia del intervalo, media, mínimo y máximo de la distribución, desviación estándar.	23
3.6.	Proyección de principales variables de separación del espacio. En este caso se puede observar que existe una relación entre los clusters que tienen bajos niveles de la variable A con la de la variable B. El gran cluster central presenta comportamientos mixtos.	24
3.7.	Presencia de desviación estándar en los clusters encontrados. La desviación estándar de la variable a nos lleva a interpretar que el cluster inferior izquierdo presenta altos niveles pero estables de la variable a. Mientras que en la derecha, el cluster central presenta niveles intermedios de la variable b y con alta variabilidad.	24
3.8.	En el caso de las tendencias lineales de ambas variables, no se presenta una tendencia clara, pero igual añade información valiosa. En el caso del cluster superior derecho, se tiene que existe una tendencia mezclada de la variable a y la variable b tiende a ser constante, con tendencia cercana a 0. Esto se condice con la baja variabilidad en la variable b y sus bajos niveles.	25
3.9.	Variables S y B en proyección UMAP a 4 horas. No se observa una separación clara entre los clusters. La razón es la baja variabilidad de la distribución de dichas variables.	25
3.10.	Los primeros dos gráficos corresponden a la desviación estándar de las variables A y B, y los inferiores a las tendencias. Como se puede observar, estas características pierden poder de explicación al agregarse a un intervalo tan grande. . .	26
3.11.	Resultados clustering data operacional con UMAP y DBSCAN.	27
3.12.	Clustering sobre camiones particulares y su proyección en UMAP.	28

4.1.	Evolución en el tiempo de la concentración de dos elementos diferentes en el aceite. En la primera visualización se muestra un elemento con una tendencia poco clara; en la segunda se muestra una tendencia más marcada. Con esto se muestra la necesidad de quitar la tendencia global de dichos elementos para los siguientes pasos en el análisis.	31
4.2.	Odómetro de la cantidad de horas que se ha mantenido el aceite desde el último cambio. Se toma como variable contra de referencia de la edad del aceite en el camión.	31
4.3.	Gráficos de correlaciones de mediciones en análisis tribológico. Primeros dos representan a elementos producidos por el roce y por la combustión del motor cuyas concentraciones aumentan a medida que el aceite se utiliza; el tercero son variables ambientales que no presentan mayor correlación con el uso; y el último representa el <i>total base number</i> el cual al disminuir indica que aumenta la aceidez del aceite a medida que este se utiliza, i.e. la corrosión aumenta en el aceite. .	32
4.4.	Gráfico superior: eventos de falla y mantención registrados en el sistema. Gráfico del centro: función de degradación diferencial a partir de análisis tribológicos. Gráfico inferior: acumulación de la degradación.	34
4.5.	Gráfico de corrección contra valor de falla al inicio y fin de un intervalo analizado. Gráficos de zona de peligro en probabilidad y probabilidad acumulada.	36
4.6.	Indicador de degradación modificado por problema de optimización.	36
5.1.	Tasas de desgaste estimadas a partir de los datos sin el ajuste por curva de degradación.	39
5.2.	Estimación de las tasas de degradación a partir de distintos periodos de desgaste.	40
5.3.	Estimación y evolución de medias de tasa de desgaste	40
5.4.	Distribución de tasas de degradación estimadas.	41
5.5.	Evolución de la métrica de ajuste en la estimación de las tasas de desgaste. . .	41
6.1.	Progresión de estimación de degradación en línea sin re-entrenamiento.	45
6.2.	Progresión de estimación de degradación en línea con re-entrenamiento.	46
6.3.	Ejemplo de distribución de masa de probabilidad de Tiempo de Falla	47
6.4.	Progresión de estimaciones de degradación en línea para un camión.	48

1. Introducción

La faena minera conlleva un trabajo constante para la extracción de mineral desde las montañas. Complejos trabajos de extracción se llevan a cabo día y noche para mantener la producción en niveles de producción óptimos. En una operación de tal nivel de complejidad y en la cual se ven involucrados tantos equipos sometidos al desgaste de sus componentes debido al funcionamiento continuo, esta es sensible a mal funcionamientos de estos equipos, que paraliquen la faena por completo.

Uno de los componentes fundamentales en esta operación, es el transporte de material de un lado a otro de la mina, donde el traslado de toneladas de material es llevado a cabo por camiones propulsados por sendos motores diésel. Estos equipos están sometidos al día a día de la operación y sus condiciones adversas, al igual que a la forma en que los operadores hagan uso de estos y a las condiciones del terreno por el que circulan. En otras palabras, estos equipos están sometidos a un desgaste de sus componentes dependiendo de las condiciones en que su trabajo se lleve a cabo y su operador haga uso de este.

El desgaste que sufren estos equipos se refleja en su totalidad, desde los neumáticos hasta el motor interno. En este último componente es donde se centrará la investigación a desarrollar. El motor diésel de estos camiones es monitoreado en tiempo real por cantidad de sensores que entregan presión, temperatura, revoluciones, nivel de carga, y otros valores que dan cuenta del funcionamiento del motor en todo momento. Una de las hipótesis que se tiene sobre este funcionamiento, es que este pasa por distintas etapas a lo largo del día y su operación. Donde cada una de estas etapas corresponde a un estado de operación. Este también depende del uso que se le dé, y el contexto en que éste se desenvuelva. La siguiente hipótesis generada para llevar a cabo esta investigación, es que dependiendo de cada uno de estos estados de operación se genera un nivel de desgaste particular, donde ese desgaste se verá reflejado en sus componentes.

En base a lo estipulado anteriormente, se propone el desarrollo de una metodología que permita estimar en el futuro el instante de falla de estos equipos y así poder ajustar una mantención programada que permita pesquisar el problema antes de que esta ocurra en medio de una operación. La metodología desarrollada implica la investigación de un indicador de desgaste de un componente en específico del equipo, el cual puede ser medido directa o indirectamente en un intervalo de tiempo, para ser asociado con la operación del mismo, información que será recabada a una frecuencia más alta que el mismo indicador. La asociación del indicador de desgaste con la operación implica la estimación de las tasas de desgaste a dicho estado de operación. Luego de esta asociación, se propone un monitoreo en base a los estados de operación obtenidos en línea, para luego realizar un pronóstico del desgaste futuro y con ello la estimación de un instante de falla en el futuro. Para desarrollar dicha metodología, se selecciona la operación de los camiones diésel de transporte de material dentro de la mina.

Las fallas en un equipo tan complejo y que prácticamente está en operación las 24 horas del día, son frecuentes. Pero existen fallas que obligan al equipo a entrar a taller por tiempos prolongados, lo que implica pérdida de horas de operación, lo que significa pérdidas monetarias para la faena. Una de las condiciones de falla de este equipo es provocada por el mal funcionamiento de las culatas. Componente ubicado sobre los pistones del motor que sellan su funcionamiento y por el cual circula el refrigerante, aceites y combustible necesario para su operación. Los modos de falla por falla en la culata implican las fugas de aceite, salida de humo blanco por el tubo de escape, imposibilidad de partir del motor. Esta última es la más preocupante debido a que conlleva una estadía prolongada del camión en el taller, tanto que cada cierto tiempo se debe cambiar el módulo completo.

La metodología se basa en la obtención de información a partir de data de los sensores en el motor que permiten generar una caracterización de los estados de operación por los que pasa el camión. Data del análisis tribológico o de aceites que permite generar el indicador de desgaste en base a un procesamiento de esos datos de acuerdo a investigación realizada que explica la correlación de los niveles de elementos en el aceite asociados a fallas o desgaste de componentes en el motor. Data asociada a eventos de falla y episodios en que el camión debe ingresar a taller por fallas en el motor. Se realiza una construcción del indicador en conjunto con la zona de peligro de falla, para luego ser asociada a los datos operacionales del motor y así realizar una estimación y pronóstico del desgaste e instante de falla del motor. Para finalmente ser corroborado con data de eventos de falla del camión.

El artículo está organizado partiendo desde una motivación del problema, seguido por el marco teórico en el que se detallan las herramientas a utilizar en la metodología, una explicación en detalle de la metodología a realizar por sección, donde se especifican los objetivos de la sección, la metodología, resultados y discusión en particular de esa sección y, finalmente, los resultados asociados a la metodología completa. Se finaliza con una discusión sobre los resultados y aplicaciones de la herramienta desarrollada.

1.1. Problema

El problema sobre el que se desarrolla la metodología y el que pretende resolver, es la alta incertidumbre que se tiene a la hora de generar predicciones del momento de falla de los motores de camiones mineros. Dado que estos elementos están sometidos a distintas formas de uso que dependen del área en que se realice su trabajo, la forma de operar de los conductores, la carga a los que son sometidos, etc. Es difícil generar un modelo de evolución en la degradación de los mismos. Además, no se cuenta con información de degradación directa del motor o de alguna de sus partes, si no que se estima que ocurrió una falla cuando en inspecciones se visualizan problemas en el exterior del motor o el motor se detiene o entra en un estado de mal funcionamiento. Esto ocurre cuando ya ocurrió una falla que paralice el motor y su faena.

1.2. Hipótesis

En base a información operacional y mediciones del estado de salud, es factible desarrollar una metodología que permita estimar en tiempo real la degradación y pronosticar el momento de una falla catastrófica de forma probabilística en motores diésel de camiones mineros, donde las mediciones de estado de salud tienen alta incertidumbre.

1.3. Objetivos

A continuación, se describe el objetivo principal de la investigación.

1.3.1. General

El objetivo principal de esta investigación es encontrar una metodología que permita fusionar la información proveniente de sensores que capturan la operación en línea del motor, con información de mantenimiento e inspecciones que nos entregan información de la degradación del motor, generando un modelo estocástico de la degradación en base a información operacional. Y con ello, a partir de la caracterización de la operación, generar una estimación de forma probabilística del tiempo de falla catastrófico asociado a fugas en culatas del motor diésel del camión de extracción. Teniendo como resultado información valiosa para la toma de decisiones en procesos de mantenimiento preventivo.

1.3.2. Específicos

En cuanto a los objetivos específicos, se tienen los siguientes:

1. Generar la caracterización de estados de operación de un motor diésel de camión de extracción minero a partir de información operacional utilizando métodos de reducción de dimensión y clustering que permitan darle sentido fenomenológico a dichos estados.
2. Definir un indicador de salud en base a datos de mediciones de mantenimiento y eventos de fallas, que permita identificar el inicio de la vida útil del motor y sus fallas catastróficas, además de la zona de peligro donde el motor tiene alta probabilidad de falla.
3. Estimar de forma probabilística las tasas de desgaste de los estados de operación por medio de un algoritmo que las asocie a la tasa de desgaste proveniente de mediciones intermitentes de inspecciones de dicho motor.
4. Implementar un sistema de estimación de la degradación a partir de un modelo de evolución basado en la degradación acumulada de los estados operacionales.
5. Generar predicciones de la degradación del motor con el modelo encontrado, utilizando algoritmos basados en filtros bayesianos, e integrar el concepto de *First Passage Time* para estimar la ocurrencia de una falla catastrófica en el motor.
6. Caracterizar la distribución de probabilidad del tiempo de falla con el modelo propuesto con el fin de proveer estadísticos de dicha distribución que sean de utilidad para la toma de decisiones de mantenimiento preventivo de los motores diésel de camiones mineros.

1.4. Descripción del trabajo realizado

En esta sección se describe brevemente el trabajo realizado y de la organización del informe a presentar.

Este informe desarrolla la metodología para llevar a cabo el objetivo de esta tesis y explorar la verosimilitud de la hipótesis planteada.

En primer lugar se desarrollan las bases de la investigación y las herramientas utilizadas, como los métodos de reducción de dimensionalidad como PCA, t-SNE y UMAP, para posteriormente exponer el método de clustering a utilizar. El marco teórico continúa con una declaración de los métodos de estimación de fallas a partir de los análisis tribológicos del aceite de motor usado. Finalizando el marco teórico con las herramientas de filtro bayesiano y la estimación del tiempo de falla.

La metodología continua con capítulos relacionados a cada etapa de la metodología. Partiendo con el capítulo 3 **Clustering de Modos de Operación** donde se describe el procesamiento de datos para llegar a los estados de operación de cada motor diésel. En ella se utilizan las herramientas de reducción de dimensionalidad y clustering de UMAP principalmente, variando las escalas de tiempo del análisis y la cantidad de variables utilizadas en él.

El capítulo 4 **Indicador de desgaste del motor fuera de línea** describe el tratamiento de los datos de análisis de laboratorio del aceite usado del motor para llegar a la construcción del indicador de degradación fuera de línea. Se utilizan herramientas de limpieza de datos para estandarizar las variables y su selección para generar el indicador. Se realiza un análisis de correlaciones con el tiempo de uso para determinar cuáles son las variables más importantes en el análisis. El capítulo finaliza con los resultados del problema de optimización para encontrar la zona de peligro asociada a la degradación de los motores a partir del indicador construido y los eventos de falla registrados.

El siguiente capítulo que contiene la metodología de asociación de las tasas de degradación de cada estado es el capítulo 5 **Estimación de tasas de degradación** donde se aplica un algoritmo que estima, a partir de la reconstrucción de la curva de degradación, la distribución de la tasa de degradación para cada estado.

Con la información anterior, el capítulo 6 **Estimación de Tiempo de Falla** describe cómo se integra la información de los estados de operación, las mediciones intermedias de la degradación de los aceites y el modelo de degradación, para generar estimaciones del tiempo de falla de un motor en particular. Se cierra el capítulo con una pequeña discusión de los resultados y trabajo a futuro.

El capítulo final 7 **Conclusiones** finaliza planteando el cumplimiento de los objetivos particulares y general, además de proponer posibles mejoras al trabajo planteado.

2. Marco Teórico

Para tener un mejor entendimiento de los procedimientos discutidos en el trabajo, se necesita tener un marco común de métodos y terminología. Para ello se describen los métodos y herramientas utilizadas en el tratamiento de los datos y estimación de las tasas de desgaste y posteriormente de la distribución del tiempo de falla.

Para llegar a la estimación del tiempo de falla, se debe contar con los estados operacionales, el indicador de falla y los métodos de estimación. Para el primer punto, se refiere en primera instancia a la reducción de dimensionalidad, donde se revisan los métodos de análisis por componentes principales, *t-distributed stochastic neighborhood embedding* (t-SNE) y *Uniform Manifold Approximation and Projection for Dimension Reduction* (UMAP). Para encontrar los clusters se describe brevemente los métodos de K-means y *Density Based Spatial Clustering of Applications with Noise* (DBSCAN), que nos permitirán terminar de caracterizar los estados de operación. En el caso del indicador de degradación, se expone la investigación relacionada al análisis del aceites en la degradación del motor en camiones mineros y cómo mediciones en el aceite pueden ser relacionadas con la degradación del motor. Finalmente, se exponen métodos de filtros de partículas que nos permitirán, a partir de un modelo de degradación, estimar el estado de degradación a partir de datos históricos y simulaciones; además de generar pronósticos respecto de la degradación futura.

2.1. Métodos de reducción de dimensionalidad

La realización del clustering es una tarea que se apalanca en herramientas de reducción de dimensión o manejo de los datos para un mejor y más fácil clustering. Está demostrado [1] que en espacios de alta dimensión para problemas de multivariable es mejor realizar una reducción de dimensión debido a que los datos están menos dispersos en el espacio.

Es por ello, que dentro de las tareas de preparación de datos para el clustering, se encuentra la de reducción de dimensionalidad. Entre ella se van desde la menor complejidad que permiten una interpretación mucho más fácil como la que provee el análisis de componentes principales (PCA); hasta algunas, como t-SNE o UMAP, donde se reduce la dimensión logrando encontrar agrupaciones, pero perdiendo un poco de interpretación.

2.1.1. Análisis de Componentes Principales (PCA)

Para realizar una exploración inicial de los datos disponibles, se utiliza PCA y así identificar las variables que contienen el mayor significado en relación a los datos y su variabilidad. El análisis se basa en la proyección del conjunto de datos a un espacio donde los ejes sean una combinación lineal de los ejes originales. De este modo, los nuevos ejes o componentes contienen la información del aporte de cada variable a esta proyección [2].

Es requisito para PCA que la matriz de datos de entrada esté normalizada [2], para que los valores de las características sean comparables entre sí. La normalización consiste en que cada columna debe tener media cero y varianza unitaria. Esto se logra restando a cada dato de la columna su media y dividiendo el resultado por la desviación estándar de la columna.

La transformación de los datos por medio de PCA se realiza con una proyección ortogonal calculada de la siguiente forma. Sea X la matriz de datos con N filas correspondientes a la cantidad de datos y sus M columnas con las características. Su descomposición en valores singulares es:

$$X = P\Delta Q^T \quad (2.1)$$

donde P es la matriz izquierda de vectores propios de tamaño $N \times L$ donde $L = \min N, M$, y Q derecha de vectores propios de tamaño $M \times L$. Con Δ como la matriz diagonal de valores propios de tamaño L .

La inercia de una columna es definida como:

$$\gamma_m^2 = \sum_n x_{n,m}^2 \quad (2.2)$$

Multiplicando X por Q se obtiene la proyección de los datos en la componentes principales, esto es por:

$$F = XQ = P\Delta Q^T Q = P\Delta \quad (2.3)$$

siendo F la proyección de tamaño $N \times M$ y Q es la matriz de proyección y conocida como la matriz de scores o loading_scores. Esta matriz entrega los coeficientes que tiene cada característica de los datos en cada componente. Con ella se puede utilizar para obtener la principal característica en cada componente.

Se tiene que las componentes van reduciendo su inercia desde la primera a la última. Se puede tomar el ratio entre inercia sobre total de inercia por columna para determinar la cantidad de componentes significativas. A esto se le llama seleccionar por ratio de varianza explicada. Seleccionar las primeras componentes hasta que la varianza total explicada sea del 80 o 90 % significa tomar dicho porcentaje de la información presente en los datos.

Seleccionando las primeras componentes suficientes para explicar un buen porcentaje de varianza, se puede ver en ellas las variables que más importancia tienen mirando los coeficientes lineales en las componentes seleccionadas.

2.1.2. t-distributed stochastic neighborhood embedding (t-SNE)

El uso de t-distributed stochastic neighborhood embedding (t-SNE) como reductor de dimensionalidad para clustering es algo que se ha estudiado y donde se han generado propuestas para su mejor uso [3].

El algoritmo de t-SNE transforma X la matriz de datos de tamaño $N \times M$ con N como la cantidad de muestras y M las dimensiones, en la matriz proyectada Y de tamaño $N \times S$ con $S \ll M$ típicamente tomando valores de 2 o 3. La probabilidad conjunta $p_{i,j}$ que denota la similitud entre x_i con x_j se calcula como:

$$p_{i|j} = \frac{\exp(-\|x_i - x_j\|^2/2\sigma^2)}{\sum_{k \neq i} \exp(-\|x_i - x_k\|^2/2\sigma^2)} \quad (2.4)$$

y

$$p_{ij} = \frac{p_{i|j} + p_{j|i}}{2N} \quad (2.5)$$

donde σ es elegido de tal forma que el coeficiente de *perplexity* de P_i sea equiparado al definido por el usuario, donde P_i es la distribución condicional de todos los puntos dado x_i . La similitud entre y_i e y_j en el espacio de proyección queda definida como:

$$q_{ij} = \frac{(1 + \|y_i - y_j\|^2)^{-1}}{\sum_{k \neq i} (1 + \|y_k - y_i\|^2)^{-1}} \quad (2.6)$$

Por lo que t-SNE encuentra los puntos $Y = \{y\}_i^N$ que minimizan la divergencia Kullback-Leibler (KL) [4] entre la distribución conjunta P de puntos en el espacio de entrada y la distribución conjunta de puntos en el espacio de salida Q :

$$C(Y) = KL(P||Q) = \sum_{i \neq j} p_{ij} \log \frac{p_{ij}}{q_{ij}} \quad (2.7)$$

Los puntos Y son inicializados de forma aleatoria y se minimiza $C(Y)$ utilizando gradiente descendiente, cuya expresión se deriva en [5] y se divide en dos como en [3]:

$$\frac{1}{4} \frac{\delta C}{\delta y_i} = \sum_{j \neq i} p_{ij} q_{ij} Z(y_i - y_j) - \sum_{j \neq i} q_{ij}^2 Z(y_i - y_j) \quad (2.8)$$

donde Z es una constante global de normalización

$$Z = \sum_{k \neq l} (1 + \|y_k - y_l\|^2)^{-1} \quad (2.9)$$

Dado que se quiere minimizar el funcional, se toma el negativo del gradiente como la dirección de optimización:

$$-\frac{1}{4} \frac{\delta C}{\delta y_i} = \sum_{j \neq i} p_{ij} q_{ij} Z(y_i - y_j) - \sum_{j \neq i} q_{ij}^2 Z(y_i - y_j) \quad (2.10)$$

El primer término está asociado a la atracción y el segundo a la repulsión de los puntos resultantes en la proyección [5]. Esto se debe a que el primero tenderá al promedio ponderado entre y_i e y_j , ya que si los puntos están cerca en el espacio original, tenderán a estar cerca en el de proyección. Mientras que el segundo tiene el mismo principio, pero de efecto contrario, en este caso, solamente depende de qué tan cerca estén los puntos en el espacio original [3].

t-SNE es superior a otras técnicas como mapeo de Sammon, Isomap y Locally Linear Embedding (LLE) de acuerdo a [5]. Y elegir los parámetros es fácil, variando el de *perplexity* basta para realizar un análisis exploratorio.

Una de las desventajas de t-SNE, es que no es reproducible ni puede ser usado fácilmente en flujos de datos, ya que no representa una transformación del espacio original al de proyección, si no que ajusta el espacio de proyección de acuerdo a la densidad de puntos en el espacio original. Por lo que este algoritmo es utilizado para la identificación de clusters en la primera fase del manejo de datos.

2.1.3. Uniform Manifold Approximation and Projection for Dimension Reduction (UMAP)

UMAP [6] es un algoritmo para reducción de dimensionalidad que ha sido usado en variadas ocasiones para reducir la dimensión de datos multivariable [7][8][9]. Incluso siendo utilizado en series de tiempo como en [10], utilizando una representación de atractor para las series de tiempo, donde cada columna corresponde a un regresor de la serie.

En esta sección se realizará un resumen de lo que se trata este algoritmo, dejando para el ávido lector el adentrarse profundamente en el detalle de UMAP en [6]. El análisis se centrará en identificar los parámetros a variar para encontrar la realización de una reducción de dimensión efectiva.

En [6] se especifica que UMAP es un algoritmo de reducción de dimensionalidad no lineal que trabaja sobre los siguientes axiomas:

- Existe un conjunto de datos distribuidos uniformemente en el espacio que abarcan.
- El conjunto de puntos de interés está localmente conectado.
- Preservar la estructura topológica de este conjunto de puntos es la principal meta.

UMAP realiza una caracterización de los datos provistos como un grafo de vecinos más cercanos en el espacio de características, donde el propósito es generar una especie de grafo que cubra por completo los puntos. Para generar este grafo se generan bolas sobre cada punto de un radio fijo que permiten encontrar los vecinos más cercanos con la intersección de estas bolas. El problema, es que en datos reales se tienen puntos aislados que no conectan con otros según este principio. Para lograr esta uniformidad, se propone un ajuste a la geometría del espacio considerando la geometría de Riemann. Es decir, se generan métricas locales que permiten tener bolas de tamaño unitario, utilizando para ello un conjunto de k -vecinos cercanos. Cada punto tendrá su propia función de distancia, lo que permitirá la existencia de estas bolas de radio unitario. De esta forma, se logra tener el espacio ocupado por los datos uniformemente distribuido, y así obtener los puntos localmente conectados. De este modo, se cumplen los dos primeros principios para realizar el algoritmo de reducción de dimensión, cambiando la selección del radio por la selección de los k -vecinos [6].

El tratamiento de los vecinos más cercanos permite un buen manejo de los datos en alta dimensión, ya que, debido a que a grandes dimensiones los puntos tienden a estar más separados entre sí y las distancias tienden a aumentar. Este mismo efecto hace que las distancias en alta dimensionalidad sean similarmente altas, lo que permite que estableciendo el número de k -vecinos por el de la distancia se enfoque en distancias con más sentido que estableciendo una distancia absoluta cuya diferencia entre vecinos sea muy baja.

Teniendo caracterizado el espacio con métricas locales se tiene el problema de que entre ellas no son compatibles. Es decir, se tendrá el grafo conectado con aristas cuyos pesos no son comparables entre sí. Una cosa que no se mencionó hasta ahora, es que las bolas y sus métricas corresponden a un conjunto difuso. Es decir, las métricas de una bola se superponen la una con la otra ante la probabilidad de estar en una o la otra. Es por ello, que para que las aristas del grafo puedan conversar entre sí, se aplica este principio para definir el peso de la arista o la distancia entre dos puntos, como la unión de las distancias:

$$d_{ab} = a + b - a \cdot b \tag{2.11}$$

con a y b la distancia del punto A hasta B visto desde A , y b la distancia de A hasta B desde B . Siendo $A, B \subset E$ el conjunto de puntos vecinos entre sí. Esto corresponde a la existencia de una de las dos distancias.

De esta forma, se termina con un conjunto de puntos en el espacio de alta dimensionalidad que definen un grafo dirigido cuyos pesos están determinados por las distancias de un punto al otro por medio de un truco geométrico utilizando bolas unitarias cuyos bordes son difusos y métricas localmente definidas.

A continuación, se debe llevar este grafo a una proyección de baja dimensión, la cual corresponde al espacio de cuya métrica es bien conocida y es la euclidiana. Se quiere que la proyección tenga una sola métrica y no una que varía de forma local. También, debemos establecer la mínima distancia al vecino más cercano, esto se deja como hiperparámetro `min_dist`.

Finalmente, para determinar la forma de la proyección se debe proceder a ajustarla a la mejor representación del conjunto de datos en alta dimensionalidad a la baja dimensión. La función a optimizar consiste en la entropía cruzada entre los pesos de los puntos en alta dimensión (pesos difusos d_{ab} como en 2.11) siendo el peso $w_h(e)$ una medida de probabilidad de que dos puntos estén cercanos en alta dimensión, y el de baja dimensión, el peso entre los puntos $w_l(e)$, siendo e la tupla entre dos puntos. De modo que la entropía cruzada es:

$$\sum_{e \in E} w_h(e) \log \left(\frac{w_h(e)}{w_l(e)} \right) + (1 - w_h(e)) \log \left(\frac{1 - w_h(e)}{1 - w_l(e)} \right) \quad (2.12)$$

donde el primer término corresponde a una fuerza atractiva entre los puntos A y B , ya que si $w_h(e)$ es grande se beneficia una representación con una probabilidad $w_l(e)$ alta, lo que quiere decir que los puntos en la proyección están muy juntos. Y por el otro lado, si se minimiza el lado derecho se tiene que si $w_h(e)$ es bajo, se beneficiará un valor muy pequeño de $w_l(e)$ y probablemente los puntos no estén conectados o conectados débilmente.

Finalmente, el algoritmo consiste en [6]:

1. Construir una representación topológica difusa como se describe anteriormente, con el truco de las métricas locales y la creación del grafo cuyos pesos son la probabilidad de que los puntos estén cerca o no.
2. Optimizar el grafo en baja dimensión, donde los puntos están sujetos a las fuerzas repulsoras y atractoras de la entropía cruzada entre ambas representaciones.

Finalmente, algunas consideraciones que se deben tener para la utilización de UMAP.

Primero, este es un algoritmo estocástico que logra buenas representaciones en baja dimensión de datos de alta dimensionalidad, sin embargo, al ser estocástico puede generar variadas representaciones dependiendo de su inicialización. En este trabajo se utiliza siempre una semilla fija para sus realizaciones, y posteriormente se revisa el sentido de la separación realizada por medio de mapas de calor de las variables del proceso.

Segundo, se debe busca la mejor representación por medio de la selección de hiperparámetros del algoritmo, ya que dependiendo de los resultados buscados (clusters altamente compactos, clusters difusos, etc) serán los parámetros asociados al algoritmo.

Tercero, las métricas de distancia en el espacio de proyección se pierden debido a la naturaleza del algoritmo de optimización, donde se construye el grafo inicial con métricas locales en lugar de globales. Es por ello que al utilizar algoritmos de clustering se debe tener cuidado en clasificar los puntos que caen fuera de los clusters bien definidos.

2.2. Algoritmos de clustering

Los principales algoritmos de clustering utilizados en este trabajo son k-means y DBSCAN.

2.2.1. K-means

En [11] se enumeran distintas aplicaciones que ha tenido k-means y sus variantes en distintos campos del conocimiento como: reconocimiento facial, redes de sensores inalámbricos, predicción de potencia de energía eólica, etc. El algoritmo consiste en, a partir de una cantidad k de clusters, asignar aleatoriamente los puntos a clusterizar a cada uno. Minimizando el error de clasificación que se determina como [12]:

$$E(\{m\}_1^M) = \sum_{i=1}^N \sum_{k=1}^M I(x_i \in C_k) \|x_i - m_k\|^2, \quad (2.13)$$

donde C_k es un cluster, m_k su centro en el espacio, N la cantidad de puntos, M la cantidad de clusters, e $I(\cdot)$ la función indicatriz: 1 si es que pertenece al cluster C_k , 0 de lo contrario. Lo que varía en el algoritmo es la asignación de los puntos a cada cluster. Existen distintos tipos de inicialización de los centros, generando distintas variantes del algoritmo.

El resultado final del algoritmo son k clusters que se reparten los puntos en el espacio de forma que cada centro está minimizando la distancia de los puntos más cercanos a él.

Los resultados de k-means dependerán directamente de la distribución de los puntos, siendo que k-means tiende a formar esferas entorno a los centros de los clusters, por lo que si dos clusters tienen formas alargadas y están cercanos entre sí, es posible que k-means no pueda diferenciar de forma correcta entre los dos.

2.2.2. Density Based Spatial Clustering of Applications with Noise (DBSCAN)

DBSCAN es un algoritmo con la capacidad de encontrar clusters en el espacio cuya forma puede ser arbitraria, robusto al ruido puede clasificar un punto como también puede no hacerlo, dejando fuera puntos que están lejos de acuerdo a los parámetros del algoritmo. De esta forma, DBSCAN es ideal para encontrar clusters con la presencia de ruido en el espacio.

Los parámetros a ajustar del algoritmo corresponden a:

- la distancia del vecindario cercano a un punto eps ,
- y la cantidad mínima de puntos de un cluster.

En la figura 2.1 se muestra el algoritmo en el formato original publicado en [13].

```

ExpandCluster(SetOfPoints, Point, ClId, Eps,
              MinPts) : Boolean;
seeds:=SetOfPoints.regionQuery(Point,Eps);
IF seeds.size<MinPts THEN // no core point
  SetOfPoint.changeClId(Point,NOISE);
  RETURN False;
ELSE // all points in seeds are density-
  // reachable from Point
  SetOfPoints.changeClIds(seeds,ClId);
  seeds.delete(Point);
  WHILE seeds <> Empty DO
    currentP := seeds.first();
    result := SetOfPoints.regionQuery(currentP,
                                       Eps);
    IF result.size >= MinPts THEN
      FOR i FROM 1 TO result.size DO
        resultP := result.get(i);
        IF resultP.ClId
          IN {UNCLASSIFIED, NOISE} THEN
          IF resultP.ClId = UNCLASSIFIED THEN
            seeds.append(resultP);
          END IF;
          SetOfPoints.changeClId(resultP,ClId);
        END IF; // UNCLASSIFIED or NOISE
      END FOR;
    END IF; // result.size >= MinPts
    seeds.delete(currentP);
  END WHILE; // seeds <> Empty
  RETURN True;
END IF
END; // ExpandCluster

DBSCAN (SetOfPoints, Eps, MinPts)
// SetOfPoints is UNCLASSIFIED
ClusterId := nextId(NOISE);
FOR i FROM 1 TO SetOfPoints.size DO
  Point := SetOfPoints.get(i);
  IF Point.ClId = UNCLASSIFIED THEN
    IF ExpandCluster(SetOfPoints, Point,
                     ClusterId, Eps, MinPts) THEN
      ClusterId := nextId(ClusterId)
    END IF
  END IF
END FOR
END; // DBSCAN

```

Figura 2.1: Imagen del algoritmo de Density Based Spatial Clustering of Applications with Noise (DBSCAN) tomado de [13]

El algoritmo parte recorriendo por los puntos no clusterizados. Se verifica que los puntos vecinos sean alcanzables dentro del radio determinado por **eps**. Si la cantidad de puntos es inferior a la mínima de un cluster, entonces todos ellos se catalogan como ruido. De lo contrario, se determina que todos esos puntos corresponden a un solo cluster y se buscan los puntos no clusterizados en la vecindad de los nuevos puntos del cluster, estos también se añaden al conjunto del cluster y se sigue buscando iterativamente. Esta iteración termina cuando todos los puntos cercanos en densidad a este cluster son clasificados como pertenecientes o ruido. Luego se vuelve a comenzar con otros puntos que están clasificados como ruido.

Una de las ventajas que representa DBSCAN para este trabajo, es la capacidad de encontrar clusters de diferente forma dentro del espacio. Al ser utilizado con UMAP como algoritmo que genera la proyección, es difícil intuir que al utilizar un algoritmo que justamente utiliza métricas euclidianas para clasificar un punto dentro de un cluster o no, para la tarea de clustering. Sin embargo, DBSCAN al seleccionar clusters por el criterio de densidad, conversa bien con la heurística de UMAP que beneficia la proximidad de puntos similares, es decir, generando conjuntos densos de puntos, que son fácilmente identificables por DBSCAN.

2.3. Degradación de aceites de motor

Para el estudio de la degradación de los motores en camiones mineros, se debe definir un indicador de daño. Para ello, como no se cuenta con una medición directa de la degradación, se debe generar un indicador indirecto. Para ello, en la comunidad y en el conocimiento experto se ha encontrado que un buen indicador de la degradación del motor se encuentra en la información contenida en el análisis del aceite de lubricación interna del motor [14][15][16][17].

El estudio de la lubricación y las partes móviles que estos protegen, se llama tribología. Esta ciencia tiene como objetivo el estudio de las propiedades y elementos presentes en los compuestos que sirven de intermediario entre dos superficies sólidas. Un estudio tribológico considera tanto las concentraciones de elementos en el aceite, como sus propiedades: viscosidad, acidez. Además de la existencia de otros subproductos de la operación del camión, como la presencia de hollín o sulfatos producidos tras la combustión del motor.

En [15][16] se analiza la relación de la degradación del aceite y del motor con las concentraciones de distintos elementos y cambios en propiedades del aceite. Para ello, se analizan los aceites de un conjunto de vehículos en uso, y se estudia la correlación de los componentes metálicos en el aceite con las horas de uso del aceite.

En [16] se establece la relación en que los mecanismos del componente tribomecánico se relacionan con el análisis tribológico:

[...] porque los componente móviles de sistemas tribomecánicos necesariamente degradan, cuyos contaminantes y residuos son recolectados en el aceite usado para lubricación, y porque es necesario monitorear cambios en las propiedades del fluido durante la operación, la conclusión debe ser que entre todas las técnicas de monitoreo, la clave para mantener la condición operativa y para lograr ciertos efectos tecno-económicos, es el monitoreo de los lubricantes.

También se establece que, dado que los metales actúan como catalizador de la oxidación y tienen efectos abrasivos, es necesario mirar de cerca su cantidad en el aceite [16].

Pueden ser varios los orígenes de las partículas presentes en el aceite, desde los aditivos, la atmósfera, residuos de roces entre piezas metálicas, hasta del combustible. Existe cierta clasificación que permite encontrar el origen, ya que existen aditivos comunes y las piezas metálicas del motor comparten características minerales, la tabla 2.1

Entre las investigaciones que han tratado de generar un indicador de degradación a partir de la información tribológica de motores en el campo [14][16][17], se destaca [14] donde se realizan estudios de estimación directa de la ocurrencia de falla. En ella se relaciona la falla a niveles altos de concentración de elementos como Fe y Pb, para los que se realiza un modelo de degradación en función de la evolución de estos, y a partir de esto se genera una distribución de la ocurrencia de la falla. En [17] estudia la degradación del motor en una flota de buses, donde se enfatiza en la posibilidad de integrar otras variables al análisis para la generación de un indicador más robusto.

2.4. Filtros Bayesianos

En ingeniería existen muchos sistemas que requieren la estimación de parámetros en línea a partir de mediciones ruidosas. Existen poderosas herramientas de aproximación de parámetros por medio de procesos estocásticos y sistemas dinámicos. Estas herramientas se basan en aproximaciones Bayesianas al problema, donde se caracteriza el proceso con ecuaciones de estado que permiten obtener la ecuación de medición y la de evolución [18], donde se busca la solución óptima de estimación de la función de distribución de probabilidad (pdf) a posteriori del sistema.

La metodología en [18] desarrolla un algoritmo de estimación en dos fases: la primera de predicción y la segunda de actualización. Este mecanismo funciona en línea a medida que lleguen los datos a estimar, donde se aplican los principios Bayesianos para mezclar la información del modelo con la de la medición.

Para definir el problema de estimación [18] es necesario considerar la secuencia $\{x_k, k \in \mathbb{N}\}$

Tabla 2.1: El origen de ciertos elementos de desgaste en el aceite de motor generada en [15].

Elemento	Posible origen de metal
Fe	fundas de cilindro, anillo de pistón, rodamientos, cojinetes de deslizamiento, alizador de válvula, eje de levas, cigüeñal
Al	pistón, rodamientos de Al-Sn, turbocompresor
Ag	cojinetes de deslizamiento, rodamientos, partes plateadas
Cr	partes cromadas, pistones, cilindros, alizador de válvula, tuberías de escape, conectores
Cu	rodamientos Cu-Pb, cojinetes, enfriadores de aceite, cigüeñal, distribución, inyector de combustible, regulador
Pb	rodamientos Cu-Pb, gasolina, aditivos
Sn	partes de bronce, rodamientos, pistones
B	anticongelante
Na	anticongelante
Ca	provenientes de la atmósfera
Si	partículas atmosféricas
Zn, Mg, Mo	aditivos

con ecuación de evolución:

$$x_k = f_k(x_{k-1}, v_{k-1}) \quad (2.14)$$

donde $f_k : \mathbb{R}^{n_x} \times \mathbb{R}^{n_v} \rightarrow \mathbb{R}^{n_x}$ función no lineal del estado x_{k-1} , $\{v_{k-1}, k \in \mathbb{N}\}$ como un proceso ruidoso i.i.d., con n_x, n_v dimensiones de la variable del proceso y del ruido vectorizado [18]. El objetivo es estimar el estado x_k a partir de las mediciones:

$$z_k = h_k(x_k, n_k) \quad (2.15)$$

donde $h_k : \mathbb{R}^{n_x} \times \mathbb{R}^{n_n} \rightarrow \mathbb{R}^{n_z}$ es posiblemente una función no lineal; con $\{n_k, k \in \mathbb{N}\}$ i.i.d. medición de ruido. Y n_z, n_n dimensiones de la medición y del ruido de la medición respectivamente. Particularmente, se buscan estimaciones filtradas de x_k basados en el conjunto de todas las mediciones disponibles $z_{1:k} = \{z_i, i = 1, \dots, k\}$ hasta el instante k .

El proceso de estimación, desde una perspectiva bayesiana [18], consiste en en calcular de forma recursiva hasta k cierto grado de confianza en x_k . Para ello se requiere construir la pdf $p(x_k|z_{1:k})$. Se asume que $p(x_0|z_0) = p(x_0)$ del estado inicial, lo que se conoce como prior. En principio, la pdf $p(x_k|z_k)$ puede ser obtenida de forma recursiva en dos fases, predicción y actualización.

Supongamos que la pdf $p(x_{k-1}|z_{1:k-1})$ al tiempo $k-1$ está disponible. La fase de predicción involucra usar el modelo del sistema para obtener el la pdf prior del estado en el tiempo k via la ecuación de Chapman-Kolmogorov:

$$p(x_k|z_{1:k-1}) = \int p(x_k|x_{k-1})p(x_{k-1}|z_{1:k-1})dx_{k-1} \quad (2.16)$$

En la ecuación 2.16 se utiliza el principio Markoviano de $p(x_k|x_{k-1}, z_{1:k-1}) = p(x_k|x_{k-1})$. El modelo probabilístico de evolución de estado $p(x_k|x_{k-1})$ está definido por el sistema de ecuaciones 2.14 y los estadísticos conocidos de v_{k-1} [18].

Al instante k , se dispone de una medición de z_k que es usada para actualizar el prior vía la regla de Bayes:

$$p(x_k|z_{1:k}) = \frac{p(z_k|x_k)p(x_k|z_{1:k-1})}{p(z_k|z_{1:k-1})} \quad (2.17)$$

con la constante de normalización

$$p(z_k|z_{1:k-1}) = \int p(z_k|x_k)p(x_k|z_{1:k-1})dx_k \quad (2.18)$$

depende de la función de verosimilitud $p(z_k|x_k)$ definida por el el modelo de medición en 2.15 y los estadísticos conocidos de n_k . Se utiliza z_k en 2.17 para modificar la densidad del prior y obtener la posterior del estado actual.

La relación de recurrencia entre 2.16 y 2.17 forman los bloques básicos de la solución Bayesiana óptima [18].

El filtro de partículas, descrito sencillamente en [19], es un algoritmo que obtiene muestras secuenciales desde un estado objetivo cuya distribución de probabilidad $\pi_k(x_{0:k})$ puede generar un conjunto de $N \gg 1$ con pesos variables $\{w_k^{(i)}, x_{0:k}^{(i)}\}_{i=1}^N, w_k^{(i)} > 0, \forall k \geq 1$ que satisfacen:

$$\sum_{i=1}^N w_k^{(i)} \phi_k(x_{0:k}^{(i)}) \xrightarrow{N \rightarrow \infty} \int \phi_k(x_{0:k}) \pi_k(x_{0:k}) dx_{0:k} \quad (2.19)$$

donde ϕ_k es cualquier función π_k -integrable. Se elige la distribución $\pi_k(x_{0:k}) = p(x_{0:k}|y_{1:k})$ la pdf posterior del vector estado condicional a las observaciones ruidosas [19].

Sea en el tiempo $k - 1$ un conjunto de N caminos (partículas) $\{x_{0:k-1}^{(i)}\}_{i=1}^N$ disponibles. Estos caminos están distribuidos de acuerdo a $q_{k-1}(x_{0:k-1})$ (también llamada la densidad de importancias al tiempo $k - 1$). Luego, se utiliza el filtro de partículas para obtener nuevos caminos distribuidos aproximadamente como $\pi_k(\hat{x}_{0:k})$.

La posterior puede ser escrita como:

$$\hat{\pi}_k^N(x_{0:k}) = \sum_{i=1}^N w_{0:k}^{(i)} \delta(x_{0:k} - \hat{x}_{0:k}^{(i)}) \quad (2.20)$$

donde $w_{0:k}^{(i)} \propto w_{0:k}(\hat{x}_{0:k}^{(i)})$ y $\sum_{i=1}^N w_{0:k}^{(i)} = 1$ [19].

El algoritmo presenta un solución óptima bajo algunos supuestos como el filtro de Kalman, que supone que la distribución posterior de cada paso es una gaussiana parametrizada por una media y covarianza. Esto en muchos casos no se cumple, y la distribución cambia de comportamiento a medida que avanza el proceso. En este caso, existe algoritmo sub-óptimos del filtro de partículas como el muestreo secuencial de importancia o *sequential importance sampling* (SIS).

2.5. Estimación de Tiempo de Falla

La probabilidad de caer en falla está bien caracterizada para umbrales y, la metodología y herramientas para su desarrollo se encuentran en [20]. En [21] se define una metodología para calcular la ToF de zonas de peligro probabilísticas y poder caracterizar la distribución con colas bien definidas. A continuación, veremos cómo se llega a ese planteamiento.

La distribución del tiempo de falla o ToF para un umbral determinístico, se puede definir como:

$$P(\text{ToF} = k) = \sum_{i=1}^{N_p} w_k^{(i)} P(x_k^{(i)} \geq T | y_{1:k_p}) \quad (2.21)$$

dado que $w_k^{(i)} P(x_k^{(i)} \geq T | y_{1:k_p})$ es la probabilidad de caer en el evento de falla catastrófica condicional a una partícula en específico [21]. Siendo $\{x_k^{(i)}\}_{i=1}^{N_p}$ el peso de las partículas al instante k .

De esta forma, la ToF quedará definida para una zona de peligro definida por un umbral único, como:

$$\text{ToF}^{(i)} = \inf \{k : \{k > k_p\} \wedge \{x_k^{(i)}\} \geq T | y_{1:k_p}\} \quad (2.22)$$

En el caso en que se esté trabajando con una zona de peligro probabilística y no un umbral fijo,

$$\text{ToF}^{(i)} = \inf \{k : \{k > k_p\} \wedge \{F(x_k^{(i)}) = 1\}\} \quad (2.23)$$

donde $F(\cdot)$ es la función de verosimilitud de falla que denota la condición de falla dado una partícula:

$$F(x_k^{(i)}) = \begin{cases} 1 & \text{condición de falla} \\ 0 & \text{condición operativa} \end{cases} \quad (2.24)$$

$F(\cdot)$ puede ser pensado como una realización de un proceso de Bernoulli donde la probabilidad de falla es una función de la verosimilitud que define la zona de peligro. A medida que se adentra en dicha zona, es decir, la partícula $x_k^{(i)}$ se adentra en la zona de peligro, su probabilidad de falla naturalmente aumenta. $F(x_k^{(i)}) \sim \text{Bernoulli}(p(x_k^{(i)}))$. En este caso, es una función que mapea el espacio de una forma no lineal como:

$$p(x) = \begin{cases} 1 & x \geq T^+ \\ p^* & x \in (T^-, T^+) \\ 0 & x \leq T^- \end{cases} \quad (2.25)$$

donde T^- y T^+ denotan los límites inferior y superior de la zona de peligro [21].

Justamente en [21] se trabajan métodos para bien caracterizar la distribución de la ToF en el tiempo. Para entender de qué trata cada uno, se tiene que considerar que las partículas que van cayendo en condición de falla, normalmente quedan fuera del conteo realizado para continuar con el cálculo. Las propuestas para el cálculo de la ToF son 3:

1. Todas las partículas tienen el mismo peso y no se vuelven a contar entre las que van superando el umbral o la zona de peligro.

2. Las partículas tienen pesos acorde a la distribución de verosimilitud subyacente a los datos. También las partículas se van perdiendo a medida que se adentran en la zona de falla.
3. El último método desarrolla un concepto de re-muestreo de los pesos de todas las partículas a medida que vayan cayendo en condición de falla. Esto se prueba para que la distribución no pierda granularidad y permita ser aproximada con un poco de mayor precisión.

Nosotros nos enfocaremos en el tercer método, el cuál permite caracterizar las colas de la distribución de mejor manera. El algoritmo se puede ver en 2.2 y una figura de su funcionamiento del artículo original junto a él.

Algorithm 4 ToF-PMF computation when a probabilistic hazard zone is considered

- 1: $p \leftarrow$ set of N_p particles in time k_p
- 2: $W \leftarrow [1 / N_p]$
- 3: **while** $k \leq Prediction_horizon$ **do**
- 4: $p \leftarrow Prediction_step(p)$
- 5: $l \leftarrow hazard\ zone\ CDF\ for\ p[k]$
- 6: $B \leftarrow Bernoulli(l)$
- 7: $pmf[k] \leftarrow \sum W[find(B == 1)]$
- 8: Discard particles in p that $(B == 1)$
- 9: $W \leftarrow [\sum W(find(B == 1)) / N_p]$
- 10: Resample particles in p that $(B == 1)$
- 11: **end while**




Figura 2.2: Algoritmo de estimación de ToF en zona de peligro probabilística junto a visualización del algoritmo tomado de [21]

3. Clustering de Modos de Operación

Un estado de operación genérico lo determinamos a partir de un periodo determinado en que el motor diésel se encuentra operando. Este periodo deber tener características determinadas como, por ejemplo, una combinación de valores medios alto de las variables operacionales del activo. Este estado de operación se caracteriza por repetirse en el tiempo, donde el motor pasa de un estado a otro a lo largo de toda la operación.

Para determinar los modos de operación del motor se deben conocer las características de su operación. En el caso de algunos activos que son sometidos a distintas etapas en la operación; como aeronaves cuyos modos se pueden catalogar como: desplazamiento en pista, despegue, ascenso, crucero, aterrizaje, etc. es fácil determinar los modos de uso a partir de valores como altitud, velocidad o datos de posicionamiento. Mientras que en otros activos se debe abordar de otra forma para llegar a dicha caracterización, y es donde se tienen que buscar patrones en los datos operacionales que permitan determinar un régimen en que los datos en determinado intervalo se denominen estado operacional.

Para poder determinar los estados de operación de un camión minero, es necesario explorar las variables operacionales del motor. Las variables disponibles son principalmente velocidades, aceleración, revoluciones por minuto, potencia, carga, presiones, etc. Con la exploración de datos se busca determinar las principales variables para el clustering, separando aquellas que solamente aportan ruido al proceso. Las variables a utilizar deben hacer sentido a la hora de determinar un estado de operación, como por ejemplo, que un estado se caracterice por presentar baja velocidad, alta carga y altas presiones, indicando que el activo está bajo estrés.

En el presente capítulo se desarrolla una metodología que permite caracterizar en clusters los datos operacionales del camión. Se describirán los elementos necesarios para realizar el clustering como el procesamiento de datos, los algoritmos utilizados, el ajuste de los modelos generados y, finalmente, los resultados obtenidos.

3.1. Objetivo

El objetivo del clustering es encontrar un número de conjuntos de datos que sean parecidos entre sí y tengan sentido en su separación del resto. Es decir, encontrar conjuntos de puntos que compartan características similares entre sí y, obviamente, diferente al resto. Para ello se debe limpiar, caracterizar y modificar el conjunto de datos para que el algoritmo de reducción funcione adecuadamente. Por ejemplo, entregar la data normalizada al algoritmo de PCA es una forma de definir el conjunto de datos a entrar en el algoritmo.

En este caso, debemos establecer un par de supuestos clave:

- La independencia de los puntos.

Esto se refiere a determinar un periodo entre dato a dato que permita decir que son dos muestras distintas o obtenidas de distribuciones de datos distintos. En este caso, se definirá un intervalo de tiempo sobre el cual se quiere determinar el estado de operación. Resultando en una agregación de la data disponible a dicho intervalo y generando características de los datos que permitan determinar un estado de operación en esa hora.

- La decorrelación entre los datos a analizar o selección de características.

La necesidad de tener características que no estén correlacionadas entre sí, permite que los algoritmos que buscan clusters en el espacio puedan fijarse en una variable importante. al tener dos o más variables altamente correlacionadas, en PCA se tiende a favorecer una dirección en el espacio de proyección que acompaña la dirección de ambas variables altamente correlacionadas. En otros algoritmos sucede similar.

Dados los supuestos establecidos, se procede a evaluar los métodos disponibles para la realización de clustering. Se realizan experimentos con dos métodos: PCA y UMAP, ya que no es el foco realizar una investigación intensiva en el descubrimiento de modos de operación. Sin embargo, se explora el algoritmo t-SNE para obtener una comparativa visual de la separación de los clusters contra UMAP.

En el caso de PCA, este se utiliza para la búsqueda de variables en el espacio de variables que tengan alto coeficiente en las componentes de proyección. Esto se realiza con el argumento de encontrar variables que tengan mayor direccionalidad y por ende mayor información de la variabilidad de los datos. PCA también es utilizado para la visualización y primera exploración de posibles clusters en los datos. De modo que pueda seleccionarse con expertos las mejores variables para el posterior clustering definitivo.

UMAP es seleccionado como el algoritmo de clustering de preferencia dada su robustez ante la alta correlación de variables (en el caso de que la limpieza de variables haya salido incorrecta), y donde se le entregan: primero todas las variables para una primera inspección y luego las variables seleccionadas con el método de PCA para la segunda inspección. De estas, se selecciona el método que permita discriminar clusters más claros.

Los resultados esperados son la determinación de un set de clusters cuya separación sea notable y las distribuciones de los datos obtenidos en ellos tengan sentido con la operación (curvas de rpm al alza, rpm estables, cambios bruscos en alguna variable con determinada dirección, etc).

3.2. Procedimiento para obtener el clustering

La preparación de los datos para el clustering se realiza a partir de seleccionar las variables que entrarán al proceso, quitando outliers y variables altamente correlacionadas. Para ello se realiza un análisis de distribuciones de las variables disponibles y luego un análisis de correlación para dejar las que contengan mayor información. Para seleccionar las que tienen mayor información, se ve la cantidad de datos nulos que tiene, su variabilidad, si existe corresponde a una variable con información intuitiva y si presenta varios modos en la distribución. Finalmente, se deben formatear los datos para el clustering, como dejar datos categóricos, numéricos, etc. en el formato correcto.

Para finalizar la primera fase, se deben dejar los datos agregados a un determinado intervalo de tiempo, de este modo se facilitan los análisis posteriores estableciendo un paso de tiempo constante entre un dato y otro. Además, se establece un periodo de tiempo que permita, de cierta forma, independizar las muestras. Esta independencia es necesaria para realizar el clustering, ya que se busca que los datos sean muestreados de distribuciones distintas.

Luego del formateo, y durante el proceso de agregar los datos, se debe tener en cuenta el cómo caracterizar de forma adecuada el periodo de tiempo de análisis, ya que si se cuenta con muestras con una frecuencia mayor, digamos 5 minutos o segundos, si se quiere llevar a una hora al agregar los datos se puede perder mucha información si no se tiene cuidado.

3.2.1. Agregación de los datos

Para conservar la cantidad de información y que se minimice la pérdida de datos, se procede a generar características que permitan explicar lo que sucede con la variable en dicho periodo. Las principales características son relacionadas a la distribución de datos en ese periodo, por ejemplo, cuantiles, mínimo, máximo, media, moda, etc. También se pueden agregar valores relacionados a tendencias, como la pendiente de un ajuste lineal, o la ecuación de la recta.

Dependiendo del algoritmo que se utilice para el clustering, se deben o no limpiar las variables correlacionadas en esta fase. Por ejemplo, para encontrar clusters con PCA, es ideal que se puedan limpiar las variables altamente correlacionadas, para obtener componentes principales que no estén muy cargadas a un sub-conjunto de variables.

3.2.2. Estandarización de los datos

Para que un algoritmo de clustering pueda funcionar de forma adecuada, es necesario que las variables que entren sean comparables entre sí. En particular, k-means trata de generar esferas en el espacio de características, si una variable tiene una desviación estándar mucho más grande que las otras, tienden a formarse elipses en lugar de esferas, lo que provoca que los algoritmos tengan un rendimiento malo.

Para realizar el escalamiento de los datos, se utiliza un subconjunto del total de datos para entrenar un normalizador que deje los datos con media cero y desviación estándar unitaria. de este modo, todas las características tendrán el mismo peso e importancia. Este normalizador se utilizará posteriormente sobre el resto de los datos.

3.2.3. UMAP

El algoritmo predilecto para el análisis de clustering, es UMAP ya que permite entregarle variables correlacionadas a la entrada y ajuste de hiperparámetros más o menos intuitivo para buscar la cantidad adecuada de clusters.

3.3. Resultados del clustering

A partir de la limpieza de datos, se obtiene un conjunto de características sin correlación que permiten explicar los datos operacionales. Este conjunto de variables es luego sometida a la creación de nuevas características y la agregación de los datos, para finalizar con la normalización de la data. Con estos datos se procede a generar un análisis PCA para entender si a simple análisis se tiene alguna separación que haga sentido y permita profundizar en el clustering.

3.3.1. Agregación a 5 minutos

La seguidilla de experimentos se realiza para determinar la cantidad de tiempo a agregar a la data que permita caracterizar un modo de uso y contenga información relevante para el proceso. El primer experimento consiste en tomar la data agregada a alta frecuencia (5 minutos) para explorar los estados del camión a una resolución alta. Los datos que se toman para el experimento son los datos operacionales promediados en 5 minutos, asumiendo que el estado del camión no cambia radicalmente en 5 minutos. Los datos que se entregan son numéricos y no categóricos. Existe una etiqueta que clasifica entre distintos estados del motor como Alta en Vacío, Ralentí, Retardo y Potencia, con un estado intermedio que se denomina Transición.




Figura 3.1: Proyección PCA de principales variables operacionales del camión.

En la figura 3.1 se puede apreciar que el experimento encuentra 3 clusters que se forman en la proyección PCA, pero la división no es tan clara y no permite generar interpretaciones al respecto. Sin embargo, los *loading plots* se puede apreciar que existen fuertes direcciones en las componentes. El paso siguiente será utilizar otro algoritmo de clustering que permita visualizar la separación de forma más clara.

Se utiliza t-SNE como segunda aproximación y en la figura 3.2 se obtiene una separación un poco más evidente entre los clusters. Sin embargo, es difícil aplicar un algoritmo de distinción

de clusters a esta proyección ya que existen puntos entre ellos que no son fáciles de distinguir. Por lo que se procede a aplicar el algoritmo UMAP sobre las mismas características.




Figura 3.2: Experimento con reducción de dimensionalidad con t-SNE. Se observa cómo al cambiar el parámetro de *perplexity* se divisan clusters más definidos.

Del gráfico de la figura 3.2 se puede apreciar que los clusters encontrados en pca pueden también ser vistos con t-SNE, donde el valor de la *perplexity* (confusión en español) aumenta y se encuentra una separación un poco más alta de los puntos. Sin embargo, no llega a haber una separación limpia entre ellos.

Como t-SNE no nos brinda una separación que los algoritmos de clustering puedan encontrar fácilmente, se decide utilizar UMAP como método de reducción de dimensionalidad y observar la separación lograda. Para ello se le entregan los mismos datos que se le brindaron a t-SNE y se realizaron ajustes en los hiperparámetros como la métrica utilizada, la cantidad de vecinos, y la distancia mínima entre puntos.

En la figura 3.3 el resultado de UMAP muestra una separación más clara entre los clusters formados y cómo el algoritmo desmenuza el estado de motor Transición entre los otros tres estados. Esto permite validar la separación realizada por la reducción de UMAP ya que encuentra un modo de operación válido para una operación en 5 minutos. El método de UMAP permite generar una etiqueta menos ambigua para el estado de operación Transición.

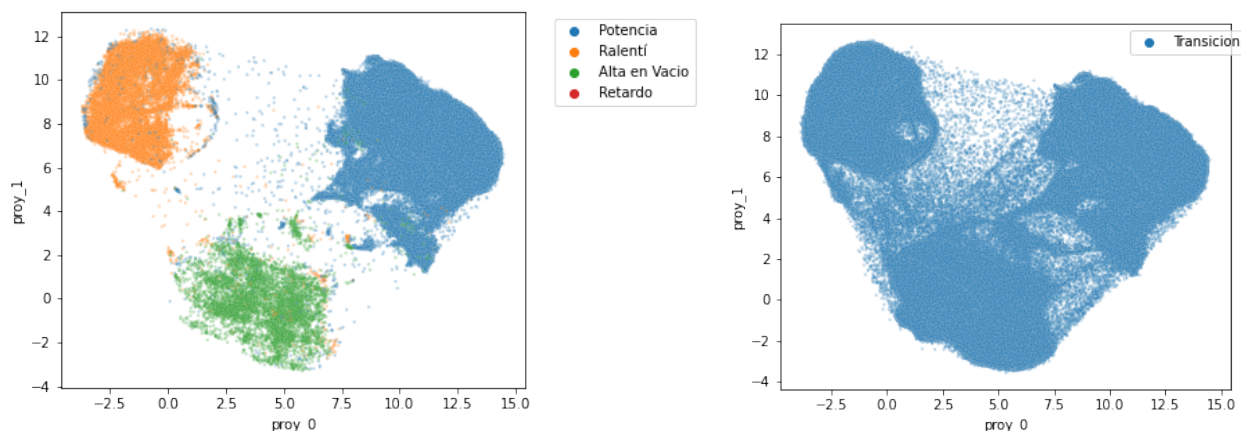


Figura 3.3: Proyección en umap utilizando las mismas variables que en PCA y t-SNE.

Estos resultados validan la metodología utilizada y se establece el algoritmo a utilizar para otros clusters que se quieran realizar. En especial, cuando se desee agregar la data a otro intervalo de tiempo más amplio para así capturar modos de uso más complejos. Por

ejemplo, cómo se comporta el camión en 1 a 4 horas. Esto permitirá generar más estados que traten de capturar el manejo del camión más que los cambios entre estados de Ralentí, Alta en Vacío y Potencia.




Figura 3.4: Mapa de calor de variables importantes en el modelo, donde se nota una clara separación en 3 modos de operación entre ellas.

Además, cuando se analiza una variable en específico de la operación del camión, como en la figura 3.4, se tiene que clusters en específico tienen un valor alto de dicha variable. En el gráfico de la izquierda se puede ver que el cluster superior derecho tiene un alto valor de la variable en análisis. Mientras que en el gráfico derecho, para otra variable, también se tiene un valor alto. Esto quiere decir que se cumple con tener un estado caracterizado por tener variables con valores definidos en un conjunto de puntos. En este caso, el estado operacional dura 5 minutos.

3.3.2. Agregación a 1 hora

También se agrega la data a una hora para poder capturar patrones en un periodo de tiempo intermedio entre 5 minutos y 4 horas. Creyendo que esto puede presentar mayor cantidad de clusters lo que beneficiaría la estimación de las tasas de desgaste por estado.




Figura 3.5: Proyección PCA de variables agregadas a 1 hora. Algunas variables son: tendencia del intervalo, media, mínimo y máximo de la distribución, desviación estándar.

En la figura 3.5, la proyección PCA encontrada no logra clusters separados entre sí, por lo que no es claro cuáles variables considerar para el clustering. En estos casos, se entregan todas las variables disponibles para UMAP ya que este es robusto a variables altamente correlacionadas [6].

Se proyectan los datos y se dibujan mapas de calor de las mismas variables utilizadas en el análisis de 5 minutos. Se puede observar, en la figura 3.6, que existe igualmente una separación en el espacio por lo menos en la media de estas variables.

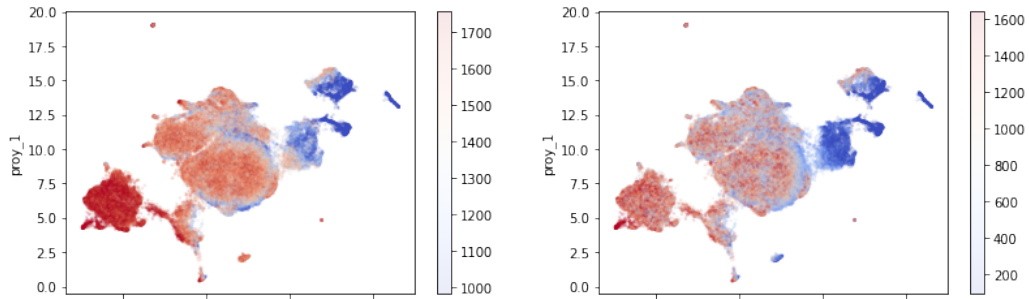


Figura 3.6: Proyección de principales variables de separación del espacio. En este caso se puede observar que existe una relación entre los clusters que tienen bajos niveles de la variable A con la de la variable B. El gran cluster central presenta comportamientos mixtos.

En el caso de las variables creadas para describir el comportamiento de los datos, variables como la tendencia lineal de los datos en dicho periodo o la desviación estándar, también tienen presencia en el clustering, considerando las mismas variables del análisis anterior, figura 3.7.

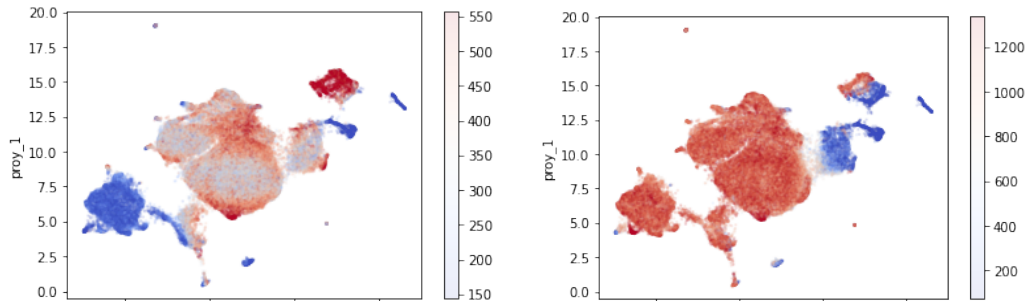


Figura 3.7: Presencia de desviación estándar en los clusters encontrados. La desviación estándar de la variable a nos lleva a interpretar que el cluster inferior izquierdo presenta altos niveles pero estables de la variable a. Mientras que en la derecha, el cluster central presenta niveles intermedios de la variable b y con alta variabilidad.

En la figura se puede apreciar que algunos clusters tienen relación entre sí. Como por ejemplo los clusters superiores de la derecha presentan baja variabilidad para la variable B, y bajos niveles de ambas variables. En el caso del cluster central, se tiene variabilidad media para la variable A y muy alta para la variable B, de niveles intermedios para ambas. Y el cluster inferior izquierdo representa la situación en que la variable A presenta altos niveles con baja variabilidad, y la variable B niveles medios y muy alta variabilidad.

En el caso de las tendencias de las mismas variables, se presenta el caso similar, figura 3.8.

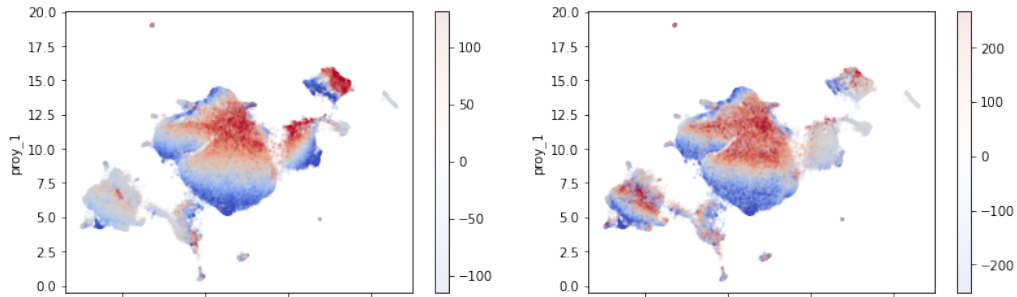


Figura 3.8: En el caso de las tendencias lineales de ambas variables, no se presenta una tendencia clara, pero igual añade información valiosa. En el caso del cluster superior derecho, se tiene que existe una tendencia mezclada de la variable a y la variable b tiende a ser constante, con tendencia cercana a 0. Esto se condice con la baja variabilidad en la variable b y sus bajos niveles.

Para esta característica de los datos se tiene un comportamiento mixto y en ocasiones que puede ser explicado de forma aislada. Como es el caso del cluster superior de la derecha, donde se tiene bajo nivel de variable b, baja variabilidad en variable b y una tendencia a mantenerse en ese valor. Mientras que algo similar pasa en el cluster inferior izquierdo con la variable a, en este caso para valores altos de la variable. El cluster central contiene comportamientos mixtos que no pueden ser explicados fácilmente.

De estos análisis se establece una caracterización adecuada de los clusters y que puede servir para caracterizar de la forma deseada el comportamiento del activo en un periodo de una hora. Quizás sea necesario agregar más características de la curva de datos en una hora. Se probó con descriptores de la distribución de los datos en ese periodo, sin embargo, esta tiene alta correlación con variables más simples como la media o mínimos y máximos.

3.3.3. Agregación a 4 horas

También se realiza el experimento de agregar los datos a 4 horas, considerando que la agregación debería abarcar la forma de operar en un intervalo de tiempo mayor a 1 hora por lo tanto más viajes. Sin embargo, corre el riesgo de perder mucha información. Los resultados en la proyección y en las mismas características utilizadas anteriormente se pueden visualizar en la figura 3.9 y 3.10, donde la separación en varios clusters no es tan clara como en la agrupación a 1 hora o 5 minutos.

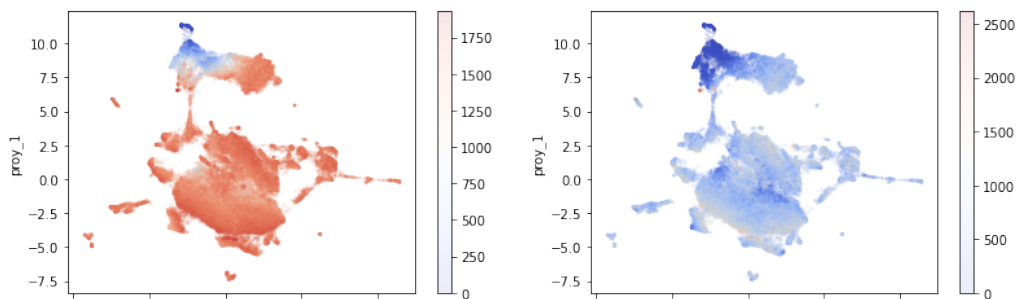


Figura 3.9: Variables S y B en proyección UMAP a 4 horas. No se observa una separación clara entre los clusters. La razón es la baja variabilidad de la distribución de dichas variables.

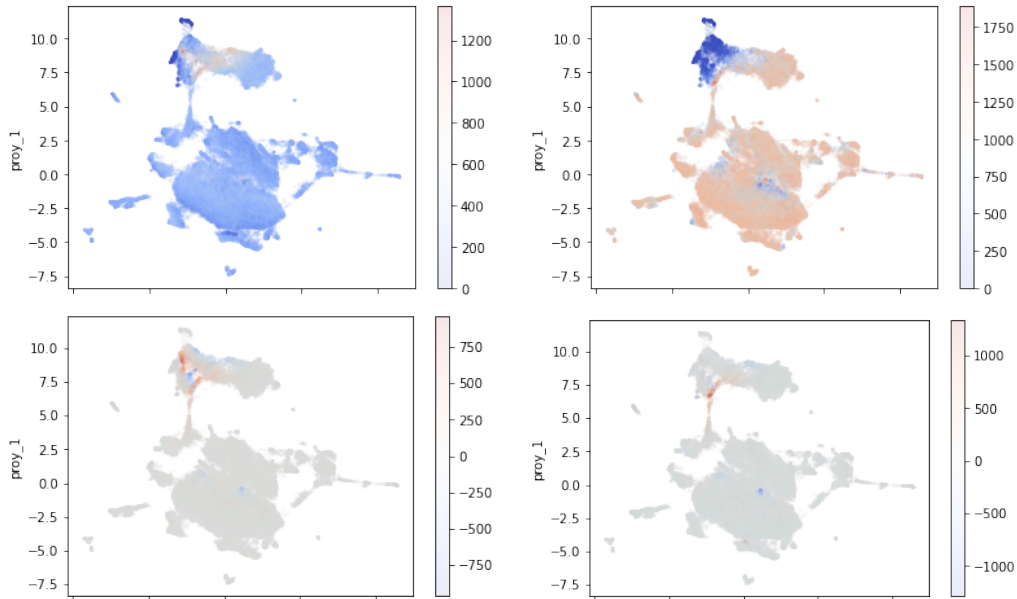


Figura 3.10: Los primeros dos gráficos corresponden a la desviación estándar de las variables A y B, y los inferiores a las tendencias. Como se puede observar, estas características pierden poder de explicación al agregarse a un intervalo tan grande.

3.4. Problemáticas del clustering

De los resultados obtenidos de la etapa de clustering, se debe elegir una caracterización que permita obtener una aproximación a las curvas de desgaste del motor. Si se cuenta con poca cantidad de estados y que entre ellos se alternan de forma muy rápida, es posible que la tasa de degradación asociada a cada estado sea muy similar entre sí, por lo que no se tendría una buena aproximación a las curvas de desgaste. Mientras más estados se tenga, es posible que más se aproximen las curvas ya que se tienen más grados de libertad.

Sin embargo, es más difícil encontrar una estimación generalizada si es que la cantidad de estados es muy grande, ya que no necesariamente todos los activos pasan por dicho estado. Por lo que se contaría con algunos estados en particular que se llevan todo el peso de la estimación, mientras los otros solamente agregan ruido a la estimación.

Del análisis, se concluye que **no** se puede utilizar una agregación de información tan grande como 4 horas para caracterizar este proceso, ya que no se encontraron cambios significativos entre estados. Es más fácil identificar los estados de operación claramente al momento de analizar a 5 minutos, ya que estos estados de operación están bien definidos. En el caso de querer analizar a un modo de uso durante una hora, las características propuestas permiten encontrar clusters con sentido, donde la variable A mantiene valores altos, con baja variabilidad, otras variables tienen otro comportamiento con sentido a esa.

Es por ello que se determina en utilizar una agregación de datos a una hora para caracterizar el proceso de degradación. Se dejará como trabajo futuro el explorar resultados con datos agregados a 5 minutos.

Finalmente, en la figura 3.11, se han explorado los hiperparámetros del modelo UMAP y seleccionando DBSCAN. El clustering obtenido separa conjuntos de datos de forma un poco difusa, pero lo suficientemente separados como para que el algoritmo los identifique como

distintos.




Figura 3.11: Resultados clustering data operacional con UMAP y DBSCAN.

Se puede apreciar que el algoritmo DBSCAN, al generar el clustering, selecciona 7 clusters (0 al 6) con separaciones significativas. Sin embargo, existen zonas poco densas que no le permiten al algoritmo determinar si el cluster 2 y 3, por ejemplo, deben juntarse en uno solo. Estos puntos en zonas de baja densidad son catalogados como outliers o fuera de rango.

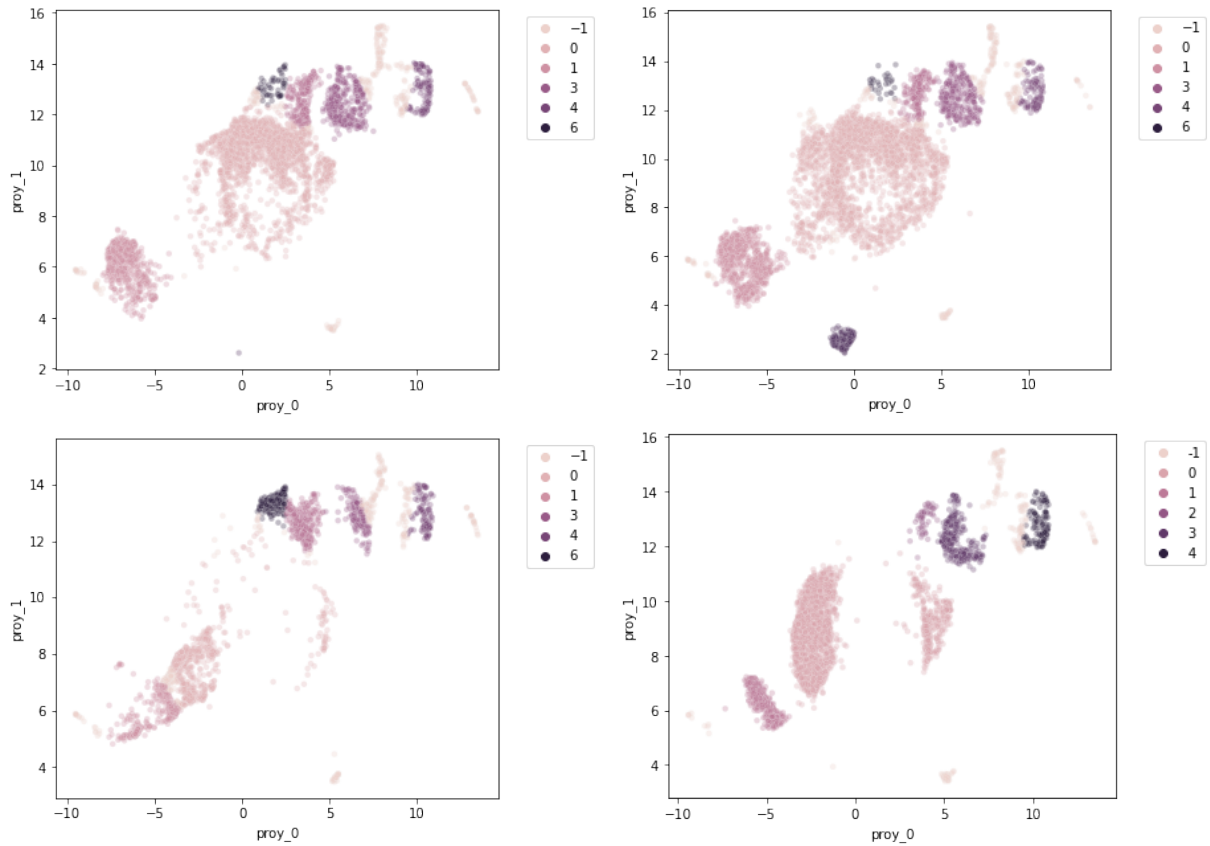


Figura 3.12: Clustering sobre camiones particulares y su proyección en UMAP.

Al aplicar los algoritmos de reducción y clustering a cada uno de los camiones de forma separada, se obtiene que en la proyección estos se concentran en algunos clusters más que en otros y algunos ni siquiera los visitan. En la figura 3.12 se puede apreciar la obtención de los clusters para activos distintos. Esto se logra ya que UMAP es un algoritmo que puede ser aplicado nuevamente en un conjunto desconocido de datos, y DBSCAN de igual forma.

4. Indicador de desgaste del motor fuera de línea

El indicador de desgaste es la principal herramienta que se tiene a la hora de determinar cuándo el elemento bajo estudio llega al punto de falla catastrófica, o está en condición de falla o mantenimiento. La generación de un indicador de desgaste está sujeta a mediciones manuales del elemento en estudio o puede ser una estimación del desgaste medido indirectamente a través de otras variables.

En el caso de que se mida directamente, se contará con una medición cada cierto intervalo de tiempo cuya precisión es alta y permite generar alarmas o agendas de mantenimiento adecuadas al desgaste esperado. A esta curva es a la que los modelos predictivos para mantención de activos se deben ajustar, de modo de poder predecir en qué momento entrará en condición de falla o es probable que lo haga.

En el caso de las mediciones indirectas, se producen cuando no se tiene fácil acceso a los activos a monitorear. Es el caso de molinos que deben funcionar de forma continua para mantener la operación de la planta. O el caso de partes de motores en vehículos de uso intensivo. En el caso de esta investigación, se monitorea el uso de motores en camiones mineros, por lo que se debe desarrollar un indicador de desgaste indirecto.

Las mediciones de desgaste que se tienen de estos activos son limitadas a mediciones de los elementos en el aceite de motor y a inspecciones visuales de las partes del motor. Se cuenta con los datos de fallas del motor y entradas al taller producto de ellas. Las paradas en taller tienen duración variable lo que también implica la profundidad del arreglo. Adicional a esto, se cuenta con los datos de cambio de motor, hay que considerar que los camiones sufren cambios de motor por reparaciones en el mismo, por lo que estos artefactos son intercambiables entre camión. Es requisito separarlos.

4.1. Datos disponibles

En la operación minera, no es fácil pesquisar fallas en los motores de los camiones. Esto es porque estas se presentan repentinamente y muchos factores influyen en la degradación del motor. Se realizan inspecciones rutinarias que permiten encontrar fallas superficiales y también preparar el camión para la operación. En el caso del interior, se tienen sistemas que monitorean el sistema eléctrico del motor, y con ello pueden encontrar fallas escaneando el sistema. Además, se cuentan con sistemas de monitoreo de las condiciones en las que trabaja el motor por medio de sensores.

Otra fuente importante de información relacionadas a las fallas en el motor, son los datos de los estudios tribológicos. Esta información consiste en los ensayos de laboratorio que

permiten encontrar distintas concentraciones de elementos metálicos en el líquido, y con ello levantar alertas de alguna falla. También se miden propiedades del aceite que afectan a la operación según la condición. Por ejemplo, el aceite puede reducir su viscosidad o aumentar acidez y provocar que algún elemento rodante al interior pierda protección y aislamiento.

Entre las fuentes de los datos también se cuentan los datos de fallas como registros de parada en taller y registros de inspecciones del camión. En esta información se puede realizar un análisis de frecuencia para determinar cuáles son las fallas más importantes y por cuáles el motor permanece más tiempo en el taller.

Entre toda esta información, no se cuenta con un indicador de desgaste ya construido con mediciones manuales o automáticas. Para realizar el ejercicio de estimación de tasas de desgaste de acuerdo al modo de uso, se debe levantar la necesidad de generar un indicador de desgaste a partir de los datos que se tienen. Este procedimiento considerará varios supuestos que pueden contener conocimiento experto para la generación del indicador.

En el caso de la data tribológica, se tiene que en varias investigaciones como [14][17][22] se analiza el aceite de vehículos en operación y se presenta una correlación entre algunas concentraciones de los metales con la presencia de degradación del aceite en el motor. En [14] se realiza el ejercicio de estimación del tiempo de falla, pero no se realiza sobre un equipo que sufra de regeneración del aceite, como es el caso de los camiones mineros. De estas investigaciones se inspira la creación de un indicador de falla con datos tribológicos.

En base a este conocimiento, se emprende la tarea de generar un indicador de falla que permita generar un modelo para su predicción. Para ello se desarrolla una metodología que analiza la correlación de los datos de tribología con la degradación del aceite. Para luego seleccionar algunas variables de dicho análisis y así generar el indicador con una mezcla de ellas. Finalmente, se estima una zona de peligro donde se caracteriza de forma probabilística la ocurrencia de falla. Para ello se genera un problema de optimización que busca una descripción de dicha zona.

4.2. Datos tribológicos

Los datos tribológicos contienen un análisis de los contenidos y propiedades del aceite del motor que permiten identificar posibles fallas dentro del motor. Algunos elementos en particular dan cuenta de una falla específica y, de acuerdo a información del análisis visual o del usuario, permiten apuntar una agenda con visitas al taller para su revisión.

La preparación de los datos consistió en revisar tendencias a lo largo de los elementos en el aceite de todos los camiones, también en analizar histogramas en busca de modos de uso y luego un análisis de correlación para identificar los que más correlación tienen con el uso del aceite.

En la figura 4.1, se observan los datos sin procesar de los análisis tribológicos. La eliminación de tendencias nace de la necesidad de aislar los efectos de la formulación del aceite transversalmente entre los camiones. Se pudo observar que ciertas curvas cambiaban en composición desde el inicio de los datos. Se ajustan curvas que permitan capturar la data promedio y luego se genera una nueva variable tratando de preservar la media constante y una varianza similar entre los camiones.

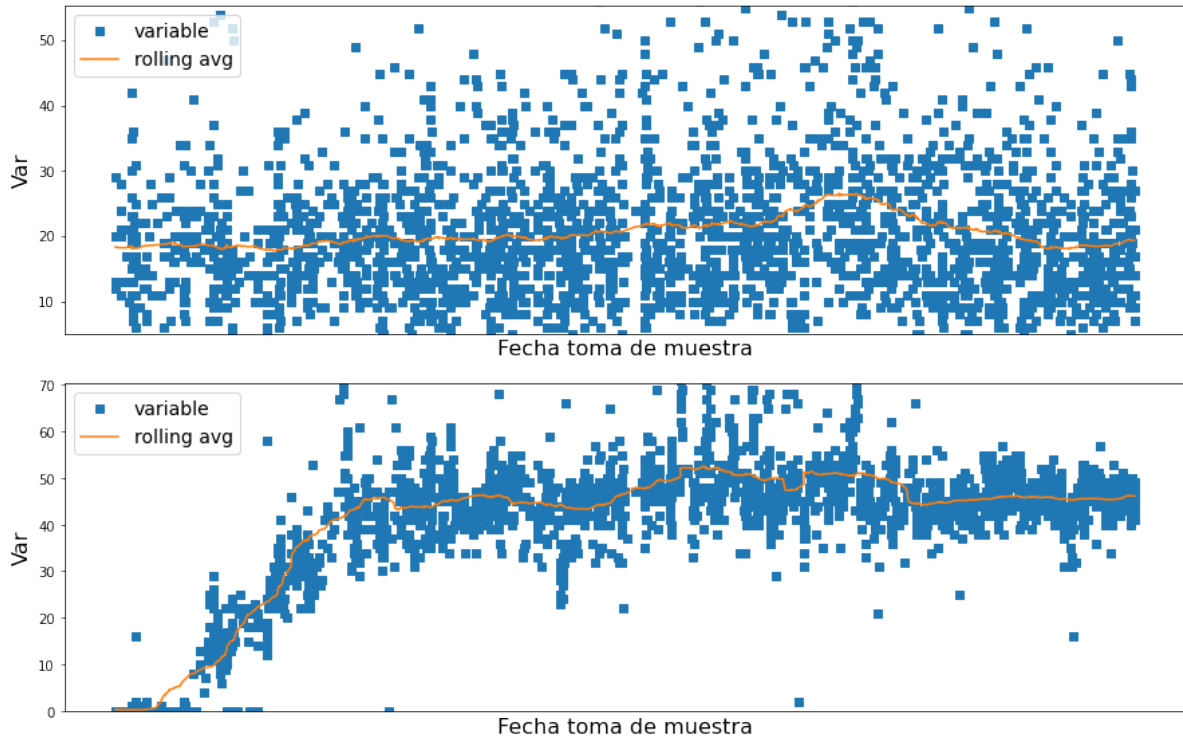


Figura 4.1: Evolución en el tiempo de la concentración de dos elementos diferentes en el aceite. En la primera visualización se muestra un elemento con una tendencia poco clara; en la segunda se muestra una tendencia más marcada. Con esto se muestra la necesidad de quitar la tendencia global de dichos elementos para los siguientes pasos en el análisis.

En el gráfico de la figura 4.1 se puede apreciar que existen tendencias en los datos que indican cambios transversales a todos los camiones en algunas concentraciones de elementos. Esto indica que se cambia la composición o la forma de medir en laboratorio. Para quitar esa tendencia se aplican técnicas que remueven el promedio de una ventana de tiempo particular para afectar a los datos de igual forma.

Otra variable de interés en el análisis, se aprecia en la figura 4.2, es la variable que da cuenta del tiempo que ha permanecido el aceite dentro del motor sin ser cambiado. Contra esta variable tomaremos correlaciones de las otras para así seleccionar las que tengan relación con la degradación del aceite y consecuentemente del motor.




Figura 4.2: Odómetro de la cantidad de horas que se ha mantenido el aceite desde el último cambio. Se toma como variable contra de referencia de la edad del aceite en el camión.

Luego de esto, se procede a analizar la correlación entre las variables y el tiempo de uso del aceite. Para así encontrar las que dieran cuenta de la mayor degradación del aceite y otros componentes en el equipo. A partir de esto se obtienen los siguientes gráficos en la figura 4.3 donde se valida que presentan mayor desgaste a medida que avanza el uso del aceite.

Esto lleva a pensar que una buena variable para generar el indicador, sería con una acumulación de las concentraciones de minerales en el motor y la degradación del Total Base Number (TBN) que da cuenta de la acidez del aceite, que puede corroer otros componentes en el interior del motor.




Figura 4.3: Gráficos de correlaciones de mediciones en análisis tribológico. Primeros dos representan a elementos producidos por el roce y por la combustión del motor cuyas concentraciones aumentan a medida que el aceite se utiliza; el tercero son variables ambientales que no presentan mayor correlación con el uso; y el último representa el *total base number* el cual al disminuir indica que aumenta la acidez del aceite a medida que este se utiliza, i.e. la corrosión aumenta en el aceite.

En la correlación de los elementos con el tiempo de uso, se puede apreciar que existen ele-

mentos con alta correlación transversalmente en la degradación del aceite (primer y segundo gráfico de la figura 4.3). Estos dan cuenta principalmente de la combustión en el motor, resulta que a medida que el motor es usado, el aceite adquiere ciertos elementos de la combustión, sobre todo si esta es incompleta. Además, ciertos elementos comienzan también a aumentar debido al roce producido al interior del motor. Estas características son las que se tomarán en cuenta para la construcción del indicador de desgaste del motor.

Otros elementos no tienen mayor correlación con la degradación del aceite o del motor, por lo que no presentan el mismo patrón. Estos son descartados del análisis.

El último gráfico de la figura contiene componentes que se ven afectados con correlación negativa a medida que envejece el aceite. Este es el caso del TBN, donde la propiedad básica del aceite se ve degradada y comienza a ser más ácido, por lo tanto, degradando el motor.

Para la construcción del indicador, se debe considerar que el sistema de lubricación del motor cuenta con un mecanismo que inyecta aceite sin utilizar al sistema mientras este se encuentra en funcionamiento. Esta práctica no es recomendable en motores de uso doméstico ya que las partículas dañinas para el motor permanecen en el sistema y no son evacuadas. En el caso de camiones mineros se cuenta con un sistema que quema el aceite usado en la combustión del motor.

El mencionado mecanismo provoca que existan caídas en las concentraciones de partículas que se espera vaya aumentando en función del tiempo de uso del aceite, según lo visto en [14][17][22] donde se obtienen correlaciones positivas de los elementos con el uso del aceite al igual que se observa en la figura 4.3. Debido a esto, se realiza una separación por ciclos de aceite que se obtuvieron del odómetro del análisis (tiempo de uso del aceite en el motor) para considerar en ese ciclo la acumulación de partículas y de daño del motor.

4.3. Creación del indicador

Para la generación del indicador de degradación, en base a las investigaciones [14][17][22] se tiene que la acumulación de partículas o degradación de propiedades del aceite se puede relacionar con una degradación del motor. Y de lo observado en la figura 4.3 podemos seleccionar un conjunto de elementos para hacer el seguimiento del conteo de partículas. Además, se cuenta con el conocimiento de que concentraciones altas de algún elemento en el aceite está relacionado a un desgaste de un elemento del motor. Esto nos lleva a plantear un indicador no visto en la bibliografía realizada, el cual considere un desgaste acumulativo en base a las concentraciones fuera de la normalidad de los elementos o propiedades del aceite consideradas. En específico, se trata de generar una función que agregue las anomalías en los valores normales de concentraciones de elementos en el aceite, considerando que existe un relleno del aceite durante su ciclo.

De la selección de variables con mayor correlación (o correlación lo suficientemente negativa), se genera un indicador combinando las variables por medio de un modelo que trata de capturar las anomalías en las mediciones. El modelo considera que cuando una variable salga de la normalidad se registre en la función de degradación f . Si la medición de la variable está dentro de rangos normales, se agrega con una constante baja, que permita generar degradación pero no de la misma magnitud. Esto significa que el indicador generado asigna a las anomalías una degradación mayor mientras asigna una menor a mediciones dentro de la normalidad. El indicador generado será la suma acumulada de estas mediciones f , y este siempre tendrá pendiente positiva a pesar de que el funcionamiento sea de baja exigencia, es decir, siempre habrá un desgaste de los componentes mientras el activo se utilice.

La función de degradación quedará definida como:

$$Indicador = \sum_{i=0}^I f_i(\{x\}_n^N) \quad (4.1)$$

donde la función que agrega las anomalías en la medición tribológica queda definida como:

$$f_i(\{x\}_n^N) = \sum_{n=1}^N g(x_n) \quad (4.2)$$

donde la función g , es la que captura las anomalías en las mediciones de los análisis tribológicos. Esta función es una función por tramos donde si se sobrepasa el umbral, se le asigna el valor medido (normalizado con las otras variables), mientras que si el valor está bajo el umbral, su peso será menor:

$$g(x_n) = \begin{cases} x_n & \text{if } x_n \geq th_n \\ x_n * \gamma & \sim \end{cases} \quad (4.3)$$

En esta función g , se tendrá x_n como la variable n en el análisis tribológico en el tiempo i . Su umbral th_n estará asociado a dicha variable n de acuerdo a análisis que permitan determinar un percentil de "normalidad". Mientras que γ es el factor multiplicativo $\in (0, 1)$ que determinará el aporte de dicha variable en el rango de normalidad. Este último vendrá determinado por medio de heurísticas que den el mejor resultado respecto a la ocurrencia de fallas.

El resultado final para cada activo, será un indicador de degradación (salud) que vendrá determinado por las anomalías presentes en el análisis tribológico, donde las anomalías son medidas por g , agregadas en f y construyendo el *Indicador* como la suma acumulada de las mediciones desde el inicio de la vida del activo.

Este proceso genera un indicador para cada activo con propiedades del aceite que van variando y pudiendo incluso mejorar, pero que, dada la construcción del indicador, este considerará solamente las degradaciones de dichos elementos.




Figura 4.4: Gráfico superior: eventos de falla y mantención registrados en el sistema. Gráfico del centro: función de degradación diferencial a partir de análisis tribológicos. Gráfico inferior: acumulación de la degradación.

En la figura 4.4 se observan los eventos de falla y mantenimiento que nos permitirán encontrar los niveles del indicador en los que se produce una falla. El gráfico del centro nos entrega el valor de la función f obtenido de los análisis tribológicos.

En la construcción final del indicador, se asume que el motor se mantuvo en la situación que produjo la degradación medida. Es decir, el valor medido en el tiempo i permaneció desde la última medición realizada hasta ser medido. Este supuesto nos lleva a determinar que el valor de f es la pendiente de la curva en el indicador final, en el periodo entre mediciones.

4.4. Proceso de Optimización para encontrar la Hazard Zone

La Zona de Peligro o Hazard Zone es un área en el espacio del indicador a la cual este se va acercando a medida que tome valores más altos. Esta zona refiere a donde existen mayores riesgos de entrar en condición de falla.

Como el indicador es creado, no es fácil definir un umbral o zona de peligro. Para ello se emplea un problema de optimización que permita encontrar una estimación de la hazard zone y un umbral de falla.

El problema de optimización considera las siguientes restricciones:

- El indicador de desgaste nunca puede ser inferior a cero.
- Los valores del indicador en que ocurre la falla deben ser cercanos entre sí.
- Los valores en que ocurre la falla deben ser los más cercanos a cero que se permita.

Luego se establece la función objetivo, la cual será la encargada de encontrar la solución al problema de optimización. En ella se considera la magnitud de la corrección de la curva como la distancia entre las demás correcciones.

$$F(f, a) = \sum_n^N \sum_{n'}^N (f_n + a_n - f_{n'})^2 \quad (4.4)$$

La función objetivo $F(f, a)$ trata de minimizar la distancia a_n que existe entre los valores del indicador f_n en fallas con una falla en particular ajustada $f_{n'}$. Entonces, se tratará de reducir la distancia entre todas las fallas y sus ajustes de nivel. De esta forma, se puede obtener una zona de peligro donde el nivel alcanzado por las distintas fallas sea donde mayor probabilidad existe de fallar. Como **solver** se utiliza el software GUROBI con licencia académica.




Figura 4.5: Gráfico de corrección contra valor de falla al inicio y fin de un intervalo analizado. Gráficos de zona de peligro en probabilidad y probabilidad acumulada.

La zona de peligro de falla se representa como un gráfico con una zona en degradé donde la intensidad del color expresa la probabilidad creciente de falla a medida que se adentra en dicha zona. Como se puede ver en la figura 4.5 donde se tiene a la izquierda la zona de peligro como se vería en un intervalo de tiempo determinado con el eje y con los valores del indicador. Y en la derecha, se tiene el eje x como los valores del indicador de degradación y el eje y como la probabilidad de falla a la que se enfrenta el activo.




Figura 4.6: Indicador de degradación modificado por problema de optimización.

Un ejemplo del indicador para un activo determinado se muestra en la figura 4.6 donde el indicador crece en el tiempo, y en ocasiones cae producto de alguna falla y caída en taller. Esta figura se corresponde a la figura 4.4 donde se tiene el indicador de degradación original. Mientras que en esta figura 4.6 se muestra el indicador ajustado al umbral de falla encontrado.

4.5. Consideraciones

Los riesgos de este indicador son varios. Principalmente porque es creado a partir de un análisis de data que tiene poca certeza en las mediciones ya que existe un mecanismo de

tratamiento del aceite lubricante¹ que puede alterar el patrón o correlación que existe en las variables tribológicas con el desgaste del motor. Por otro lado, la función que agrega las variables considera un comportamiento no lineal, podría emplearse otra forma de agregar la información.

Como última consideración, se debe tener en cuenta que la generación de la zona de peligro está sujeta a la calidad de los datos de paradas y su duración en el taller no se toma en cuenta para ser estrictos. Por lo que se considera cada parada en taller por fallas en motor como un evento de falla, ya sea mantención. Es por ello que puede que al momento de caer en el taller el nivel del indicador no sea alto como lo supone el algoritmo de optimización.

De todas formas, lo que se busca con este ejercicio es poder generar un marco de referencia para la estimación del tiempo de falla futuro, ya que la estimación de las tasas de desgaste se basa principalmente en los cambios que sufre este indicador. Siendo su nivel de referencia para la misma fase de riesgo de caída de falla que permite calcularlo.

La siguiente fase considera solamente las variaciones en el indicador de desgaste para la estimación de las tasas de desgaste, donde se espera terminar con un conjunto de estados que contengan tasas de desgaste que permitan aproximar la curva de degradación.

¹ Dicho mecanismo consiste en un estanque de reserva de aceite lubricante que cada cierto tiempo no establecido introduce aceite al sistema. El exceso de aceite participa de la combustión en el motor

5. Estimación de tasas de degradación

Luego del paso de clustering para encontrar los estados de operación del motor y el análisis de data tribológica que permite la creación del indicador de desgaste. Se tiene la fase que mezcla dicha información para tratar de estimar cómo degrada el motor del camión en base a sus modos de uso.

La hipótesis central de esta sección es que la tasa de cambio de la degradación cambia dependiendo de cómo se utilice el activo, ya sea de forma agresiva, media o liviana. Esto se observa en el día a día en procesos en que podemos llevar al límite el sistema y quedar cerca de la falla. Es el caso de vehículos que se utilizan de forma intensiva un determinado periodo y al tiempo presenta fallas por la alta exigencia. U otros que se utilizan de forma moderada con cuidado y duran más tiempo que los anteriores.

En base a esto, se busca estimar la tasa de cambio del indicador respecto al estado en que se encuentre. Para ello se debe generar los intervalos de análisis donde se cuente con información de la operación, sus estados resultantes del clustering y el indicador creado a partir de la data tribológica.

5.1. Algoritmo de estimación

Con esto en la mesa, se procede a la creación del algoritmo que permite, a través de la búsqueda del espacio de tasa de desgaste por estados, llegar a las zonas donde la reconstrucción de la curva a partir de las tasas de degradación estimadas por estado, se forme una curva lo más parecida a la original de desgaste.

Para ello, el algoritmo considera solamente intervalos donde la data operacional esté completa, exista disponibilidad de las mediciones tribológicas para la creación del indicador y, la cantidad de datos permita tener variabilidad en el indicador de degradación.

Al tener estos datos, el algoritmo genera muestras de una distribución desde donde se creen pueden provenir las tasas de desgaste, y estas se utilizan para la reconstrucción de la curva de desgaste a través de la ecuación:

$$I_i(e_i) = \sigma_i * \Delta t + I_{i-1}(e_{i-1}) \quad (5.1)$$

donde el indicador I_i se irá nutriendo de la tasa de degradación σ_i del estado e_i ponderando por el tiempo en que el camión se ha mantenido en ese estado Δt .

La diferencia entre la curva reconstruida y la curva original se acumula con la de las demás para tener un agregado de todas las discrepancias y comparar esta métrica con una nueva iteración de reconstrucción. Al comparar dichas métricas, la actual contra la iteración

anterior, si la métrica mejora se guarda el conjunto de tasas de desgaste que se utilizó en la estimación, si no, se sigue buscando.

Para la búsqueda se deben establecer parámetros para punto de inicio y el tamaño de los pasos que da el algoritmo al buscar candidatos. Estos parámetros se muestran en la tabla 5.1 el paso y los valores iniciales de la tasa de desgaste. Lo que se busca es poder encontrar los descriptores de las distribuciones desde donde se obtienen las tasas de desgaste en cada estado.

Tabla 5.1: Parámetros establecidos para la búsqueda de tasas de degradación.

parámetro	valor
r	$1e5$
τ_1	$1e - 1$
τ_2	$1e - 2$

Para generar estos parámetros, se obtiene la media de la tasa de cambio del indicador agrupado por cluster y su desviación estándar. Como se muestra en la figura 5.1, la tasa de desgaste promedio se acerca a 1, y su desviación se puede establecer un orden de magnitud inferior.

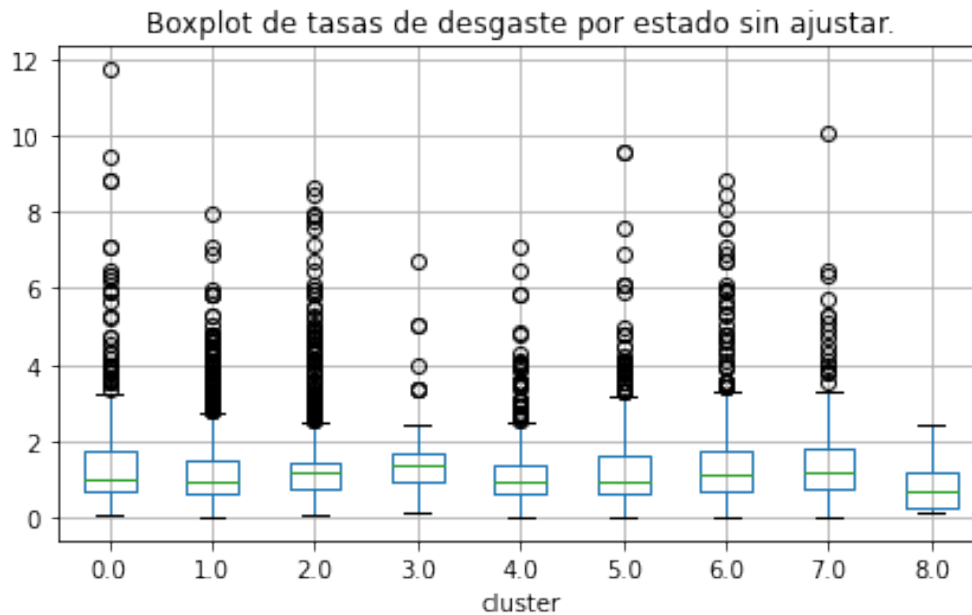


Figura 5.1: Tasas de desgaste estimadas a partir de los datos sin el ajuste por curva de degradación.

Para la estimación de las tasas de desgaste por cada estado, se considera el estado de operación y un valor propuesto de la tasa de degradación para ese estado. Esta tasa se obtiene de una distribución normal cuya media se determina por el mejor candidato para tasa de degradación. Con los candidatos por cada estado, se genera una reconstrucción del indicador de degradación, se compara con el indicador original y si es que se mejora la métrica de discrepancia, se ajusta la media de la distribución desde donde se obtienen los candidatos

para tasa de degradación.

En la figura 5.2 se observa la reconstrucción de la curva de degradación y a su lado la tasa de degradación en el tiempo. De este modo se puede visualizar el ajuste y la incertidumbre asociada a cada tasa de degradación. Por ejemplo, estados con tasas de degradación más altas tienden a tener mayor incertidumbre y ser menos frecuentes. Mientras que estados de operación con tasas de degradación media, no presentan tanta incertidumbre.

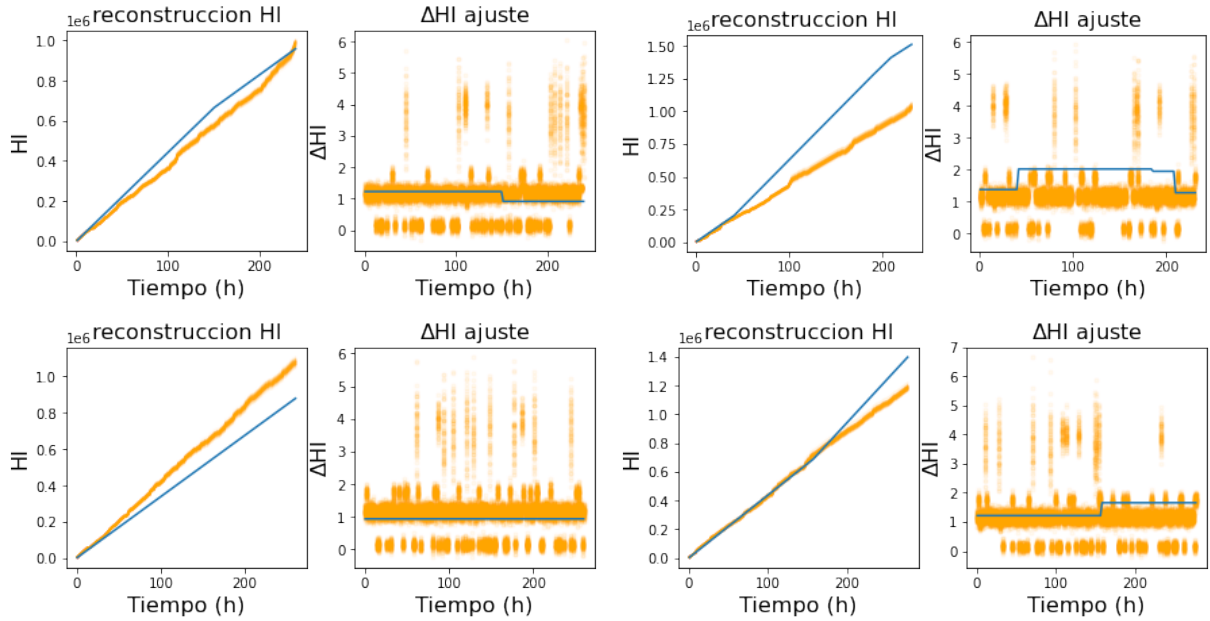


Figura 5.2: Estimación de las tasas de degradación a partir de distintos periodos de desgaste.

5.2. Resultados

Los resultados para la estimación de las tasas de degradación por estado de operación se pueden visualizar como una evolución del ajuste en la figura 5.3 donde las tasas de degradación se diferencian por tener niveles más altos y varios más bajos. En este caso, se nota la diferencia entre estados que tienen altas tasas de degradación, en la figura 5.4 se observa con mayor detalle dicha observación.




Figura 5.3: Estimación y evolución de medias de tasa de desgaste

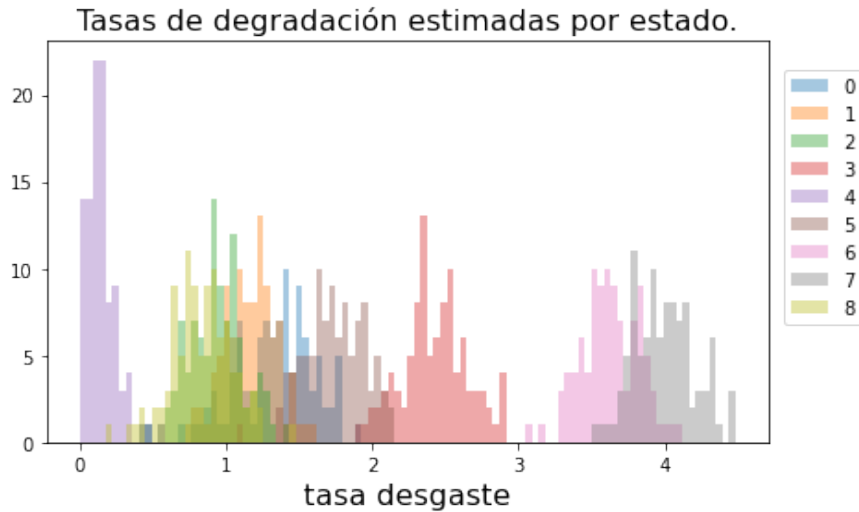


Figura 5.4: Distribución de tasas de degradación estimadas.

Estos resultados, junto con los de las curvas de ajuste, nos permiten identificar algunas hipótesis de por qué existen estados con mayor tasa de degradación que otros. Como se observa en las curvas de ajuste en la figura 5.2, se tiene que los estados con mayor tasa de degradación son los menos frecuentes en los datos, mientras que los estados más frecuentes en la data reciben una tasa de degradación promedio o menor, concentrándose en la degradación unitaria.

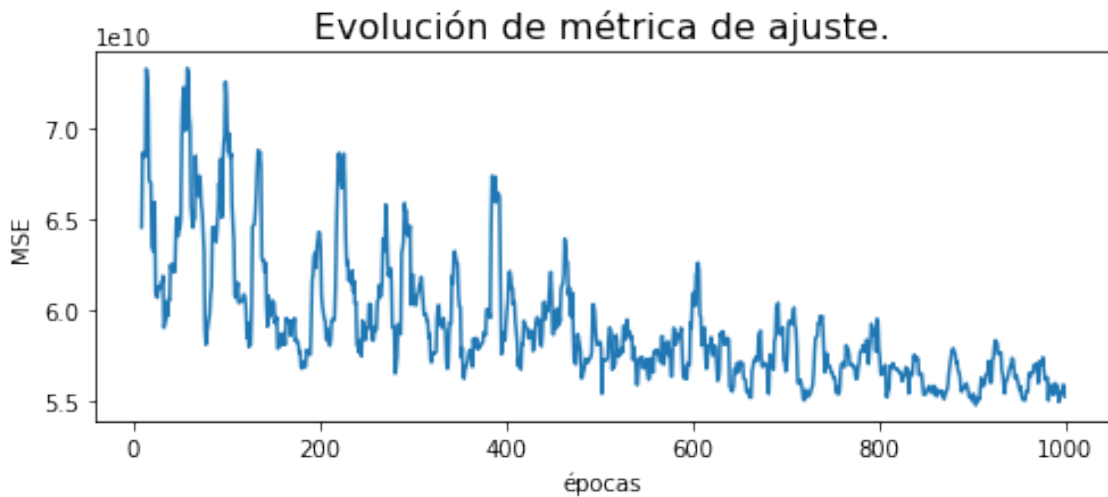


Figura 5.5: Evolución de la métrica de ajuste en la estimación de las tasas de desgaste.

La métrica de ajuste de las tasas de degradación se puede observar en la figura 5.5 donde se tiene el error cuadrático medio (MSE por sus siglas en inglés) como métrica de ajuste, donde el punto de partida es la media de las tasas de desgaste. Esta métrica se va reduciendo a medida que se ajustan las tasas de desgaste.

5.3. Discusión

La estimación de las tasas de desgaste con este método permite encontrar un ajuste un poco mejor que el obtenido con los valores medios de desgaste por estado. Esta ganancia significa que la separación en intervalos de tiempo por modelos de degradación para la estimación de la curva de degradación, tiene sentido. La ganancia se puede observar en la curva de evolución de la métrica de ajuste, donde se va de un valor con alta incertidumbre hacia uno con menos.

6. Estimación de Tiempo de Falla

La fase de pronóstico y predicción de la metodología se desarrolla con el objetivo de estimar el momento más probable en que ocurra la falla en base a la forma de operar que ha tenido el motor y sus mediciones del desgaste en el tiempo. La idea es utilizar una forma de filtrado de partículas en que se realicen muestreos de la distribución de tasas de desgaste por estado para simular el desgaste y cuando llegue una muestra desde el análisis tribológico se aplique la fase de filtrado para estimar el desgaste del camión.

En esta sección se detalla la inspiración desde donde nace el algoritmo, los métodos a utilizar en su desarrollo y el cómo estimar el tiempo de falla dada una zona de peligro de falla.

En este caso, el empleo de estos métodos consiste en generar predicciones a una cantidad n de pasos. Luego, cuando llegue la lectura del desgaste, pueda ser corregida la serie de tiempo generada en el mismo instante a través del re-muestreo de las partículas y sus pesos asociados a la función de verosimilitud de la medición entrante. En este caso, la frecuencia con que se tienen los datos determinará esa cantidad n de pasos, que en este caso es de aproximadamente 2 semanas entre muestras de laboratorio. El resto del tiempo, se cuenta con la data operacional donde se apalanca la estimación para generar estimaciones del nivel de desgaste.

A continuación, se explica el algoritmo utilizado para generar la reconstrucción de la curva de degradación a partir de los estados de operación y la distribución de tasas de desgaste de cada estado.

6.1. Algoritmo a implementar

Para ejecutar el algoritmo, primero se necesita cargar la información relacionada a camión: indicador de degradación, data operacional, clusters. Cargar la información de la estimación de tasas de desgaste inicial. Luego, se simula la estimación en línea del desgaste siguiendo el siguiente procedimiento:

1. Considerando la información operacional del momento:
 - a) Considerar el peso de las partículas
 - i. En paso 0 o cuando se tiene una medición del análisis tribológico: establecer todas las partículas con el mismo peso
 - ii. En el resto: las partículas mantienen su peso

- b) Tomar estado de operación actual
 - c) Obtener muestras de la tasa de desgaste de ese estado
 - d) Estimar desgaste a partir de estado anterior y actual sumando las tasas de degradación usando la función en 5.1
2. Evaluar si se tiene disponible un dato del **análisis tribológico**, si se tiene:
- a) Entregar la medición tribológica a la función descrita en la sección 4.3, para obtener el nivel de degradación a partir del análisis tribológico.
 - b) Una vez obtenido el nivel de degradación del análisis tribológico, comparar los pesos de las partículas con la verosimilitud de la medición de degradación.
 - c) Considerando la verosimilitud de las partículas y el ruido de la medición, se re-muestran las partículas a partir de su distribución de pesos.
 - d) Se evalúa la discrepancia de las muestras con la medición de desgaste. Si esta es muy grande, se debe proceder a re-estimar las tasas de desgaste asociadas al estado utilizando el algoritmo de la sección 5.1.
3. En el caso de que las partículas estén entrando en la zona de peligro, se toma la probabilidad de falla de cada una y se realiza un proceso de Poisson para si cae en estado de falla. Esto es basado en la investigación realizada en [21]:
- a) Contar todas las partículas que caen en condición de falla.
 - b) Aquellas que caen en falla son eliminadas.
 - c) Las restantes partículas son re-muestradas para re-generar el conjunto de partículas, de este modo se mantiene el número de partículas constante en toda la simulación.

A modo de resumen, el algoritmo incorpora la información de la operación del activo a través de los estados y sus tasas de desgaste. También cuenta con la incorporación de la información proveniente de los estudios tribológicos, que permiten estimar la degradación al momento de la medición, y con ello actualizar las partículas de la simulación. Además, si la medición diverge mucho de la estimación, se realiza una nueva estimación de las tasas de degradación de los estados y un cálculo de la cadena de Markov. Esta última parte es clave para incorporar la información reciente a las tasas de degradación, y permiten ajustarse de mejor forma a la degradación de este activo.

El progreso de la simulación se puede ver en la siguiente secuencia de imágenes en la figura 6.1. La simbología es la siguiente:

1. **Puntos rojos:** mediciones de tribología y estimación de desgaste a partir del paso 2 del algoritmo.
2. **Área naranja:** conjunto de partículas que son consideradas en la estimación de degradación. Consideran la corrección por las mediciones tribológicas.
3. **Área verde:** conjunto de partículas que no consideran la corrección por las mediciones tribológicas y que sirven para evaluar la discrepancia y establecer cuándo realizar una re-estimación de la tasa de desgaste de los estados del camión.




Figura 6.1: Progresión de estimación de degradación en línea sin re-entrenamiento.

En la figura 6.1: imagen superior se observa como en los primeros pasos la estimación de degradación evoluciona solamente a partir de información operacional. En la imagen del medio se observa como llega la información del análisis tribológico y se corrigen las partículas, separando el área naranja de la verde. En la imagen inferior de la figura 6.1 se observa que en la quinta medición tribológica se separan significativamente el área verde de la medición tribológica, lo que obliga al algoritmo a re-estimar las tasas de desgaste de los estados operacionales, del paso $2d$ del algoritmo.

Cuando se incorpora el re-entrenamiento en la progresión, en la figura 6.2 la estimación queda como:




Figura 6.2: Progresión de estimación de degradación en línea con re-entrenamiento.

Se puede apreciar que en el último periodo de la progresión de la figura 6.2 se realiza un cambio en las tasas de desgaste asociados a los estados, donde varía la pendiente según lo visto en los últimos periodos de desgaste. Como existe una gran discrepancia entre los valores estimados de degradación a partir de los estados operacionales, se debe corregir dichas tasas de degradación hasta que dicha discrepancia no exista. Este criterio está parametrizado por la incertidumbre de la medición del análisis tribológico.

Al término de la simulación se tiene un conjunto de datos correspondiente a las partículas que fueron cayendo en condición de falla. Este conjunto es llevado a un histograma para recrear la distribución del tiempo de falla.

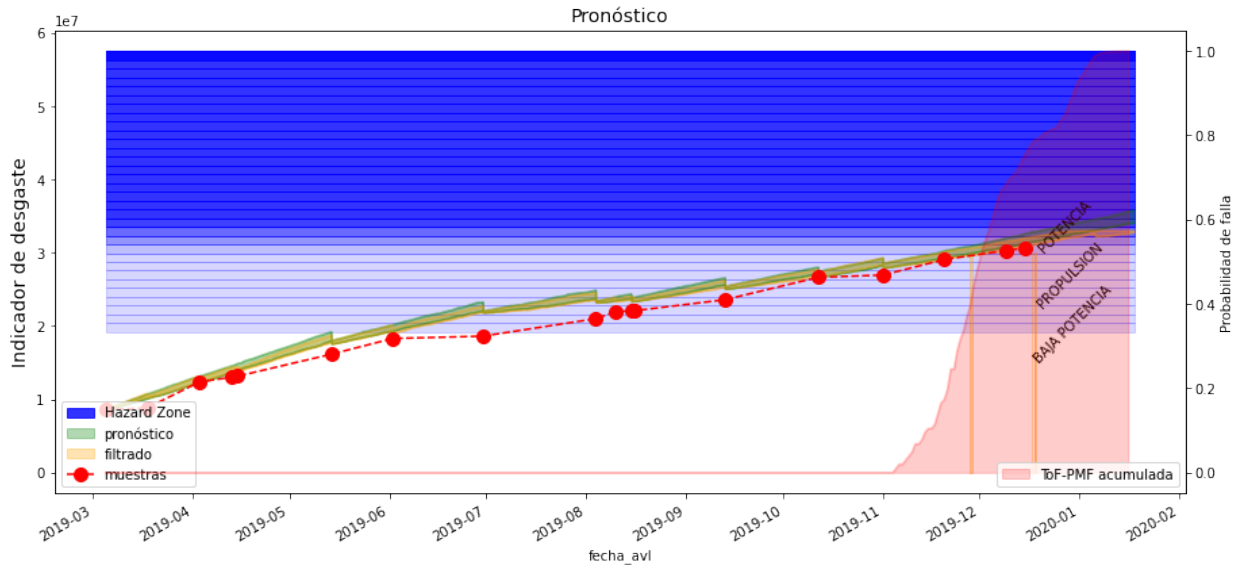


Figura 6.3: Ejemplo de distribución de masa de probabilidad de Tiempo de Falla

En la figura 6.3 se realiza una predicción a 1000 pasos o 42 días del evento de falla. Junto con la reconstrucción por medio del filtro de partículas, a este se le aplica una nueva estimación de las tasas de desgaste cuando se tiene una discrepancia muy grande entre la predicción y las partículas obtenidas de re-muestrear el conjunto de partículas al llegar una nueva medición. En esta nueva estimación solamente se consideran los datos del presente camión, lo que permite adaptar el comportamiento reciente en la estimación de la degradación.

Como se cuenta con una historia de los datos, se puede generar una simulación a futuro de cómo será el comportamiento aproximado del activo. Gracias a los estados operacionales y su cadena de Markov. Con ello, se pueden realizar estimaciones de cómo será la evolución de la degradación y así generar una ToF estimada. Esto puede servir de información para la toma de decisiones en cuanto al mantenimiento preventivo del activo, o extender el uso dado que la forma en que se utilizará el activo no representa un riesgo de falla en el futuro próximo.

6.2. Resultados

A continuación, se presentan resultados de la estimación de RUL a distintas distancias del fin de la vida del activo. Para ello se generan simulaciones de su uso de acuerdo a la historia del activo, y con ello se reconstruye la curva de degradación incorporando la información de tribología. El resultado de una simulación es la función de densidad de probabilidad de la ToF, la cual nos permite obtener la función de masa de probabilidad observada en la figura 6.4. Y así estimar el tiempo de falla como el momento en que la masa de probabilidad supera un umbral predeterminado por el riesgo a asumir. Si el umbral es bajo, quiere decir que se alertará de una falla de forma temprana, mientras que un umbral más alto, nos avisará de forma más tardía.

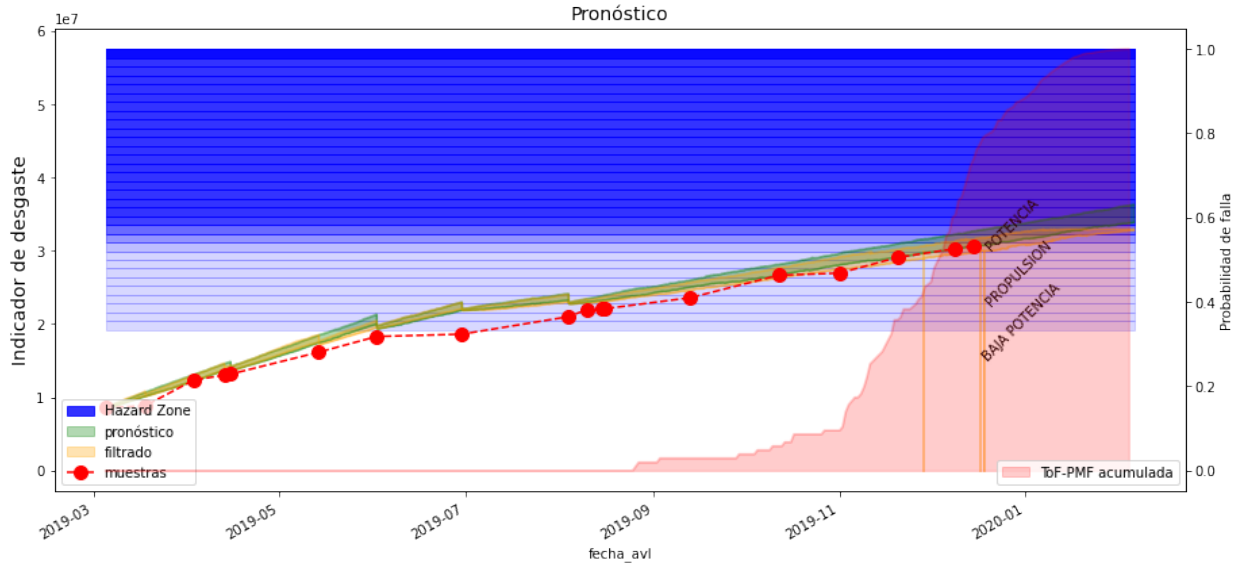


Figura 6.4: Progresión de estimaciones de degradación en línea para un camión.

El activo utilizado para obtener la degradación en la figura 6.4, es el mismo de la figura 6.3 donde se realiza una predicción a 1000 pasos o 42 días del evento de falla. En el caso de la figura 6.4, se tiene que la estimación se realiza a 3000 pasos o 125 días del evento, por lo que la estimación es más gruesa.

Tabla 6.1: Tabla de estimación de Tiempo de Falla de varios activos.

RUL	RUL estimada (días)					
	42		83		125	
probabilidad	0.4	0.8	0.4	0.8	0.4	0.8
asset1	60	80	97	115	21	115
asset2	22	37	79	101	113	134
asset3	25	47	54	73	106	129
asset4	52	81	116	146	167	199
asset5	41	67	76	98	87	106
asset6	42	57	72	89	56	171
asset7	47	67	73	92	84	106
asset8	18	39	47	68	90	108
asset9	42	68	112	142	142	168
asset10	41	44	66	78	117	139
media	39	59	79	100	98	138
desviación	13	15	22	26	39	30

A modo de ejemplificar la elección del umbral de falla, se ilustra en la tabla 6.1 la estimación de tiempo de falla desde el tiempo T . Y en la tabla 6.2 el resultado, en forma de error sobre la rul real, de seleccionar distintos umbrales.

Tabla 6.2: Tabla de errores en la estimación del Tiempo de Falla de los activos en revisión.

RUL	Error RUL estimada (días)					
	42		83		125	
probabilidad	0.4	0.8	0.4	0.8	0.4	0.8
asset1	-18	-38	-14	-32	104	10
asset2	20	5	4	-18	12	-9
asset3	17	-5	29	10	19	-4
asset4	-10	-39	-33	-63	-42	-74
asset5	1	-25	7	-15	38	19
asset6	0	-15	11	-6	69	-46
asset7	-5	-25	10	-9	41	19
asset8	24	3	36	15	35	17
asset9	0	-26	-29	-59	-17	-43
asset10	1	-2	17	5	8	-14
media error	10	18	19	23	39	26
desviación	13	15	22	26	39	30

6.3. Discusión

Se logra generar un algoritmo capaz de estimar el tiempo de falla de un activo, obteniendo resultados con alta variación, como se ven en la tabla 6.2 donde mientras mayor sea el tiempo de estimación, mayor será el error de predicción.

El algoritmo completamente consiste en la construcción de los estados de operación, la determinación del indicador de degradación y de una zona de peligro de falla, y el conjunto de algoritmos de estimación de tasas de desgaste y pronóstico del tiempo de falla. En conjunto, tienen un error bajo los 20 días para estimaciones a 40 días hasta la falla. Un error mayor de hasta 40 días para determinar el momento de falla a 120 días.

En términos prácticos, si es que se quiere realizar una estimación de en qué momento realizar una inspección o ida a taller del activo, se tiene que considerar un margen de por lo menos un mes para tener una precisión de 20 días en el instante de falla. Aunque si el activo está próximo a fallar en 20 días, dependiendo de la operación, es posible que no sea deseable tener un riesgo de tan gran magnitud.

En el caso de querer generar una agenda a un año de distancia, este algoritmo no permite tener una precisión tan alta, ya que depende fuertemente de las mediciones de los análisis tribológicos que se vayan realizando a lo largo de la operación. Estos tienen un impacto directo en la tasa de degradación del activo, ya que determinan la pendiente de la curva de degradación. Y si esta pendiente cambia mucho de un nivel a otro, puede implicar cambios de meses en el momento de falla de un activo.

7. Conclusiones

En la minería el problema de la gestión de activos en base a su vida útil, en particular la de los motores de camiones mineros, es un problema que se tiene muy presente, ya que el costo de la mantención de estos es una gran porción de la distribución de costos operacionales. En base a ello, esta tesis apunta en el camino de la generación de modelos de degradación para un activo importante en la operación como lo es el motor diésel de los camiones de extracción.

En este trabajo se llevó a cabo la construcción de la metodología que responde a la hipótesis de si es factible generar un modelo de degradación en tiempo real a partir de variables operacionales y mediciones del estado de salud del motor. Se utilizó el modelo en simulaciones que determinan de forma probabilística el tiempo de falla del motor, entregando información importante para la toma de decisiones en la faena en que estos se implementen. La hipótesis planteada es confirmada con el desarrollo de este trabajo.

Por otro lado, los objetivos general y particulares se responden con cada uno de los capítulos del trabajo. El objetivo general se responde con toda la metodología desarrollada, canalizando la información operacional y mediciones de la degradación del aceite hacia un indicador de degradación del motor que con su modelo de evolución nos entrega la estimación del tiempo de falla.

Uno a uno los objetivos específicos fueron respondidos, en primer lugar se tiene el desarrollo de la caracterización de los estados de operación a partir de los sensores en el motor. Esto empleó métodos de reducción de dimensionalidad y clustering, para luego con conocimiento experto determinar los clusters que definen un estado operacional.

El desarrollo de un indicador de degradación en base a la información de los análisis de aceites y eventos de fallas, responde al segundo objetivo, donde también se genera una zona de peligro de falla a partir de la resolución de un problema de optimización.

El tercer objetivo, de estimar de forma probabilística la tasa de degradación de cada estado de operación, se realiza de forma exitosa encontrando una distribución de la tasa de degradación para cada estado a partir de la tasa de degradación promedio del mismo periodo. En efecto, el algoritmo desarrollado es perfectible y se ha comprobado en ejercicios posteriores en otros ámbitos de investigación, que se pueden aplicar modelos predictivos en esta actividad, de forma de incorporar la incertidumbre dentro del modelo que predice la tasa de degradación de dicho estado.

El cuarto, quinto y sexto objetivos se resuelven con el desarrollo de las simulaciones donde se utiliza el modelo de degradación acumulada en función de los estados por los que transita el camión. Al mismo tiempo, en dicha etapa se utiliza la metodología que permite estimar de forma probabilística el evento de falla con el concepto de *First Passage Time*.

7.1. Trabajo Futuro

La generación de modelos de degradación a partir de datos operacionales y de degradación es una tarea compleja. En este trabajo se desarrolló una metodología que puede ser empleada sobre otros activos que presenten características similares a la estructura de datos. Se deben realizar ajustes para que los modelos se ajusten a la operación a monitorear, como el es caso de la construcción del indicador de degradación del motor en función de análisis de laboratorio del aceite usado; o la agregación de los datos para encontrar los estados operacionales.

El ejercicio realizado en esta tesis está enfocado en enmarcar una metodología que sea capaz de entregar herramientas de predicción a la toma de decisiones en el manejo de activos. Y está sujeta a la implementación en la operación, donde se debe construir la arquitectura de datos que la soporte, la forma de mostrar el tiempo de falla para finalmente realizar la gestión de una flota de camiones.

Además, existen puntos que se discuten en los capítulos que pueden ser mejorados en base a la información con la que se cuenta. Es el caso de la estimación de las tasas de degradación de los estados de operación, donde se reduce la información a una clase por estado, mientras se “pierde” información que podría ser aprovechada por un modelo de regresión para la tasa de degradación de dicho estado. O un modelo que, a partir de las variables operacionales del estado, pueda predecir de forma más precisa la tasa de degradación de ese momento.

Por último, un punto no menos importante que se puede agregar a esta investigación, es el impacto que tendría en la operación y el contraste con las gestiones realizadas en la faena. Esto es un análisis netamente económico basado en escenarios donde se tomen al pie de la letra las recomendaciones de cuándo realizar un mantenimiento preventivo por el modelo (el cual entrega solamente la probabilidad del momento de falla), donde se contraste con un grupo de control sin tomar las recomendaciones. En este caso, el análisis va más allá de la generación de una metodología y entra al campo de la implementación y su evaluación económica.

Bibliografía

- [1] Altman, N. y Krzywinski, M., “The curse(s) of dimensionality,” *Nature Methods*, vol. 15, pp. 399–400, 2018, [doi:10.1038/s41592-018-0019-x](https://doi.org/10.1038/s41592-018-0019-x).
- [2] Abdi, H. y Williams, L. J., “Principal component analysis,” *WIREs Computational Statistics*, vol. 2, no. 4, pp. 433–459, 2010, [doi:https://doi.org/10.1002/wics.101](https://doi.org/10.1002/wics.101).
- [3] Linderman, G. C. y Steinerberger, S., “Clustering with t-sne, provably,” *SIAM Journal on Mathematics of Data Science*, vol. 1, pp. 313–332, 2019, [doi:10.1137/18m1216134](https://doi.org/10.1137/18m1216134).
- [4] Kullback, S. y Leibler, R. A., “On information and sufficiency,” *The annals of mathematical statistics*, vol. 22, no. 1, pp. 79–86, 1951.
- [5] Maaten, L. V. D. y Hinton, G., “Visualizing data using t-sne,” *Journal of Machine Learning Research*, vol. 9, pp. 2579–2605, 2008.
- [6] McInnes, L., Healy, J., y Melville, J., “Umap: Uniform manifold approximation and projection for dimension reduction,” 2018, <http://arxiv.org/abs/1802.03426>.
- [7] Allaoui, M., Kherfi, M. L., y Cheriet, A., “Considerably improving clustering algorithms using umap dimensionality reduction technique: A comparative study,” pp. 317–325, Springer International Publishing, 2020.
- [8] Hozumi, Y., Wang, R., Yin, C., y Wei, G.-W., “Umap-assisted k-means clustering of large-scale sars-cov-2 mutation datasets,” *Computers in Biology and Medicine*, vol. 131, p. 104264, 2021, [doi:https://doi.org/10.1016/j.combiomed.2021.104264](https://doi.org/10.1016/j.combiomed.2021.104264).
- [9] Becht, E., Dutertre, C.-A., Kwok, I. W. H., Ng, L. G., Ginhoux, F., y Newell, E. W., “Evaluation of umap as an alternative to t-sne for single-cell data,” *bioRxiv*, 2018, [doi:10.1101/298430](https://doi.org/10.1101/298430).
- [10] Pealat, C., Bouleux, G., y Cheutet, V., “Improved time-series clustering with umap dimension reduction method,” en *2020 25th International Conference on Pattern Recognition (ICPR)*, pp. 5658–5665, 2021, [doi:10.1109/ICPR48806.2021.9412261](https://doi.org/10.1109/ICPR48806.2021.9412261).
- [11] Ahmed, M., Seraj, R., y Islam, S. M. S., “The k-means algorithm: A comprehensive survey and performance evaluation,” 2020, [doi:10.3390/electronics9081295](https://doi.org/10.3390/electronics9081295).
- [12] Likas, A., Vlassis, N., y J. Verbeek, J., “The global k-means clustering algorithm,” *Pattern Recognition*, vol. 36, no. 2, pp. 451–461, 2003, [doi:https://doi.org/10.1016/S0031-3203\(02\)00060-2](https://doi.org/10.1016/S0031-3203(02)00060-2). *Biometrics*.
- [13] Ester, M., Kriegel, H.-P., Sander, J., y Xu, X., “A density-based algorithm for discovering clusters in large spatial databases with noise,” en *Proceedings of the Second International Conference on Knowledge Discovery and Data Mining, KDD’96*, p. 226–231, AAAI Press, 1996.

- [14] Vališ, D., Žák, L., y Pokora, O., “Failure prediction of diesel engine based on occurrence of selected wear particles in oil,” *Engineering Failure Analysis*, vol. 56, pp. 501–511, 2015, [doi:10.1016/j.engfailanal.2014.11.020](https://doi.org/10.1016/j.engfailanal.2014.11.020).
- [15] Nedić, B., Perić, S., y Vuruna, M., “Monitoring physical and chemical characteristics oil for lubrication,” *Tribology in Industry*, vol. 31, pp. 59–66, 2009.
- [16] Perić, S. y Nedić, B., “Monitoring lubricant performance in field application,” *Tribology in Industry*, vol. 34, pp. 92–100, 2012, [doi:10.5937/vojtehg1204059p](https://doi.org/10.5937/vojtehg1204059p).
- [17] Raposo, H., Farinha, J. T., Fonseca, I., y Galar, D., “Predicting condition based on oil analysis – a case study,” *Tribology International*, vol. 135, pp. 65–74, 2019, [doi:10.1016/j.triboint.2019.01.041](https://doi.org/10.1016/j.triboint.2019.01.041).
- [18] Arulampalam, M., Maskell, S., Gordon, N., y Clapp, T., “A tutorial on particle filters for online nonlinear/non-gaussian bayesian tracking,” *IEEE Transactions on Signal Processing*, vol. 50, no. 2, pp. 174–188, 2002, [doi:10.1109/78.978374](https://doi.org/10.1109/78.978374).
- [19] Rozas, H., Jaramillo, F., Perez, A., Jimenez, D., Orchard, M. E., y Medjaher, K., “A method for the reduction of the computational cost associated with the implementation of particle-filter-based failure prognostic algorithms,” *Mechanical Systems and Signal Processing*, vol. 135, p. 106421, 2020, [doi:10.1016/j.ymsp.2019.106421](https://doi.org/10.1016/j.ymsp.2019.106421).
- [20] Orchard, M. y Vachtsevanos, G., “A particle-filtering approach for on-line fault diagnosis and failure prognosis,” *Transactions of The Institute of Measurement and Control - TRANS INST MEASURE CONTROL*, vol. 31, 2009, [doi:10.1177/0142331208092026](https://doi.org/10.1177/0142331208092026).
- [21] Jaramillo, F., Valderrama, M., Quintero, V., Perez, A., y Orchard, M., “Time-of-failure probability mass function computation using the first-passage-time method applied to particle filter-based prognostics,” vol. 12, *Prognostics and Health Management Society*, 2020, [doi:10.36001/phmconf.2020.v12i1.1299](https://doi.org/10.36001/phmconf.2020.v12i1.1299).
- [22] Nedić, B., Perić, S., y Vuruna, M., “Monitoring physical and chemical characteristics oil for lubrication,” *Tribology in Industry*, vol. 31, pp. 59–66, 2009.