

MODELO DE GESTIÓN PARA DETERMINAR PLAN DE CAMBIO DE
BASTIDORES Y ORUGAS APLICANDO MACHINE LEARNING EN LA FLOTA DE
TRACTORES DE ORUGAS DE CERREJÓN.

PEDRO SAÚL GÓMEZ MERCADO

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERIAS FISICOMECANICAS
ESCUELA DE INGENIERÍA MECÁNICA
MAESTRÍA EN GERENCIA DE MANTENIMIENTO
BUCARAMANGA

2021

MODELO DE GESTIÓN PARA DETERMINAR PLAN DE CAMBIO DE
BASTIDORES Y ORUGAS APLICANDO MACHINE LEARNING EN LA FLOTA DE
TRACTORES DE ORUGAS DE CERREJÓN.

PEDRO SAÚL GÓMEZ MERCADO

Plan de Trabajo de Grado para optar al título de Magister en Gerencia de
Mantenimiento

Director

Ing. CARLOS BORRÁS PINILLA

PhD. MSc., Esp. Gerencia de Mantenimiento

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERIAS FISICOMECHANICAS
ESCUELA DE INGENIERÍA MECÁNICA
MAESTRÍA EN GERENCIA DE MANTENIMIENTO
BUCARAMANGA

2021

AGRADECIMIENTOS

Este trabajo de grado no hubiese sido posible realizar sin el soporte y apoyo del ingeniero Carlos Borrás, a quien agradezco profundamente por ser el director del proyecto. También un agradecimiento muy especial a Melisa Paola Leiva, mi prometida, por su constante apoyo y aliento en los momentos necesarios para trabajar e investigar en los tópicos de este trabajo. Agradezco además a la compañía CARBONES DEL CERREJÓN por brindarme esta oportunidad y a todos los empleados que de alguna manera me facilitaron información o tiempo para el desarrollo de este trabajo.

CONTENIDO

	Pág.
INTRODUCCIÓN	12
1. OBJETIVOS.....	16
1.1. OBJETIVO GENERAL	16
1.2. OBJETIVOS ESPECIFICOS.....	16
2. MARCO TEÓRICO	17
2.1. INTELIGENCIA ARTIFICIAL.....	17
2.2. MACHINE LEARNING	17
2.3. APRENDIZAJE SUPERVISADO	22
2.3.1 Clasificación multiclase.....	24
2.4. MÁQUINA DE SOPORTE VECTORIAL	26
3. MODOS DE FALLAS DEL TREN DE RODAJE DE TRACTORES DE ORUGAS	33
3.1. MODOS DE FALLAS DE ORUGAS.....	34
3.1.1 Desgaste de la zapata y bujes.....	35
3.1.2 Cadena estirada.....	37
3.1.3 Cadena no tensionada.....	39
3.2. MODOS DE FALLAS DE BASTIDORES	40
3.2.1 Desgaste de rodillos y rueda guía.....	40
3.2.2 Daño interno	42
3.2.3 Rodillo y rueda guía frenados	43
4. PLAN DE GESTIÓN DE MANTENIMIENTO ACTUAL PARA MODOS DE FALLAS DEL TREN DE RODAJE	44

5.	DESARROLLO DEL MODELO SVM	46
5.1.	TRATAMIENTO DE DATOS.....	46
5.2.	HERRAMIENTA UTILIZADA.....	46
5.3.	DIAGRAMA DEL PROCESO.....	47
6.	RESULTADOS	48
6.1.	ORUGAS	48
6.2.	BASTIDORES.....	54
6.3.	ANALISIS DE RESULTADOS.....	
7.	CONCLUSIONES	63
	BIBLIOGRAFÍA.....	65
	ANEXOS	69

LISTA DE FIGURAS

	Pág.
Figura 1. Tractor de orugas, vista frontal y trasera.	14
Figura 2. Bastidor y orugas del tractor	15
Figura 3. Diagrama de flujo del aprendizaje supervisado	19
Figura 4. Diagrama de flujo del aprendizaje no supervisado	20
Figura 5. Diagrama de flujo del aprendizaje por refuerzo	21
Figura 6. Ejemplo de clasificación binaria.....	24
Figura 7. Ejemplo de un clasificador cuatro clases	25
Figura 8. Ejemplo de un modelo SVM para vectores bidimensionales	27
Figura 9. Sobreajuste.....	28
Figura 10. Subajuste.....	29
Figura 11. Comparación de hiperplanos de separación.....	30
Figura 12 Transformación del espacio de entrada por medio de un Kernel.....	32
Figura 13. Eslabón y cadena	34
Figura 14. Diferentes tipos de zapatas	34
Figura 15. Medición del desgaste de la altura de la zapata	35
Figura 16. Medición del desgaste exterior del buje.....	36
Figura 17. Cadena estirada.....	37
Figura 18. Medición del desgaste eslabones y buje	38
Figura 19. Medición de ruedas guías y rodillos.....	41
Figura 20. Parte interna del bastidor.....	43
Figura 21. Clasificación eventos de mantenimiento (2018-2020)	44
Figura 22 Diagrama del proceso para la creación del modelo SVM	47
Figura 23 Análisis de datos de falla y operación normal (eslabón, bujes y horas) .	48
Figura 24 Análisis de datos de falla y operación normal (zapata, paso y horas) ...	49

Figura 25 Distribución de desgastes de las orugas, normalizado y características	50
Figura 26 Distribución de operación normal de las orugas, normalizado y características.....	50
Figura 27 Resultado SVM usando Fine Gaussian para orugas	52
Figura 28 Resultado SVM usando Cubic para orugas	53
Figura 29 Rata de valores positivos y valores falsos negativos en orugas	53
Figura 30 Valores positivos predictivo y rata de falsos descubiertos en orugas	54
Figura 31 Análisis de datos de falla y operación normal (Rodillo 1, rodillo 2 y horas)	55
Figura 32 Análisis de datos de falla y operación normal (Rueda guía trasera, rueda guía delantera y horas)	55
Figura 33 Análisis de datos de falla y operación normal (Rodillo 4, rodillo 5 y rodillo 3).....	56
Figura 34 Distribución de operación normal del bastidor, normalizado y características.....	57
Figura 35 Distribución de desgastes del bastidor, normalizado y características ..	57
Figura 36 Resultado SVM usando Fine Gaussian para bastidores.....	58
Figura 37 Rata de verdaderos positivos y valores falsos negativos para bastidores	59
Figura 38 Rata de verdaderos positivos predictivo y falsos descubiertos.....	59
Figura 39 Desviación estándar de Fine Gaussian para bastidores.....	60
Figura 40 Curva ROC para SVM Fine Gaussian	61
Figura 41 Respuesta del SVM a las entradas.....	62

LISTA DE TABLAS

Pág.

Tabla 1 Resultados del SVM para diferentes algoritmos	51
Tabla 2 Resultados del SVM para diferentes algoritmos	58

LISTA DE ANEXOS

	Pág.
Anexo A Formato de registro de medición de rodaje de tractores de orugas	69
Anexo B Tabla guía de medición del desgaste de los eslabones de las orugas....	70

RESUMEN

TÍTULO: MODELO DE GESTIÓN PARA DETERMINAR PLAN DE CAMBIO DE BASTIDORES Y ORUGAS APLICANDO MACHINE LEARNING EN LA FLOTA DE TRACTORES DE ORUGAS DE CERREJÓN.*

AUTOR: PEDRO SAÚL GÓMEZ MERCADO**

PALABRAS CLAVE: MACHINE LEARNING, APRENDIZAJE AUTOMÁTICO, MÁQUINA DE SOPORTE VECTORIAL (SVM), TREN DE RODAJE.

DESCRIPCION: Cerrejón es una compañía minera de explotación de carbón que se ha visto afectada por la caída drástica del precio del carbón en el último año, lo que la ha llevado a buscar estrategias que la ayuden a seguir siendo una mina costo efectiva y vigente en el mercado. En este proyecto se propone la incorporación de técnicas avanzadas de mantenimiento basadas en el análisis de datos por medio de aprendizaje automático que permitan la optimización de la estrategia de cambio de los componentes bastidores y orugas. En este trabajo se estudia y determinan los principales modos de fallos de los componentes del tren de rodaje y a partir del registro histórico de sus fallas y el uso de machine learning con el software Matlab. Se determinó un modelo de aprendizaje supervisado de Máquina de soporte vectorial que permite clasificar la condición de desgaste y condición de operación normal, de acuerdo con las mediciones del porcentaje de desgaste de las partes de estos componentes y sus horas de operación, con una precisión de 98% para las orugas y 100% para bastidores. Con este modelo se busca tomar decisiones asertivas con respecto al cambio de estos componentes que permitan reducir al máximo los fallos imprevistos o no programados.

*Trabajo de grado

** Facultad de Ingenierías Físicomecánicas. Escuela de Ingeniería Mecánica. Director: Carlos Borrás Pinilla PhD. en Ingeniería Mecánica

ABSTRACT

TITLE: MANAGEMENT MODEL TO DETERMINE CHANGE PLAN FOR FRAMES AND TRACKS APPLYING MACHINE LEARNING IN THE CERREJÓN TRACKED TRACTOR FLEET*

AUTHOR: PEDRO SAÚL GÓMEZ MERCADO**

KEY WORDS: MACHINE LEARNING, AUTOMATIC LEARNNG, VECTOR SUPPORT MACHINE, UNDERCARRIAGE

DESCRIPTION: Cerrejón is a coal mining company that has been affected by the drastic fall in the price of coal in the last year, which has led it to look for strategies that help it remain a cost effective and current mine in the market. This project proposes the incorporation of advanced maintenance techniques based on the analysis of data by means of machine learning that allow the optimization of the change strategy of the frame and track components. This work studies and determines the main fault modes of the components of the undercarriage and from the historical record of their failures and the use of machine learning with Matlab software. A model of supervised learning of vector support machine was determined that allows to classify the condition of wear and normal operating condition, according to the measurements of the percentage of wear of the parts of these components and their hours of operation, with an accuracy of 98% for tracks and 100% for frames. This model seeks to make assertive decisions regarding the change of these components that allow to minimize unforeseen or unscheduled failures.

* Degree work

** Faculty of Physicomechanical Engineering. School of Mechanical Engineering Director: Carlos Borrás Pinilla PhD. in Mechanical Engineering

INTRODUCCIÓN

Cerrejón es una de las minas de extracción de carbón a cielo abierto más grande del mundo, con una extensión de 69 mil hectáreas y capacidad de producción de más de 40 millones de toneladas métricas. Siendo este un importante actor de la economía en Colombia y motor de La Guajira¹. Con la caída drástica del precio del carbón la empresa tiene como pilar fundamental optimizar los procesos con el fin de mantenerse competitiva, estableciendo estrategias que le apunten a la reducción de costos de manera responsable².

Actualmente en la superintendencia de planeación y programación de la vicepresidencia de mantenimiento, de CARBONES DE CERREJÓN, no se tiene un método certero que permita predecir el número de componentes a cambiar dentro del ejercicio periódico de plan de cambio de componentes para aquellos componentes de equipos que pertenezcan al tren de rodaje y que tienen en su estrategia de mantenimiento el cambio por condición, lo cual puede conllevar a una solicitud errada de compras, poniendo en riesgo la credibilidad con los representantes de los accionistas, comprometiendo las metas de presupuesto de la superintendencia de tractores de orugas y reconstrucción rodajes, y la disponibilidad de tractores ofrecida a producción para el cumplimiento de sus metas.

En la superintendencia de tractores de orugas dos de los componentes que se cambian por condición dentro del tren de rodaje son los bastidores y las orugas siendo los de más alto valor económico comparados con el resto de los componentes de todos los sistemas. Al tener variabilidad en la flota, manteniendo tractores con diferentes modelos, D9T las series RJS y TWG, en D10T las series RJS y RAB (estos últimos con orugas con tratamiento térmico distinto) y en D11T

¹ CERREJÓN Página principal [en línea] disponible en: <https://www.cerrejon.com/>

² PORTAFOLIO Caída en precio del carbón ya afecta la operación en el país [en línea] disponible en: <https://www.portafolio.co/economia/caida-en-precio-del-carbon-ya-afecta-la-operacion-en-el-pais-530425>

las series GEB y AMA³, con contextos operacionales variados dificulta aún más poder establecer un plan de cambio a largo plazo sin alguna técnica avanzada de mantenimiento.

Hoy día y desde hace más de 24 meses, se registran datos de medición de desgaste para orugas y bastidores cada mil horas de operación, concordando con los PMs que se realizan en los talleres permanentes (1000 horas para PM tipo D y 2000 horas para PM tipo E), normalmente con personal calificado y con herramientas idóneas, pero aun nos encontramos con imprevistos estando los equipos en taller en mantenimiento programado, lo cual nos lleva a acciones reactivas, afectando normalmente el cumplimiento de la programación comprometido en la semana o ventana de mantenimiento, alargando las paradas de los equipos, afectando negativamente la productividad del personal técnico, conllevando a la reprogramación de actividades, cambio de secuencia en los trabajos planeados en el tractor de orugas, necesidad de mayor apoyo logístico y por ende afectación en la disponibilidad comprometida para el cumplimiento de los planes de producción, en lo que refiere a equipos auxiliares como lo son los tractores de orugas o bulldozer.

Aplicando técnicas de mantenimiento avanzado como el método de Machine Learning, a través del software MATLAB o Python, se pretende reducir al máximo los fallos imprevistos o no programados relacionados con bastidores y orugas, y todos los retrabajos, pérdidas e improductividad que estos fallos imprevistos traen consigo, otorgándole valor al mantenimiento predictivo y aplicando nuevas tecnologías, siendo innovadores en la vicepresidencia de mantenimiento de CARBONES DEL CERREJÓN, manteniendo a nuestra empresa a la vanguardia de

³ CATERPILLAR, Products Large dozers [en línea] disponible en: https://www.cat.com/es_US/products/new/equipment/dozers/large-dozers.html

las más altas tecnologías aplicadas en el mundo en mantenimiento, especialmente en la industria de la minería.

Por medio Machine Learning se podrá predecir el número de componentes a cambiar dentro del ejercicio periódico de plan de cambio de componentes para aquellos componentes de equipos que pertenezcan al tren de rodaje y que tienen en su estrategia de mantenimiento el cambio por condición de desgaste. Este modelo de gestión computacional de Machine Learning hará esto posible ya que tiene la capacidad de analizar un gran número de datos de medición de desgaste y así detectará, identificará, clasificará y diagnosticará por medio de máquinas de vectores soporte (SVM) fallas potenciales y sus posibles causas de manera oportuna.

Figura 1. Tractor de orugas, vista frontal y trasera.



Figura 2. Bastidor y orugas del tractor



Con Machine Learning podremos ejecutar acciones pertinentes y gestión oportuna de mantenimiento sobre estos componentes. Las compras serán asertivas, inventario en bodega alineado con la realidad, ganancia en credibilidad con los representantes de los accionistas, facilidad para el cumplimiento de las metas de presupuesto de la superintendencia de tractores de orugas y reconstrucción rodajes, y afectación reducida en la disponibilidad de tractores ofrecida a producción para el cumplimiento de las metas en relación y mayor confiabilidad en el sistema de tren de rodaje.

Indiscutiblemente la implementación de este proyecto traerá grandes beneficios para la empresa, bien sea en la parte económica, en agilización de los procesos de análisis de confiabilidad, en agilización en la elaboración de presupuesto de planeación, confiabilidad en los planes de parada de programación, disminución de imprevistos para el supervisor, mayor confiabilidad de equipos de la empresa y mayor confianza en los representantes de accionistas principalmente.

1. OBJETIVOS

1.1. OBJETIVO GENERAL

Desarrollar un modelo computacional inteligente que permita predecir el cambio de bastidores y orugas, basados en la condición y datos históricos de la flota tractores de orugas.

1.2. OBJETIVOS ESPECIFICOS

- Seleccionar y analizar los diferentes modos de fallos, las causas principales que los originan y su criticidad operativa, en las orugas y bastidores de los bulldozers de la flota de Cerrejón.
- Seleccionar las características dimensionales de la data relacionadas con los modos de fallos que permitan a el sistema experto operar de manera continua y robusta para la detección, identificación y clasificación de las causas de fallos en los tractores de orugas y bastidores de la flota del Cerrejón.
- Desarrollar y aplicar un modelo de gestión Machine Learning para los componentes bastidores y orugas, a través del software MATLAB o Python, en los bulldozers de la empresa Cerrejón.
- Validar el modelo de Machine Learning aplicada a los componentes bastidores y orugas de los bulldozers con datos frescos nuevos obtenidos de operación.

2. MARCO TEÓRICO

2.1. INTELIGENCIA ARTIFICIAL

La IA, como se conoce comúnmente a la inteligencia artificial es una disciplina informática que imita parte de lo conocido sobre el funcionamiento del cerebro humano (procesos de percepción sensorial) y se aplica en una máquina, la cual debe ser capaz ayudada con algoritmos de tratar diferentes, complejos y gran cantidad de datos para analizarlos, identificar sistemas, reconocer patrones etcétera. El cerebro humano hace uso de la experiencia y el aprendizaje, y la IA no está exenta a ello. Son programas con la habilidad de aprender y razonar como humanos⁴. Los principales ámbitos o áreas de aplicación de sistemas IA son: medicina, ingeniería, economía, biología, informática, robótica, automatización, física y matemáticas. Las aplicaciones de mayor impacto en la ingeniería son: organización de la producción, optimización de procesos, cálculo de estructuras, planificación y logística, diagnóstico de fallos y toma de decisiones.

2.2. MACHINE LEARNING

El Machine learning o aprendizaje automático usa algoritmos automatizados partiendo de un conjunto inicial de datos permite determinar resultados predictivos, descriptivos y prescriptivos⁵. A través del aprendizaje automático se pueden construir modelos basados en las relaciones complejas de entradas y salidas, procesando los datos y obteniendo un criterio optimizado de predicción. Denominando “aprendizaje” al proceso automático de la creación del modelo y “datos de aprendizaje” a los datos utilizados en el proceso.

⁴ BENÍTEZ IGLÉSIAS, Raúl Inteligencia artificial avanzada. España: Editorial UOC 2013

⁵ HUDDLESTON, S. Machine Learning. Informs Analytics Body of Knowledge, 2018

Denominada una disciplina de la IA que a través de algoritmos que se basan en colecciones de ejemplos sobre algún fenómeno dota a los ordenadores de la capacidad de identificar patrones en datos masivos para hacer predicciones⁶, este aprendizaje permite realizar tareas específicas de forma autónomas a las computadoras, es decir sin necesidad de ser programados, las máquinas “aprenden” con la experiencia. El aprendizaje automático brinda en el ámbito de las empresas reducir costos, predecir tendencias, impulsar la innovación, mejora la segmentación del público objetivo, entre otros⁷.

Las aplicaciones prácticas donde se utiliza el aprendizaje automático son en vehículos inteligentes, recomendaciones, redes sociales, procesamiento del lenguaje humano (SIRI), motores de búsquedas, detección de enfermedades, antivirus⁸. Además, el machine learning ha realizado un aporte significativo al mantenimiento⁹, aplicación tratada en este proyecto, ayudando con las predicciones y mejoras en las rutinas de mantenimiento.

El aprendizaje automático puede ser¹⁰:

- Supervisado: Su finalidad es poder hacer predicciones con algoritmos que hacen uso de un sistema de datos etiquetado y que se han alimentado previamente con aprendizaje. Ejemplos de aplicación: Detectores de spam.

⁶ BURKOV, Andriy The Hundred-Page Machine Learning Andriy Burkov 2019

⁷ JONES, Herbert Aprendizaje Automático: El Aprendizaje Automático para principiantes que desean comprender aplicaciones, Inteligencia Artificial, Minería de Datos, Big Data y más Independently published 2019

⁸ IBERDROLA Machine learning aprendizaje automático [en línea] disponible en: <https://www.iberdrola.com/innovacion/machine-learning-aprendizaje-automatiko>

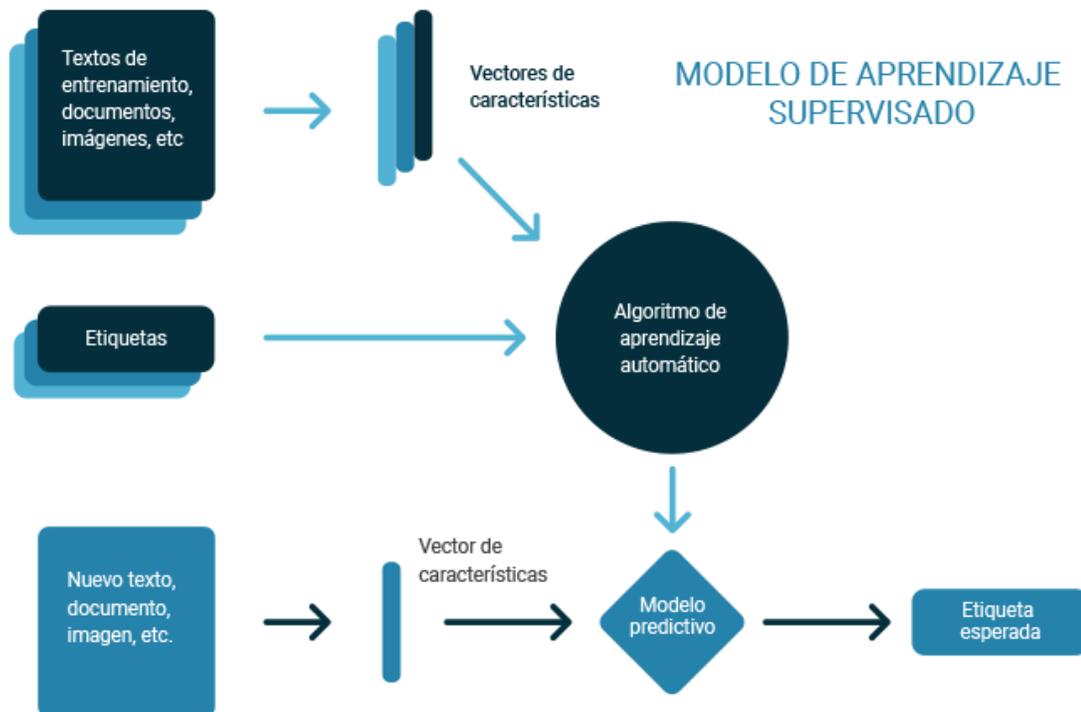
⁹ MOSCOS, Yuliano, YARIN, Maria Mejora del mantenimiento predictivo utilizando la técnica de machine learning en matlab en los camiones mineros eléctricos komatsu 830e y 930e de la compañía minera antapaccay – cusco 2019

¹⁰ HASTIE, T., TIBSHIRANI, R., & FRIEDMAN, J. The elements of statistical learning: data mining, inference, and prediction, Springer Series in Statistics. 2009

Dentro de los algoritmos supervisados se encuentran la regresión y clasificación, cuyos tipos son los siguientes:

- ✓ Regresión: regresión lineal, regresión logística y basado en arboles de decisión.
- ✓ Clasificación: Maquinas de vectores de soporte SVM, K- vecinos más cercanos y Bayes

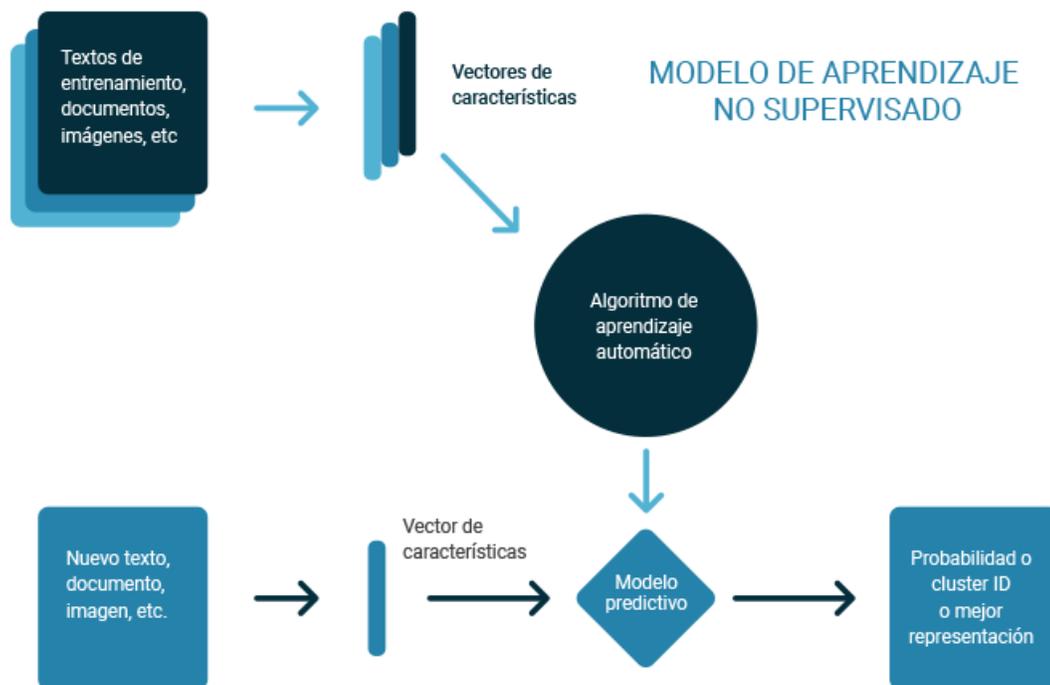
Figura 3. Diagrama de flujo del aprendizaje supervisado



Fuente: MEDIUM Tipos de aprendizaje automático [en línea] disponible en: <https://medium.com/soldai/tipos-de-aprendizaje-autom%C3%A1tico-6413e3c615e2>

- No supervisado: Su finalidad es la de hallar patrones que permitan organizar de cierta manera datos que no tienen relación o que no están etiquetados en el sistema. Estos algoritmos no tienen conocimiento previo. Ejemplos de aplicación: Marketing
- Reforzado: Su finalidad es aprender a través de la experiencia, siendo capaz de tomar ante diferentes situaciones la decisión más acertada. Estos algoritmos se basan en prueba y error. Ejemplos de aplicación: diagnósticos médicos, reconocimiento facial, clasificar secuencias de ADN

Figura 4. Diagrama de flujo del aprendizaje no supervisado



Fuente: MEDIUM Tipos de aprendizaje automático [en línea] disponible en: <https://medium.com/soldai/tipos-de-aprendizaje-autom%C3%A1tico-6413e3c615e2>

Figura 5. Diagrama de flujo del aprendizaje por refuerzo

MODELO DE APRENDIZAJE POR REFUERZO



Fuente: MEDIUM Tipos de aprendizaje automático [en línea] disponible en: <https://medium.com/soldai/tipos-de-aprendizaje-autom%C3%A1tico-6413e3c615e2>

En este proyecto se utilizó la técnica de aprendizaje supervisado. Generalmente cuando se utiliza este tipo de aprendizaje se divide el conjunto de datos en dos grupos. El primer grupo es llamado el conjunto de entrenamiento, que por lo general contiene la mayor cantidad de datos, es usado para que la maquina aprenda las relaciones de salida y entrada del problema basado en la información entregada. El segundo grupo llamado el conjunto de prueba, son los datos que no se usaron en el entrenamiento cuya función es evaluar las prestaciones de la máquina para datos de entrada que no se vieron en el entrenamiento. En la siguiente parte se estudiará en detalle este tipo de aprendizaje

2.3. APRENDIZAJE SUPERVISADO

Esta técnica de aprendizaje requiere un conjunto de patrones conocidos por la clase. La salida generalmente no coincidirá con la salida conocida requerida, por lo que se generará un error de salida. El error se utilizará para ajustar los parámetros del sistema. Si pensamos que, en una situación ideal, cada grupo representa una categoría, y cada categoría tiene un grupo altamente discriminativo asociado a otras categorías, podemos proponer un problema de clasificación supervisado para encontrar una superficie que separe diferentes grupos, llamadas superficies de decisión. Es importante decir que los grupos no tienen por qué estar relacionados.

Las superficies de decisión determinan regiones de decisión de tal manera que cada clase tiene asociada una región ρ y la decisión sobre la clase a asignar a un nuevo patrón se hará en base a la región en la que éste se encuentre en ρ .

En el aprendizaje supervisado, si se señala un punto x al evaluar la función de pertenencia de la clase, se considera que el punto está en el área de toma de decisiones asociada a la clase. Construir un clasificador en base a regiones de decisión puede considerarse como una aproximación inversa a la construcción de la función d , ya que se trata de definir R_i para $i = 0,1,2, \dots, L$ como el subconjunto de ρ para el cual $d(x) = w_i$, o sea,

$$R = \{x; d(x) = w_i\} \quad (1)$$

donde $R_0, R_1, R_2, \dots, R_j$ son distintos y verifican que

$$\rho = \cup_i R_i \quad (2)$$

Los subconjuntos R_i forman una partición de ρ . Con este planteamiento, un clasificador es una partición de ρ en $L+1$ subconjuntos disjuntos

$$R_0, R_1, R_2, \dots, R_L \quad (\rho = \cup_i R_i) \quad (3)$$

Cada una de las regiones de R_i se denominan regiones de decisión y las fronteras de decisión son las fronteras entre ellas.

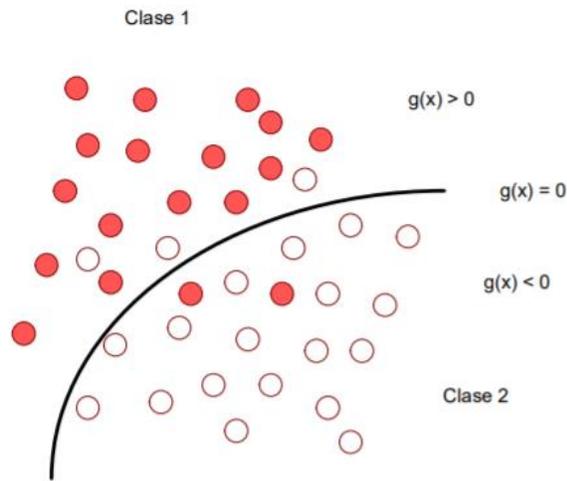
La Figura 6 se muestra un ejemplo de clasificación con dos clases. Dado un patrón x , la decisión sobre su clase dependerá de la función discriminante $g(x)$. La frontera de decisión entre las dos clases es el lugar de los puntos que verifica la ecuación $g(x) = 0$. Por lo tanto, si $g(x) > 0$, entonces la muestra se marcará como clase 1, y si $g(x) < 0$, entonces se marcará como clase 2. Entonces, R_i es el área de decisión asociada a la clase i , e incluye todos los puntos asociados con la etiqueta¹¹

$$R_1 = \{x; g(x) > 0\} \quad (4)$$

$$R_2 = \{x; g(x) < 0\} \quad (5)$$

¹¹ VALLE, Fernando Implementación eficiente de clasificadores Prior-SVM para MATLAB, Tesis Universidad Carlos II de Madrid, 2010

Figura 6. Ejemplo de clasificación binaria



Fuente: VALLE, F. Implementación Eficiente de Clasificadores Prior-SVM para MATLAB 2010

2.3.1 Clasificación multiclase. Hasta ahora, hemos estudiado el caso de la clasificación binaria, que consiste en clasificar las muestras en dos categorías posibles. Al tratar con problemas de clasificación en la vida real, a menudo nos encontramos con problemas de multclasificación¹², como el problema de la Figura 7.

Existen dos métodos básicos usando clasificadores binarios para resolver estos problemas de clasificación N clase:

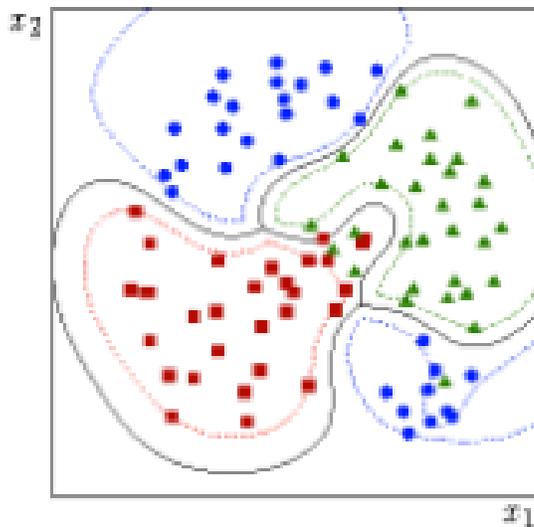
- Método uno contra todos: que incluye la combinación de clasificadores binarios entrenados de forma independiente para resolver diferentes partes del problema. Este método establece N modelos SVM, donde N es el número de clases. Cada n-ésimo SVM entrenará todos los ejemplos y etiquetará los

¹² ANGULO, Cecilio. Aprendizaje con máquinas núcleo en entornos de multclasificación. Tesis. Dpto. Ciència dels ordinadors. 2001.

de la n-ésima clase con etiquetas positivas y los elementos restantes de otras clases con etiquetas negativas.

- Método todos contra todos: La finalidad de este método es crear $N*(N-1) / 2$ clasificadores, uno para cada par de posibles clases, lo que lleva a que se enfrente todas las clases a cada una. En cada entrenamiento, solo se utilizan las dos clases de datos involucradas, Lo que quiere decir que un problema con 4 clases generaría los siguientes clasificadores: 1 vs 2, 1 vs 3, 1 vs 4, 2 vs 3, 2 vs 4 y 3 vs 4. Una vez hecho esto, los datos de la prueba se enviarán a todos estos clasificadores, y luego se agregarán los votos a la clase ganadora en cada caso. Finalmente, la clase que obtiene más votos es la clase sugerida por el sistema.

Figura 7. Ejemplo de un clasificador cuatro clases



Fuente: GERRIT, J. GenSVM: A Generalized Multiclass Support Vector Machine 2016

Es importante señalar que, dado que el método de "Todos contra todos" solo puede manejar menos muestras, tiene mayor libertad para encontrar el límite que separa

las dos clases¹³. Con respecto a los costos de entrenamiento, es mejor utilizar uno contra todos, ya que solo requiere capacitar a N SVM. La complejidad de la prueba de las dos estrategias es similar: uno contra todos requiere N evaluaciones y todos contra todos requieren N-1.

2.4. MÁQUINA DE SOPORTE VECTORIAL

La máquina de vectores de soporte o SVM (máquina de vectores de soporte) es un algoritmo que, partiendo del producto escalar de los vectores multidimensionales de las muestras, construye un hiperplano o conjunto de hiperplanos en un espacio de dimensionalidad muy alta que separa los grupos.

Fue desarrollada por Vapnik y Lerner en AT&T Labs en 1963, pero no fue hasta la década de 1990 que Boser publicó el primer artículo en 1992 y Cortes y Vapnik en 1995, cuando fue desarrollada y generalizada¹⁴. Originalmente fue diseñado para resolver problemas de clasificación binaria en los cuales las clases eran separables linealmente¹⁵, razón por la cual también se le llama Hiperplano de separación óptima o OSH (Hiperplano de separación óptima), porque la solución obtenida es una solución que clasifica correctamente todas las muestras, y genera un hiperplano de separación lo más alejado posible de estas¹⁶.

Esto se logra realizando un entrenamiento a los datos seleccionados para este objetivo, definiendo un hiperplano óptimo, en otras palabras, el máximo margen entre las muestras de cada una de las clases con relación a la frontera de

¹³ TOMAS, David (UPV). Una aproximación multilingüe a la clasificación de preguntas basada en aprendizaje automático. 2005.

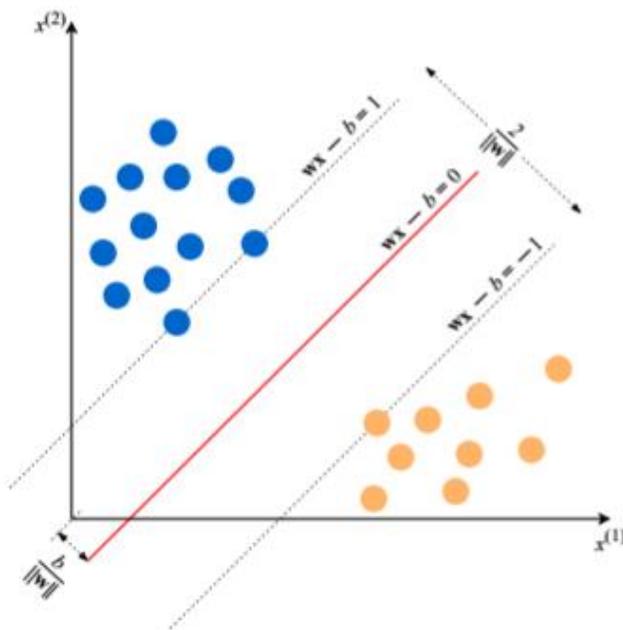
¹⁴ TAN, Ying A support vector machine with a hybrid kernel and minimal Vapnik-Chervonenkis dimension IEEE Transactions on Knowledge and Data Engineering, 2004

¹⁵ VAPNIK, Vladimir. Pattern recognition using generalized portraid method. Automation and remote control, 24. 1963.

¹⁶ BURGESS, Christopher A tutorial on support vector machines for pattern recognition. Bell Laboratories, Lucent Technologies, USA. Data Mining and Knowledge Discovery, 2, 121–167. 1998.

separación. Su objetivo está basado en que luego del entrenamiento realizado pueda generalizar de manera correcta los datos nuevos que no participaron de este entrenamiento, clasificándolo en la clase correcta, es decir a la cual pertenecen. Para lograrlo se intenta buscar una función f que minimice el costo empírico sobre el conjunto de entrenamiento, y que a su vez se llegue a la correcta generalización de la máquina.

Figura 8. Ejemplo de un modelo SVM para vectores bidimensionales



Fuente: BURKOV, A. The Hundred-Page Machine Learning Andriy Burkov 2019

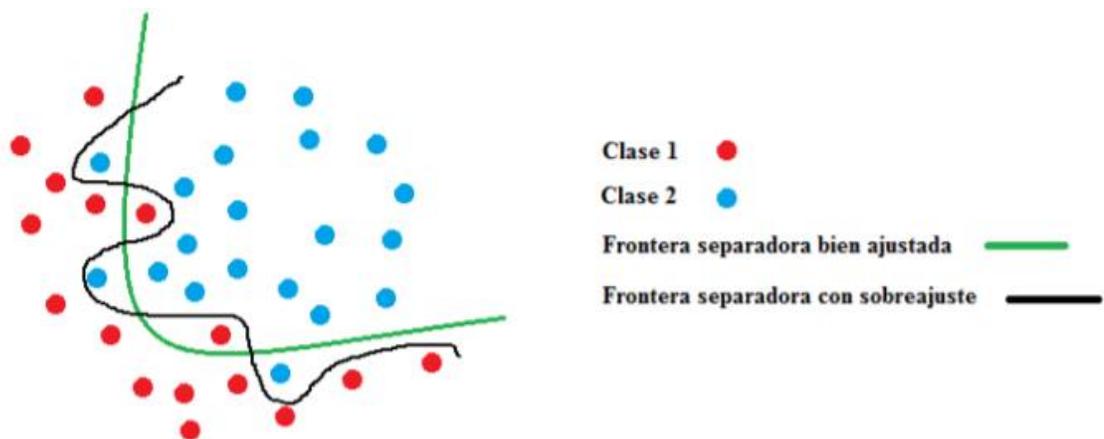
Existen dos efectos comúnmente encontrados en los entrenamientos que se deben evitar para lograr obtener una buena generalización, estos son el sobreajuste y el subajuste, explicados a continuación:

- Sobreajuste: sucede cuando se ajustan demasiado a las muestras los parámetros recolectados en el entrenamiento, lo que genera pierda en la

generalización y cuando se ingresa una nueva muestra no es clasificada correctamente

- Subajuste: sucede cuando se utilizan muy pocas muestras en el entrenamiento y el hiperplano generado es muy sencillo y no se logra una correcta generalización, razón por la cual la máquina no entregara resultados correctos a las nuevas muestras.

Figura 9. Sobreajuste



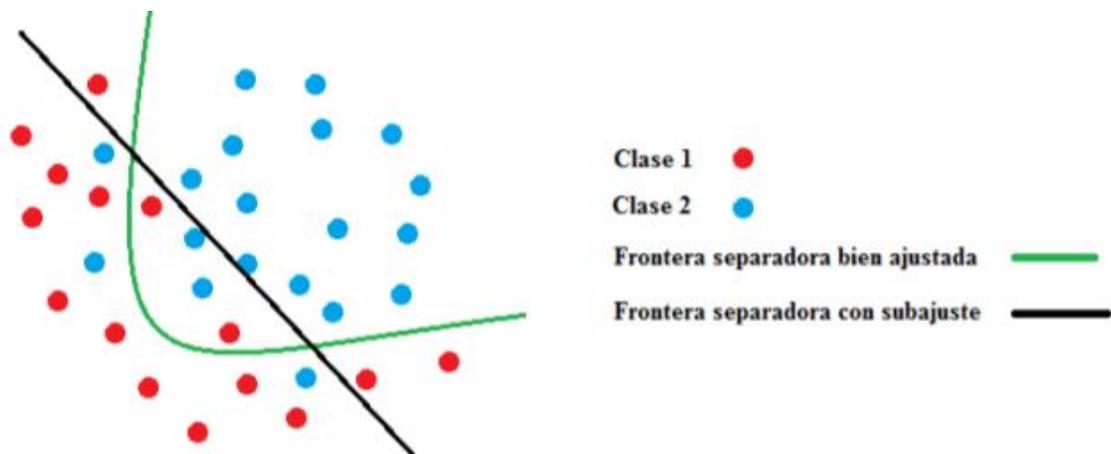
Fuente: SALAMANCA, L Generacion de conjuntos de maquina de soporte vectorial mediante tecnicas de remuestreo e inyeccion de ruido en las etiquetas. Universidad Autonoma de Madrid 2017

Si comparamos la SVM con otros paradigmas de aprendizaje y procesamiento automáticos como las Redes Neuronales, comprobamos que la SVM obtiene una mejor generalización, que hace que funcione bien cuando hay pocos datos y el espacio de entrada es de dimensión alta.

El método de SVM es bastante utilizado en aprendizajes supervisados que desarrollan métodos relacionados con problemas de regresión, selección de

variables clasificación binaria, clasificación multiclase, identificación de casos anómalos y clustering¹⁷, que mejora el clasificador lineal buscando un mejor hiperplano que el que se genera con el clasificador lineal. Al ser algoritmos de aprendizaje supervisado puede hacer predicciones con algoritmos que hacen uso de un sistema de datos etiquetado y que se han alimentado previamente con aprendizaje. Dado el conjunto de ejemplos de entrenamiento se etiquetan en distintas clases y representarlos en puntos en el espacio y así clasificar o separarlos. Esto deber realizarse con patrones óptimos de entrenamiento y de manera costo-efectiva y de esta forma los nuevos datos de prueba se clasificarán de forma acertada¹⁸.

Figura 10. Subajuste

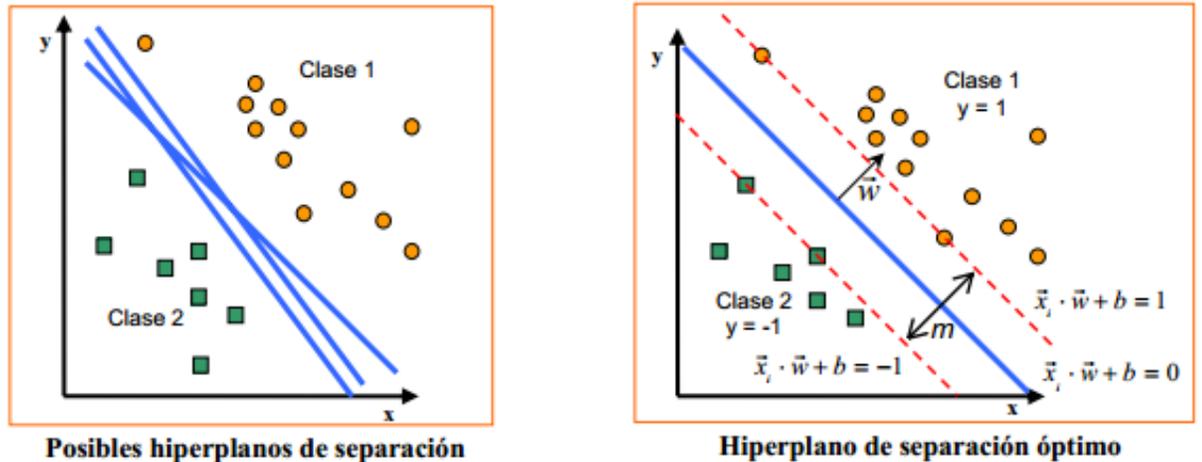


Fuente: SALAMANCA, L Generacion de conjuntos de maquina de soporte vectorial mediante tecnicas de remuestreo e inyeccion de ruido en las etiquetas. Universidad Autonoma de Madrid 2017

¹⁷ MORALES, Eduardo Maquinas de Soporte Vectorial [en línea] disponible en: <https://ccc.inaoep.mx/~emorales/Cursos/NvoAprend/Acetatos/svm2017.pdf#page41>

¹⁸ GONZÁLEZ, Samuel Abad. Detección de Anomalías Cardíacas con Aprendizaje Automático (Machine Learning) [en línea] disponible en: <http://samuelabad1991.blogspot.com/2014/02/analisis-con-maquinas-de-vectores.html>

Figura 11. Comparación de hiperplanos de separación



Fuente: GONZÁLEZ, Samuel Abad Detección de Anomalías Cardíacas con Aprendizaje Automático (Machine Learning) [en línea] disponible en: <http://samuelabad1991.blogspot.com/2014/02/analisis-con-maquinas-de-vectores.html>

En los casos donde se deban clasificar los datos en más de dos categorías, las curvas de separación no sean lineales o que los datos no sean completamente separables, el SVM utiliza Kernels¹⁹, la cual es una técnica que permite atacar problemas no lineales con algoritmos lineales, para no linealidad inherente y proyectar los datos a otros espacios de atributos en los que sí que exista un hiperplano lineal que los pueda separar.

Las funciones Kernels pueden expresarse como un producto escalar en un espacio dimensional alto, ya que son continuas, simétricas y positivas. Son capaces de simular un espacio dimensional en el que se toma como una dimensión cada

¹⁹ SCHOLKOPF, Bernhard Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond Germany The MIT Press 2001

característica de los datos. Cuando se está clasificando cada hiperplano puede tener una función Kernel diferente, sin importar el número de hiperplanos creados.

La función Kernel se expresa matemáticamente de la siguiente forma

$$x = \{x_1, x_2, \dots, x_n\} \rightarrow \phi(x) = \{\phi_1(x), \phi_2(x), \dots, \phi_n(x)\} \quad (6)$$

$$k(x_i, x_j) = \phi(x_i) \times \phi(x_j) \quad (7)$$

Los tipos de Kernels más usados son:

- Polinomiales homogéneas:

$$k(x_i, x_j) = (x_i \times x_j)^n \quad (8)$$

- Polinomiales no homogéneas:

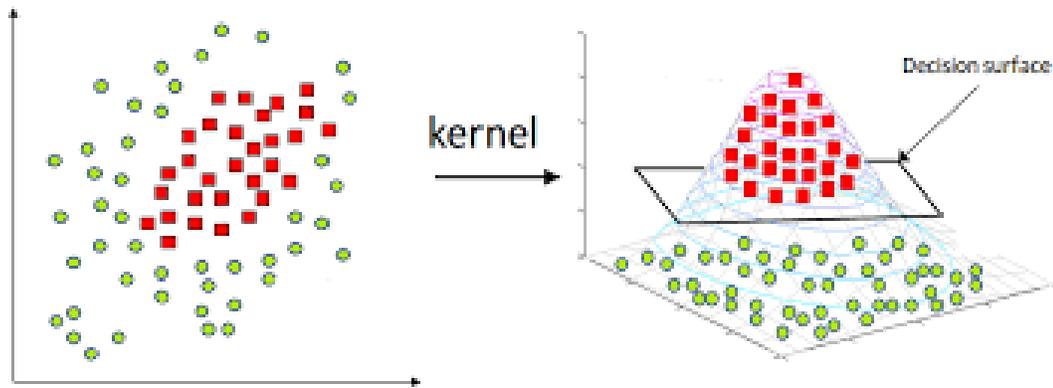
$$k(x_i, x_j) = (x_i \times x_j + 1)^n \quad (9)$$

- Gaussian o Radial basis function (RBF)

$$k(x_i, x_j) = \exp(-\gamma \times \|x_i - x_j\|)^2 \quad (10)$$

Donde $\gamma > 0$

Figura 12 Transformación del espacio de entrada por medio de un Kernel



Fuente: VAN VAERENBERGH, S Metodos Kernel para clasificacion [en línea] disponible en: https://gtas.unican.es/files/docencia/APS/apuntes/07_svm_kernel.pdf

3. MODOS DE FALLAS DEL TREN DE RODAJE DE TRACTORES DE ORUGAS

El tractor de oruga es una máquina de tracción, usada para arrastrar o empujar cargas pesadas de tierra en terrenos difíciles. Estos tractores se mueven sobre pesados carriles metálicos, que forman un anillo alrededor de grandes ruedas dentadas. Las ruedas mueven las bandas metálicas y éstas distribuyen el peso sobre una superficie amplia²⁰.

El tren de rodaje del tractor de oruga tiene dos funciones, la primera soportar el peso de la máquina y la segunda proporcionar la tracción a través del atrito con el suelo para permitir que el tractor ejecute su función de remoción de material. El tractor presenta elevado esfuerzo de tracción, conjugado con una buena adherencia sobre el terreno permitiéndoles retirar o empujar grandes cargas sin tener el problema de deslizamiento aún en lugares de desnivel grande²¹.

Las partes del tren de potencia del tractor de orugas están expuestas a varias fallas de acuerdo con la naturaleza del trabajo al que se somete, definiendo como falla el evento que provoca una pérdida total o parcial de la capacidad de un ítem para realizar las funciones para la cual fue diseñada

El tren de rodaje está compuesto fundamentalmente por las orugas o cadenas, ruedas motrices o mandos finales y bastidores. En el siguiente apartado se detallarán los modos de falla más comunes de los bastidores y orugas, partes a la que se ha enfocado este proyecto.

²⁰ ORELLANA PIMENTEL, Marco Tulio Programa de mantenimiento preventivo para tractores sobre orugas Caterpillar, en sigma constructores, S.A. Guatemala 2009

²¹ RICARDO, H. S., CATALANI, G. Manual práctico de escavação - Terraplenagem e escavação de rocha Pini, São Paulo 1990

3.1. MODOS DE FALLAS DE ORUGAS

Las orugas son componentes que permiten el desplazamiento del tractor sobre terrenos irregulares. Las orugas están compuestas por eslabones, zapatas, bujes, pasadores, tornillos y arandelas. Los eslabones se unen entre sí por medio de un pin, formando la cadena (Figura 13). Las zapatas se adhieren a cada eslabón por medio de tornillos y sufren el contacto del tractor con el terreno de aplicación. Dependiendo del uso o el contexto operacional las zapatas pueden variar en su diseño, ya sean más anchas, con una, dos o tres garras, o con tratamientos térmicos diferentes o de materiales distintos en su composición. Para minería se usan las forjadas, para terrenos pantanosos las de fundición y para terrenos asfálticos aplican de caucho, goma o poliuretano (Figura 14). Las orugas pueden ser selladas, lubricadas, engrasadas o tener ciertas combinaciones para protegerse de sobrecalentamientos y cumplir con la vida esperada.

Figura 13. Eslabón y cadena



Fuente: THYSSENKRUPP- BERCO [en línea] disponible en:
<https://www.thyssenkrupp-berco.com>

Figura 14. Diferentes tipos de zapatas



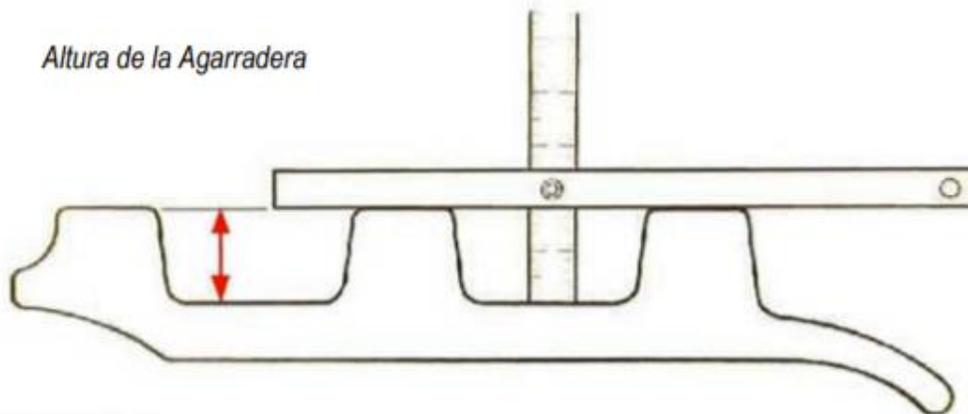
Fuente: THYSSENKRUPP- BERCO [en línea] disponible en:
<https://www.thyssenkrupp-berco.com>

Los principales modos de falla de las orugas son las siguientes:

3.1.1 Desgaste de la zapata y bujes. La zapata, sujeta al riel de rodadura por medio de tornillos de montaje y desmontaje, son las piezas que están en contacto con el suelo y por lo tanto son de los componentes con mayor desgaste en el tren de rodaje. La aleta vertical observada en la figura 15 es la parte de la zapata expuesta a mayor desgaste abrasivo. La causa del desgaste depende principalmente de las condiciones del terreno. Durante el funcionamiento, la zapata de la oruga tiene que vencer distintos esfuerzos tales como la fuerza de flexión, las fuerzas de fricción que provocan el desgaste y desgarramiento.

El desgaste más importante de la zapata es la altura relativa de la agarradera a la parte superior de la aleta de la zapata. Se deberá usar un medidor de profundidad para medir esto, como se muestra en la figura a continuación:

Figura 15. Medición del desgaste de la altura de la zapata



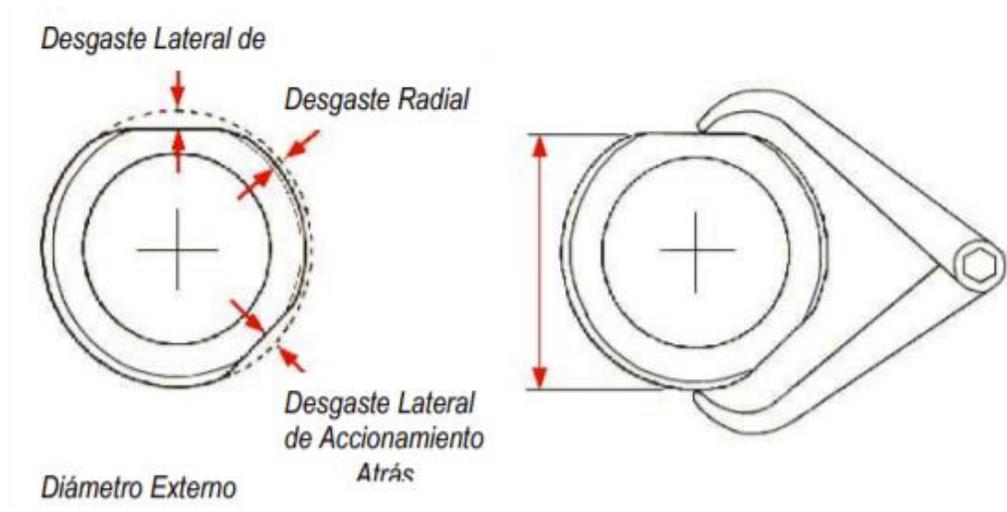
Fuente: STRICKLAND-TRACKS Manual de instalación, operación y mantenimiento [en línea] disponible en: <https://www.stricklandtracks.co.uk>

Las cualidades necesarias de un buje son la tolerancia a la fatiga y la resistencia al desgaste. Debido a que tanto la superficie interior como el diámetro exterior del buje están sometidos a fricción y desgaste con el uso.

La superficie exterior del buje está en contacto con la rueda dentada y sometida a su martilleo. Las partículas de tierra que penetran entre la rueda dentada y el buje aceleran el proceso de desgaste, a su vez la interacción entre la superficie interior del buje y el pasador también producen un efecto de desgaste. Si la tensión del conjunto de eslabón es demasiado alta, el desgaste interno será más rápido. La parte exterior del buje se desgasta en forma más rápida que la parte interna.

El desgaste externo de los bujes puede ser de cualquiera de los 3 tipos indicados anteriormente. Se debe tomar mediciones en cada posición y debe considerarse la zona donde el desgaste llega a un máximo. Para medir este desgaste, se usa calibrador externo pequeño.

Figura 16. Medición del desgaste exterior del buje

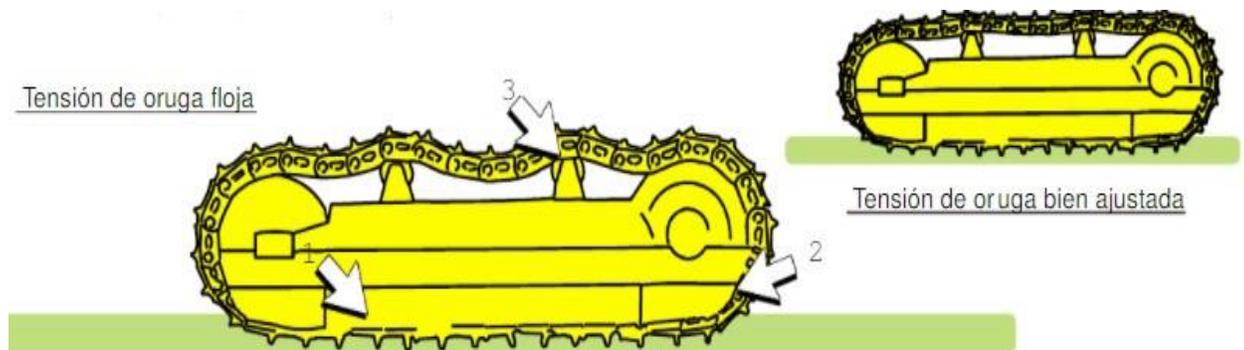


Fuente: STRICKLAND-TRACKS Manual de instalación, operación y mantenimiento [en línea] disponible en: <https://www.stricklandtracks.co.uk>

3.1.2 Cadena estirada. El estiramiento de la cadena se da cuando se aumenta el alargamiento del paso del eslabón, causando los siguientes problemas:

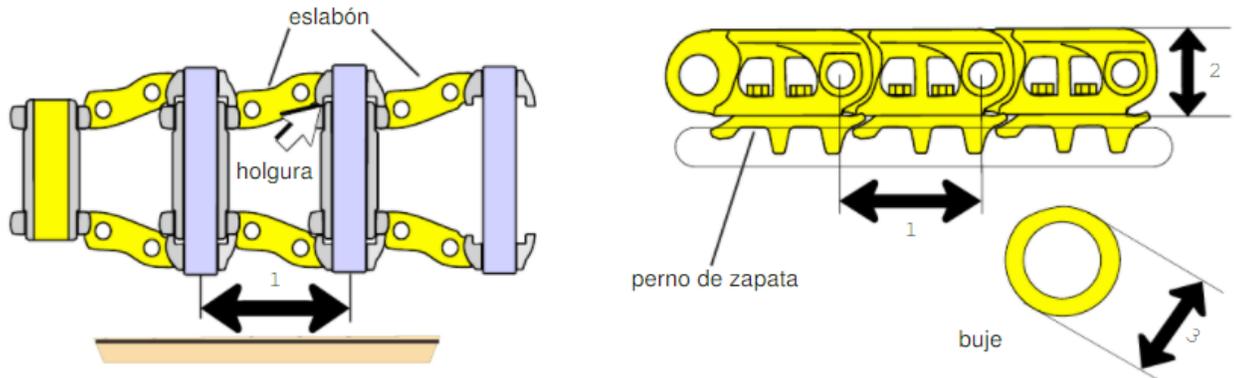
1. Se aflojan los eslabones de la oruga, desconectándose los eslabones de los rodillos inferiores y de la rueda dentada, y en los peores casos se puede llegar a romper el conjunto de eslabones
2. Desacople del eslabón con la rueda dentada, cuyos dientes tendrán una reducción importante y a su vez acelera el proceso de desgaste de la superficie del buje
3. El golpe del eslabón con los rodillos superiores reducirá su vida útil.

Figura 17. Cadena estirada



Fuente: Guía de conocimientos básicos, Eslabones y zapatas de las orugas Komatsu [en línea] disponible en: <https://fdocuments.ec/document/carrileria-komatsu.html>

Figura 18. Medición del desgaste eslabones y buje



Fuente: Guía de conocimientos básicos, Eslabones y zapatas de las orugas Komatsu [en línea] disponible en: <https://fddocuments.ec/document/carrileria-komatsu.html>

La reparación del tren de rodaje representa alrededor del 50% del costo una reparación total de un tractor de orugas por lo que evitar el estiramiento de la oruga ayudara a prolongar su vida útil y a generar grandes ahorros. Con las siguientes mediciones se puede reducir las costosas reparaciones:

1. Paso del eslabón: Se mide la relación de desgaste entre el diámetro interno del buje y el diámetro exterior del pasador.
2. Altura de la superficie de rodamiento del eslabón: Se mide el grado de desgaste en la superficie de rodamiento del eslabón.
3. Diámetro exterior del buje: Se mide el estado del desgaste

También es importante revisar la holgura entre los eslabones y revisar si presenta grietas y verificar si tiene pernos flojos

3.1.3 Cadena no tensionada. Es muy importante mantener la tensión correcta en la oruga. Si está muy tensionada, cada pasador y buje mantendrá un esfuerzo constante hasta en la posición superior de la oruga que no trabaja, lo que genera un rápido desgaste al dar vuelta los eslabones alrededor de las ruedas y generando un rozamiento adicional que adsorbe gran parte de la potencia del tractor. Las orugas sin tensión sufren desgaste por la flexión excesiva cuando entra y salen los tramos flojos en la parte superior, además la parte floja roza con las cajas de las transmisiones finales generando cortes y desgastando la oruga. Pero la mayor desventaja es la salida con facilidad de la cadena no tensionada en las vueltas y en terrenos irregulares o inclinados

Por otro lado, las orugas tienen un sistema de lubricación, el cual cuenta con un cilindro de grasa para mantener la tensión de la oruga, la grasa es bombeada desde un depósito hasta la grasera atornillada al extremo del cilindro. Cualquier falla en este sistema también provocara un mal tensionamiento de la oruga.

Por estas razones las principales causas del no tensionamiento de la oruga son:

- Desgaste excesivo de pasadores y bujes que no permita el restablecimiento de una tensión correcta
- Fugas en la cara externa de la grasera
- Fugas de grasa en la superficie de contacto entre el tensor de grasa y la grasera
- Daño del sello tensor

3.2. MODOS DE FALLAS DE BASTIDORES

Los bastidores son las vigas gruesas que van a cada lado del tractor y sirven de cuerpo o carcasa rígida para albergar elementos del tren de rodaje como ruedas guías (delantera y trasera), rodillos inferiores (ocho para las referencias D9T, D10T, D11T) y carros guías. Poseen de un cilindro telescópico interno para permitir el tensionamiento de las orugas mediante la rueda guía. Tienen internamente su sistema de lubricación y sirven de apoyo a otros elementos del tractor. Son fabricados mediante forja y formados por una parte frontal y una trasera.

Lo principales modos de falla son los siguientes:

3.2.1 Desgaste de rodillos y rueda guía. La rueda guía o rueda delantera se encuentra instalada en la parte delantera del bastidor y se emplea para guiar el conjunto de la oruga, mantener su tensión y absorber impactos frontales de operación. Las partes internas formadas por los bujes y eje están lubricadas con aceite. Se encuentra equipada con un mecanismo de ajuste de la tensión de la oruga y amortiguación del conjunto

La superficie de rodamiento y las pestañas son las partes más propensas al desgaste, además es importante que la rueda delantera este en posición central del bastidor ya que si no se encuentra correctamente alineado el desgaste de las pestañas será desigual.

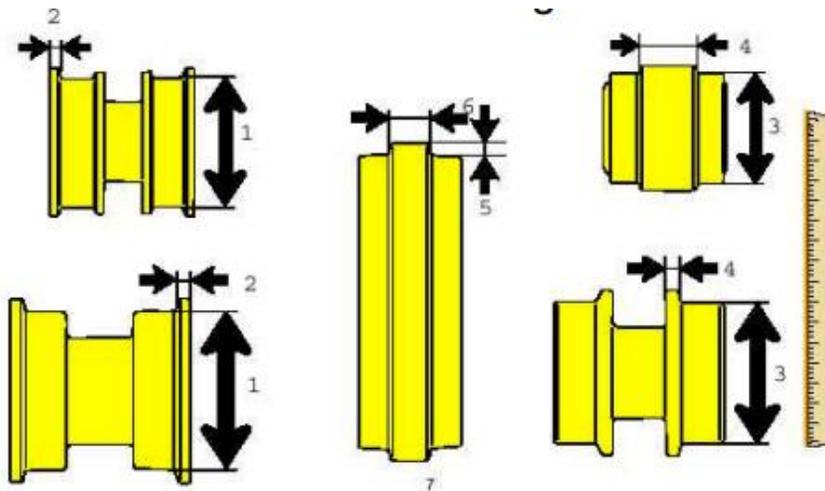
Para evitar el descarrilamiento de la oruga se debe medir la altura desde la superficie de rodamiento hasta la parte superior de la rueda delantera (Figura 19 medición 5) y para reducir el movimiento lateral de la oruga se mide la anchura saliente de la rueda delantera (Figura 19 medición 6)

El rodillo inferior soporta el peso de la maquina y lo distribuye uniformemente sobre las zapatas de la oruga. El buje y el eje del rodillo están lubricados por aceite, para minimizar la fricción entre ellos. Los rodillos pueden ser de pestaña doble o sencilla, se encargan de guiar al conjunto de eslabones de la oruga para evitar que se muevan y se salgan de posición.

Debido a la alta carga a la que son sometidos los rodillos inferiores, se produce abrasión en las superficies de los rodillos y en las pestañas de los rodillos debido al contacto constante con el conjunto de eslabones de la oruga.

Para determinar el desgaste ocurrido en la superficie de rodamiento, se mide el diámetro exterior en la superficie de rodamiento de los rodillos inferiores (Figura 19 medición 1) y para asegurar que las pestañas se encuentren dentro de los límites permitidos se realiza la medición del espesor de la pestaña del rodillo inferior.

Figura 19. Medición de ruedas guías y rodillos



Fuente: Curso de tren de rodaje de bulldozer [en línea] disponible en: <https://www.maquinariaspesadas.org/blog/2238-curso-tren-rodaje-bulldozers-funciones-partes-desgaste-tecnologia>

El rodillo superior es el encargado de soportar y guiar las orugas entre rueda dentada y rueda guía. Su estructura es menos complicada y soportan menos carga que los rodillos inferiores, pero se ven afectados por la acumulación de arena y tierra alrededor que provoca erosión. Además, si la maquina se trabaja en alta velocidad los eslabones pueden golpear fuertemente los rodillos superiores y tendrá como resultado la reducción de la vida útil de ambos componentes. Al igual que los rodillos inferiores, los bujes y eje del rodillo superior están lubricados con aceite.

Se realiza la medición del diámetro exterior de los rodillos superiores para determinar el desgaste ocurrido en la superficie de rodamiento (Figura 19 medición 3) y se mide el espesor de la pestaña del rodillo superior o ancho saliente para determinar el desgaste de la pestaña (Figura 19 medición 4).

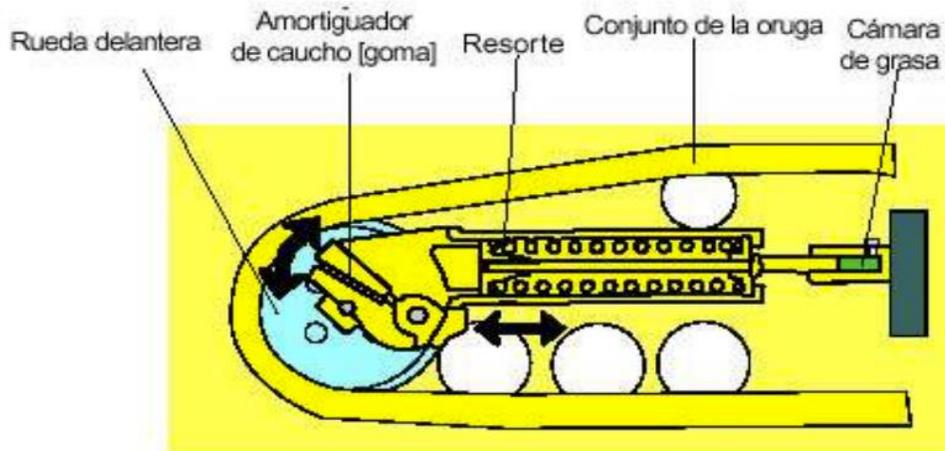
3.2.2 Daño interno. En este modo de falla se recolectan los daños de las partes internas del bastidor, cuya medición o monitoreo no es viable por su difícil acceso. Cuando un bastidor falla por un daño interno la única manera revisar y reparar se requiere el desarme completo del componente. Por ende, es una reparación que conlleva mucho tiempo, lo que se traduce en una mayor pérdida de puntos de disponibilidad.

Internamente el bastidor está conformado por un resorte que se encarga de tensionar la oruga, bujes con los que conecta al eje pivote, una cámara de grasa y un conjunto de sellos y portasellos. La lubricación es la mayor causa del daño interno, ya sea por falta o fuga de lubricante, generando desgaste en los bujes o roturas de sellos.

Por otra parte, debido a las agresivas condiciones de operación la unión del eje pivote con la parte interna del bastidor se puede ver afectada con rotura de sellos o tornillos partidos que permiten la entrada de tierra al sistema, causando

contaminación. Cuando esto ocurre se debe realizar inmediatamente una limpieza completa de todo el sistema para no afectar a otro componente.

Figura 20. Parte interna del bastidor



Fuente: Curso de tren de rodaje de bulldozer [en línea] disponible en: <https://www.maquinariaspesadas.org/blog/2238-curso-tren-rodaje-bulldozers-funciones-partes-desgaste-tecnologia>

3.2.3 Rodillo y rueda guía frenados. Los rodillos inferiores giran hacia delante cuando la rueda dentada impulsa la oruga, si estos no giran suavemente se deslizan sobre la oruga durante el movimiento de avance. Esto causa desgaste en la oruga y en los rodillos inferiores, que con el tiempo toman la forma de un polígono. Esto se debe principalmente a falta de lubricación y a la acumulación de material. Es por esto la importancia de la limpieza usual que ayudara a prolonga la vida útil.

4. PLAN DE GESTIÓN DE MANTENIMIENTO ACTUAL PARA MODOS DE FALLAS DEL TREN DE RODAJE

Actualmente en la empresa Carbones del Cerrejón existe un plan de cambio de bastidores y orugas basados en condición, sin embargo, su implementación no ha presentado el éxito esperado ya que aún se realizan una gran cantidad de cambios por imprevisto, como se observa en la siguiente gráfica, que indica la cantidad de eventos definidos como las llamadas de un equipo para reparación cambio o revisión, de acuerdo a su tipo que se presentaron en los últimos años, lo que conlleva a mayores costos en la reparación, pérdida en la disponibilidad y confiabilidad de los equipos.

Figura 21. Clasificación eventos de mantenimiento (2018-2020)



Para el caso de los bastidores, se realiza monitoreo del porcentaje desgaste de los 8 rodillos inferiores y de las ruedas guía delantera y trasera. En la oruga se mide el desgaste de los bujes, eslabón, paso o estiramiento y zapata (Anexo A). El porcentaje de desgaste se define de acuerdo con las tablas provistas por el fabricante del componente (Anexo B). Estas mediciones son realizadas cada 1000 horas de operación, que por lo general se ejecutan en dos meses. El sistema genera

alerta cuando alguna de estas mediciones se encuentra por encima del 90% de desgaste. Y la decisión del cambio, ya sea inmediato o programado, dependerá del análisis que realice el ingeniero de confiabilidad de todas las mediciones del componente. Finalmente es una decisión particular basada en el conocimiento y experiencia del analista, apoyado en los valores de desgaste que proporciona el fabricante.

Como plan de acción para definir, estudiar y evitar los diferentes modos de falla, la compañía implementó la creación del DAF (Detección analítica de fallas), en el cual se estudian las posibles causas de una falla antes de la vida media del componente y se toman acciones correspondientes. Sin embargo, es un análisis personal y dependerá del conocimiento que tenga el ejecutor del DAF sobre la falla.

Lo que se busca con la implementación de este algoritmo es poder planear y programar el cambio del componente antes de la falla por medio del análisis de los datos provenientes de las mediciones de desgaste. Para aquellas fallas asociadas a orugas y bastidores que no tienen parámetros de medición de seguimiento, se gestionan por medio de la captura de anomalías visitando a los equipos 250 horas de trabajo antes de su intervención en taller para poder repararlas en los PMs o mantenimiento programados de 1000 y 2000 horas.

5. DESARROLLO DEL MODELO SVM

5.1. TRATAMIENTO DE DATOS

Para la creación del modelo se recolectaron los datos de las últimas mediciones de desgaste los bastidores y orugas cambiados desde el 2018 hasta agosto del 2020, obteniendo 137 observaciones de orugas y 133 de bastidores, a las cuales se les definió el modo de falla de acuerdo con la información contenida de la OT (orden de trabajo) y sus respectivos comentarios de cierre, así como el porcentaje de desgaste que presento en dicha medición.

En cada observación se recolecto la siguiente información: el cálculo de las *horas de operación* que tuvo el componente en esa posición, su *vida media* (definida por el analista de confiabilidad), el porcentaje de *uso de vida media*; *el porcentaje de desgaste* de las partes medidas, zapata, eslabón paso y bujes para el caso de las orugas; y los rodillos (8 en cada bastidor) y ruedas guías traseras y delanteras del bastidor.

Del total de los datos recolectados fueron utilizados el 70% para el entrenamiento, el 15% utilizados para la validación numérica y el 15% restante para prueba de los datos con data nueva que no fue usada para el entrenamiento.

5.2. HERRAMIENTA UTILIZADA

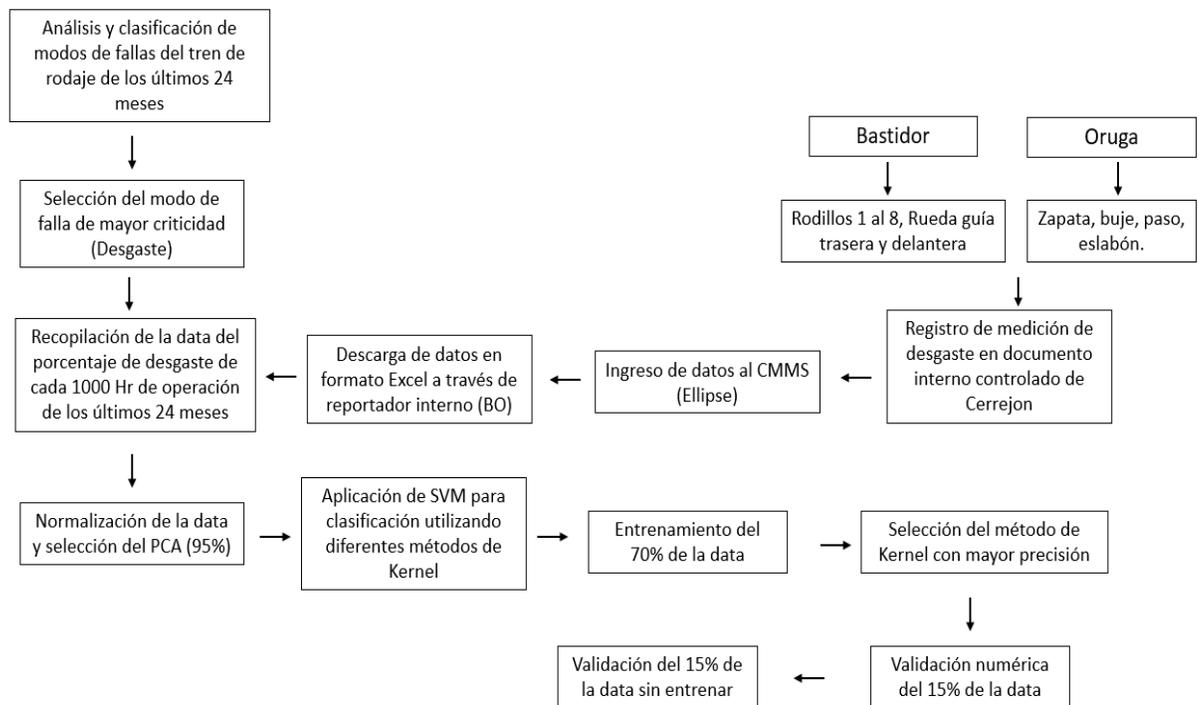
Para el desarrollo de este trabajo se utilizó el software MATLAB® versión estudiantil el cual brinda una interfaz de línea de comandos para entrenar un modelo de máquina de soporte vectorial que permite clasificar a los componentes bastidores y orugas en operación normal o desgaste, con la información recolectada de las mediciones de desgaste de sus diferentes partes y las horas de la operación del componente. Con la herramienta *Statistics and Machine Learning Toolbox* de

MATLAB se pueden crear 6 clasificadores SVM diferentes: Linear, Quadratic, Cubic, Fine Gaussian, Medium Gaussian y Coarse Gaussian.

5.3. DIAGRAMA DEL PROCESO

En la siguiente figura se observa el diagrama del proceso para la creación del clasificador de maquina de soporte vectorial con Kernels. El cual parte de la recopilacion de datos, seguido por el analisis de los datos, aplicación de SVM y validacion.

Figura 22 Diagrama del proceso para la creación del modelo SVM



6. RESULTADOS

6.1. ORUGAS

Para la selección del algoritmo se empezó por analizar el comportamiento de las variables analizadas de las orugas entre sí, desgaste de eslabón, desgaste de bujes y horas de operación en la figura 23 y desgaste de zapata, paso o estiramiento y horas de operación en la figura 24, las cuales se pueden definir como un comportamiento de clasificación no lineal, que lleva a la utilización de Kernels para la realización del modelo de clasificación.

Figura 23 Análisis de datos de falla y operación normal (eslabón, bujes y horas)

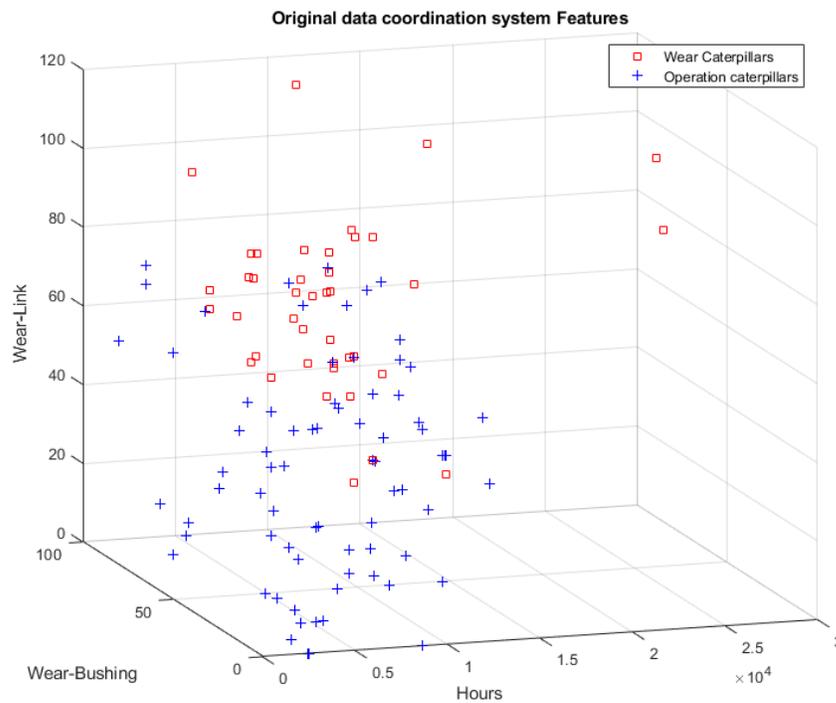
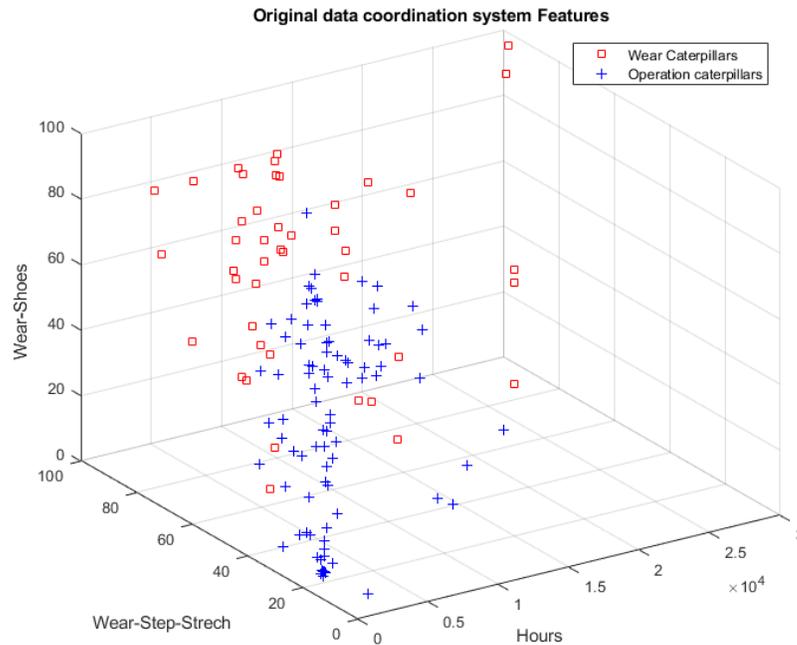


Figura 24 Análisis de datos de falla y operación normal (zapata, paso y horas)



A partir de la información recolectada se realizó el análisis estadístico y normalización de datos para observar la variabilidad de los datos, donde se observa que la distribución de los datos es asimétrica lo que indica pueden no estar distribuidos normalmente. En el caso del desgaste se ve una menor dispersión de datos con relación a operación normal, pero presenta una mayor cantidad de valores atípicos. Ese comportamiento era de esperar por la variabilidad en las condiciones de operación que pueden acelerar o no el desgaste. Por otra parte, también es visible la alta variabilidad de los datos en las dos clases definidas, en desgaste y operación normal.

Figura 25 Distribución de desgastes de las orugas, normalizado y características

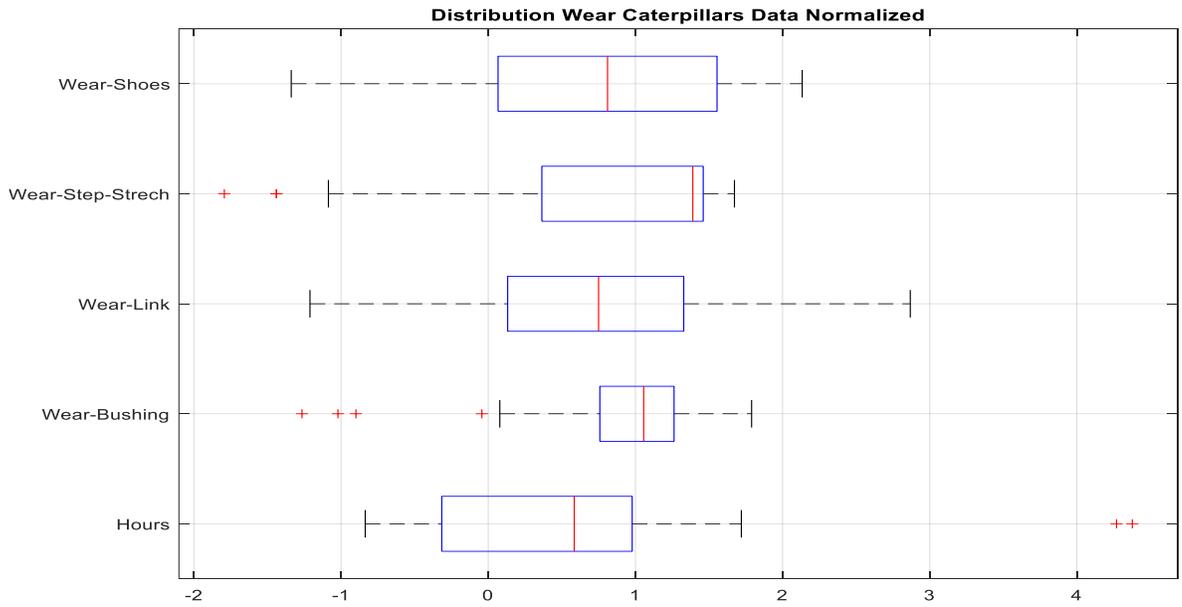
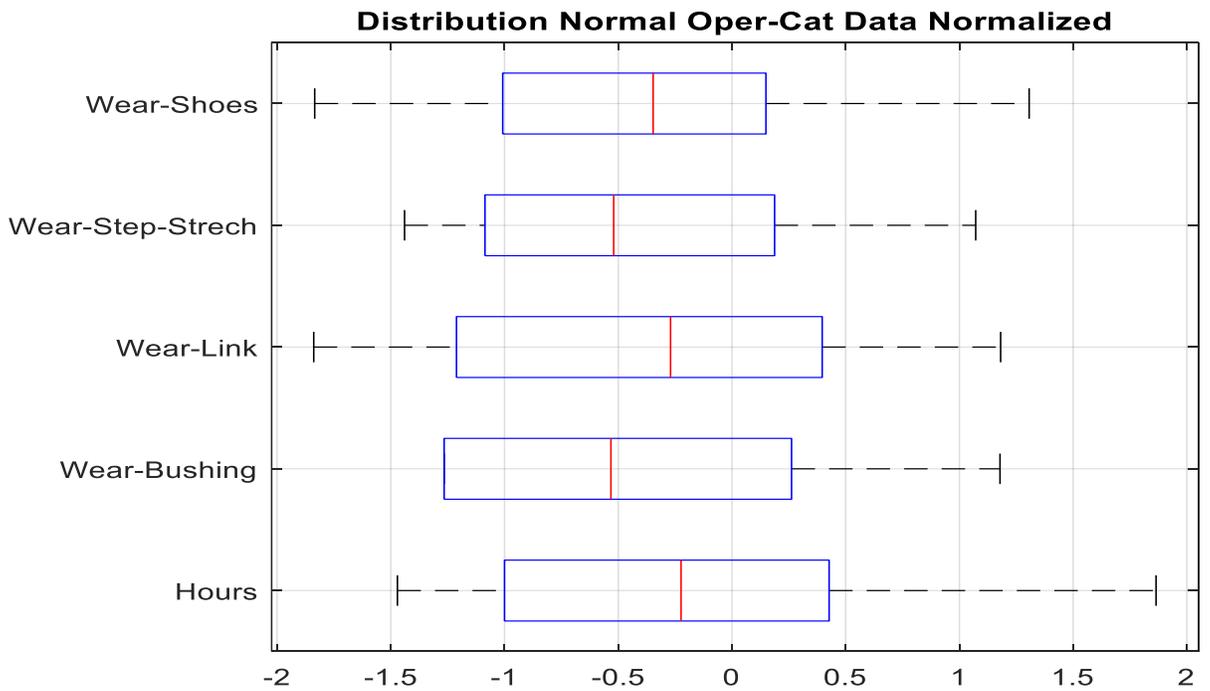


Figura 26 Distribución de operación normal de las orugas, normalizado y características



Para el cada componente fueron definidas dos clases para clasificación, en las orugas la primera clase representada con el numero "1" simboliza el desgaste y la segunda clase con el numero "2" indica operación normal. Luego, aplicando máquina de soporte vectorial en los diferentes tipos de Kernel que ofrece MATLAB®, se encontró la mayor precisión en el algoritmo Fine Gaussian con un valor de 97.8%, seguido por el algoritmo de Cubico con una precisión del 95.6%. Los resultados de todos los modelos se pueden observar en la siguiente tabla.

Tabla 1 Resultados del SVM para diferentes algoritmos

Tipo de Machine learning Kernel	Precisión con PCA al 95%
Linear SVM	82.4%
Quadratic SVM	95.1%
Cubic SVM	95.6%
Fine Gaussian SVM	97.8%
Medium Gaussian SVM	94.0%
Coarse Gaussian SVM	84.6%

Se puede analizar como interactúa el clasificador SVM con el conjunto de datos utilizando la matriz de confusión, la rata de verdaderos positivos para la clase 1 fue del 97.9% y la clase 2 del 93.2%. Lo que indica que fueron clasificados correctamente el 98% de todos los puntos correspondientes a la clase 1 y el 93.2% de todos los puntos correspondientes a la clase 2. lo que confirma la efectividad de la clasificación y el reconocimiento del problema.

Existe otros indicadores que pueden evaluar la clasificación desde otro punto de vista y es el valor predictivo positivo y el valor predictivo negativo. Mientras la rata de verdaderos positivos calcula cuantos puntos computados a partir de estímulos

visuales provenientes de un cuadrante x que hacen parte de ese cuadrante fueron clasificados correctamente de todos los puntos que pertenecían al cuadrante x , el valor predictivo positivo mide cuantos puntos en un cuadrante x fueron clasificado correctamente de entre todos los puntos que el clasificador considero como puntos correspondientes del cuadrante x .

El valor predictivo positivo alcanzo porcentajes de 97.6% para la condición normal y 93.9% para un componente en modo de falla de desgaste. Esto muestra que un alto porcentaje fue clasificado correctamente de entre todos los puntos que el clasificador considero como puntos correspondientes de su respectivo cuadrante.

Figura 27 Resultado SVM usando *Fine Gaussian Kernel* para orugas

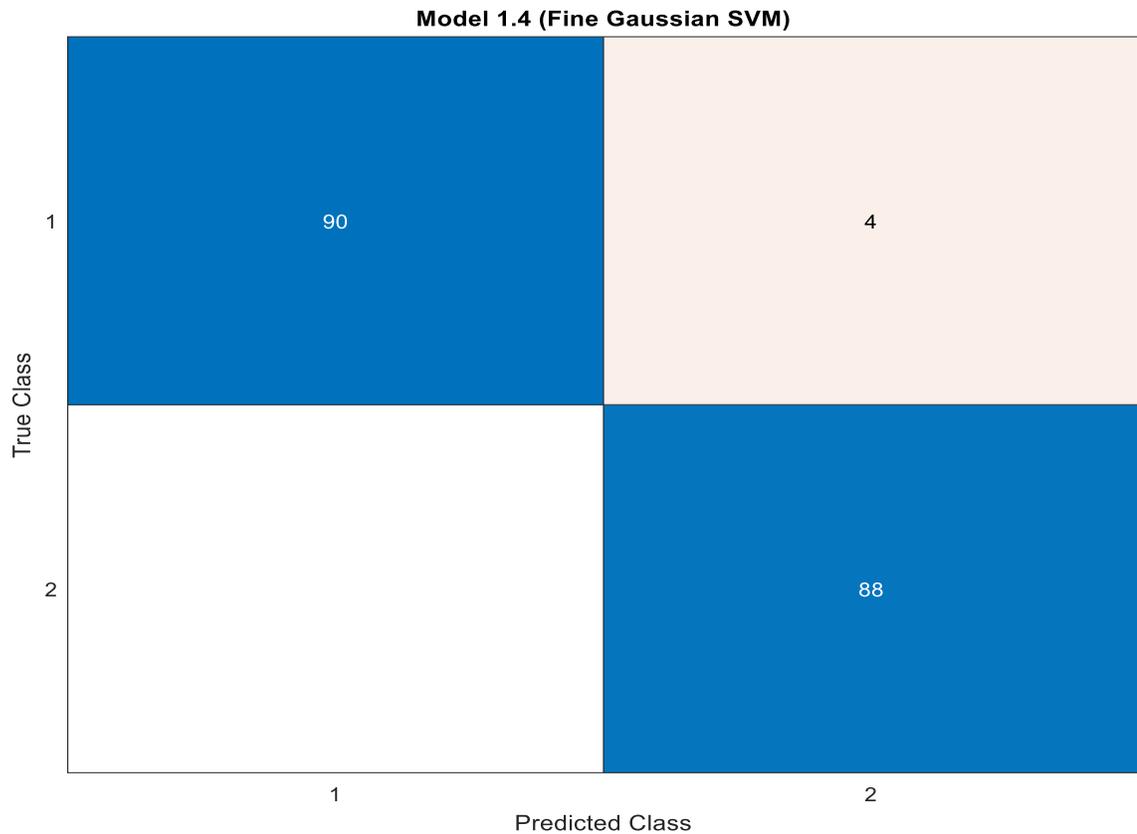


Figura 28 Resultado SVM usando *Cubic Kernel* para orugas

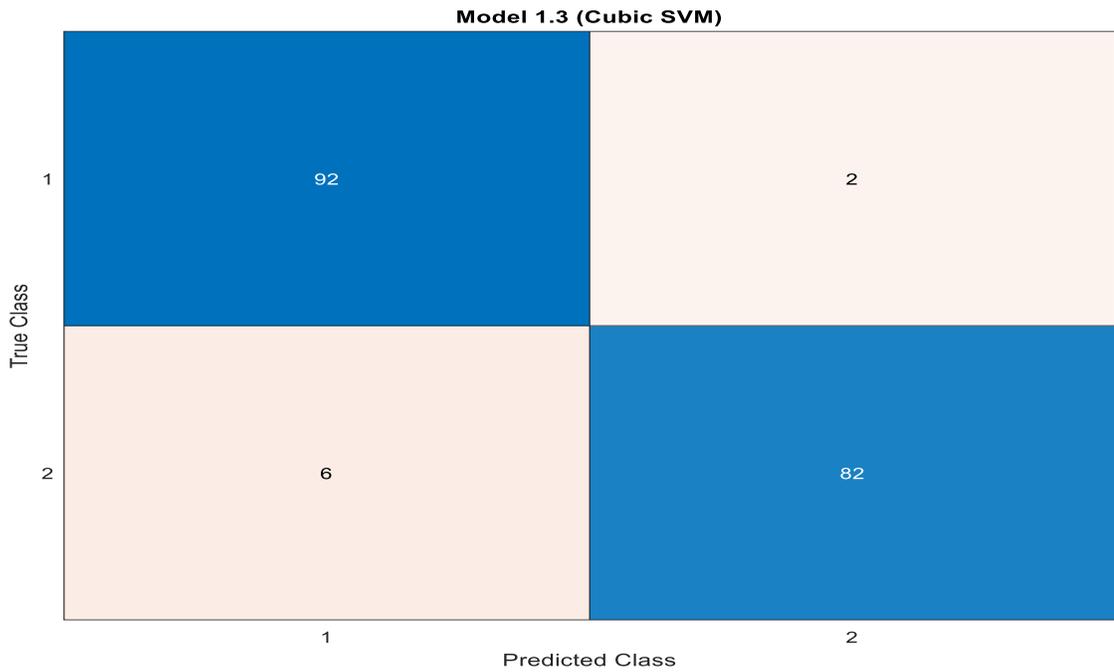


Figura 29 Porcentaje de valores positivos y valores falsos negativos en orugas

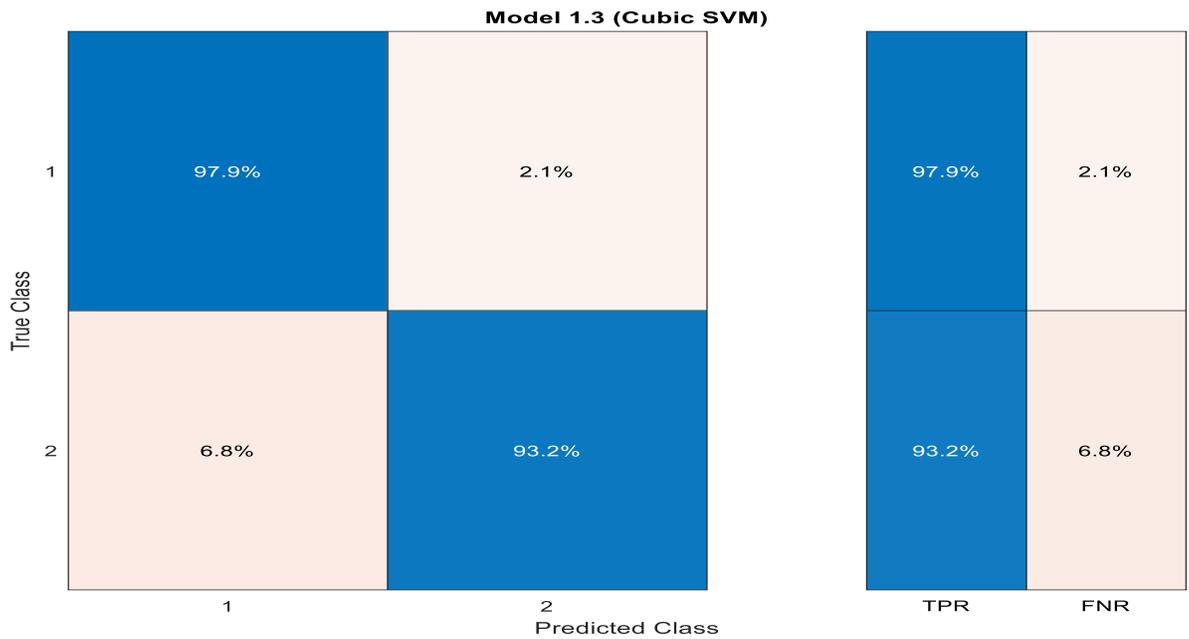
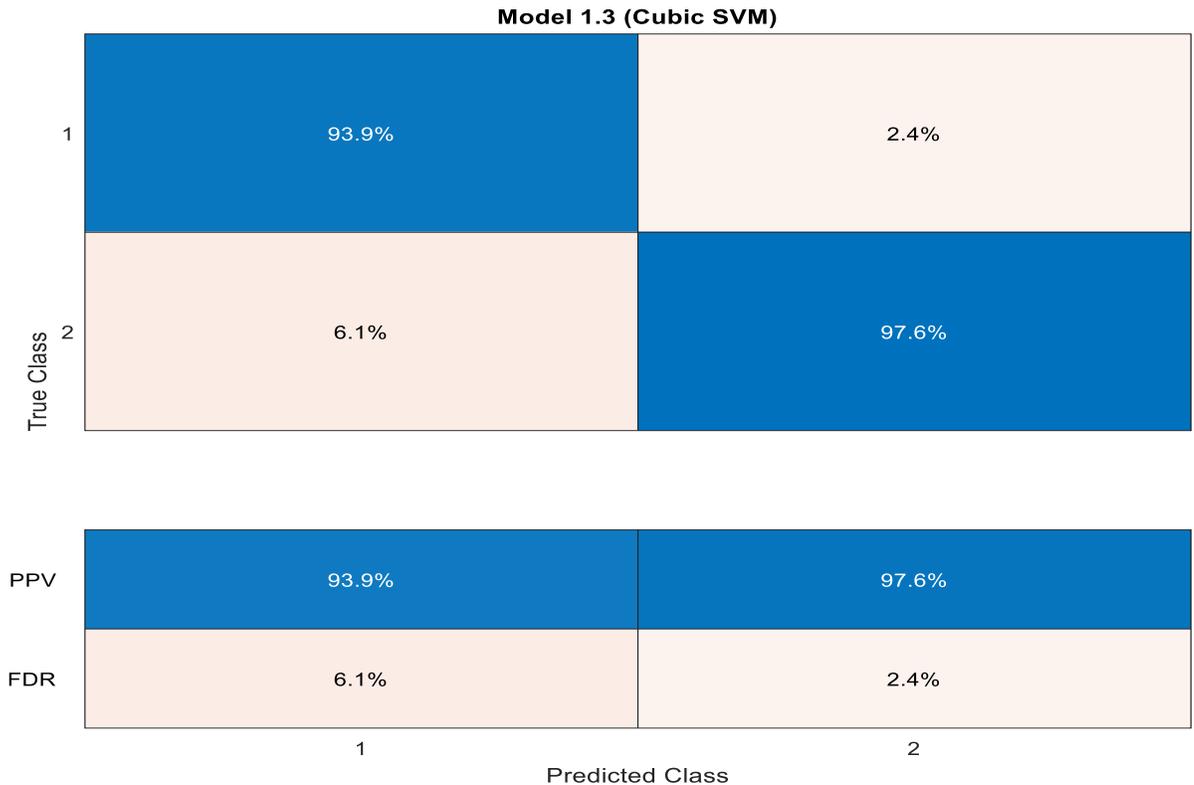


Figura 30 Valores positivos predictivo y rata de falsos descubiertos en orugas



6.2. BASTIDORES

En el caso de los bastidores, que contaba con 11 variables, rodillos del 1 a las 8 ruedas guías, rasera y delantera y horas de operación, al analizar las horas de operación con relación a los rodillos y ruedas guías, se aprecia con claridad que las curvas de separación no son lineales y que los datos no son completamente separables (ver Fig. 31 y Fig. 32). Situación que se repite al analizar los ocho rodillos entre sí (Fig. 33). Por el análisis de las gráficas y de acuerdo con la no linealidad de separación entre sus variables se opta por aplicar clasificación por máquina de soporte vectorial utilizando la función Kernel y se prueba con los 6 tipos de clasificadores que ofrece MATLAB.

Figura 31 Análisis de datos de falla y operación normal (Rodillo 1, rodillo 2 y horas)

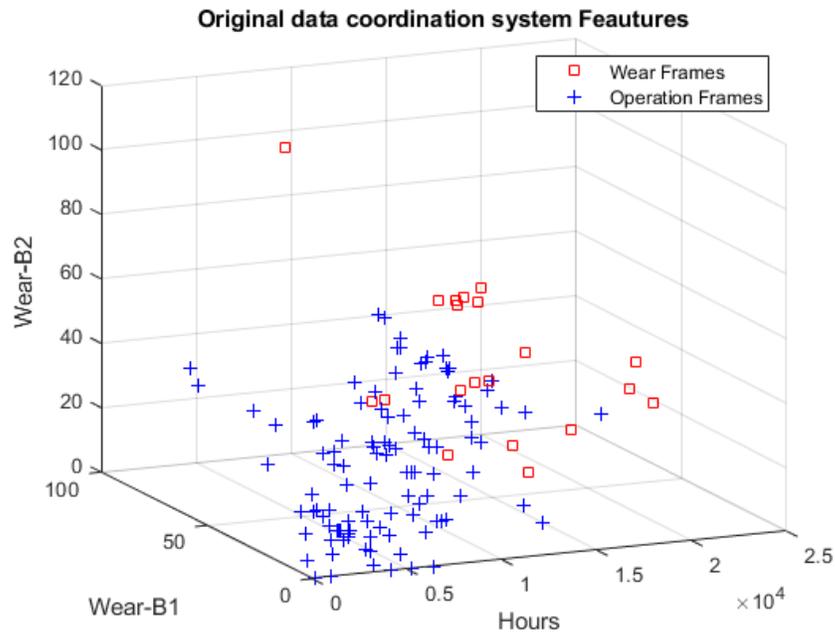


Figura 32 Análisis de datos de falla y operación normal (Rueda guía trasera, rueda guía delantera y horas)

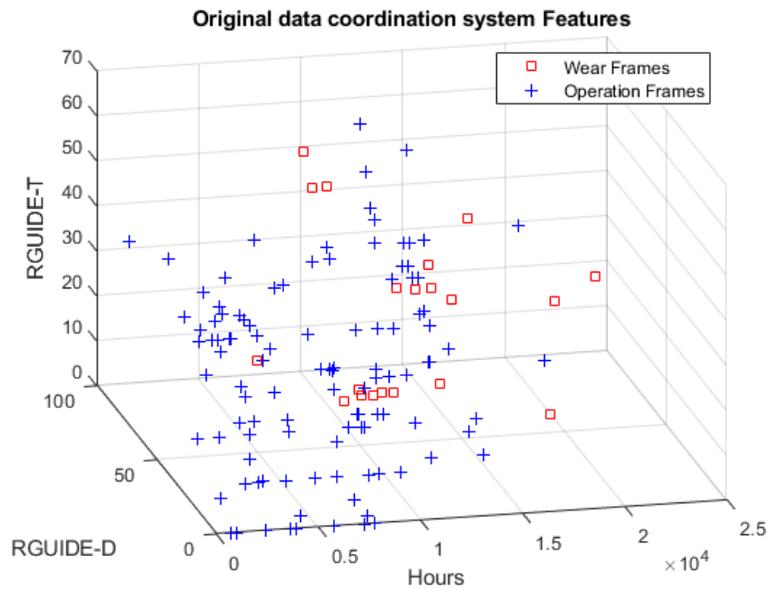
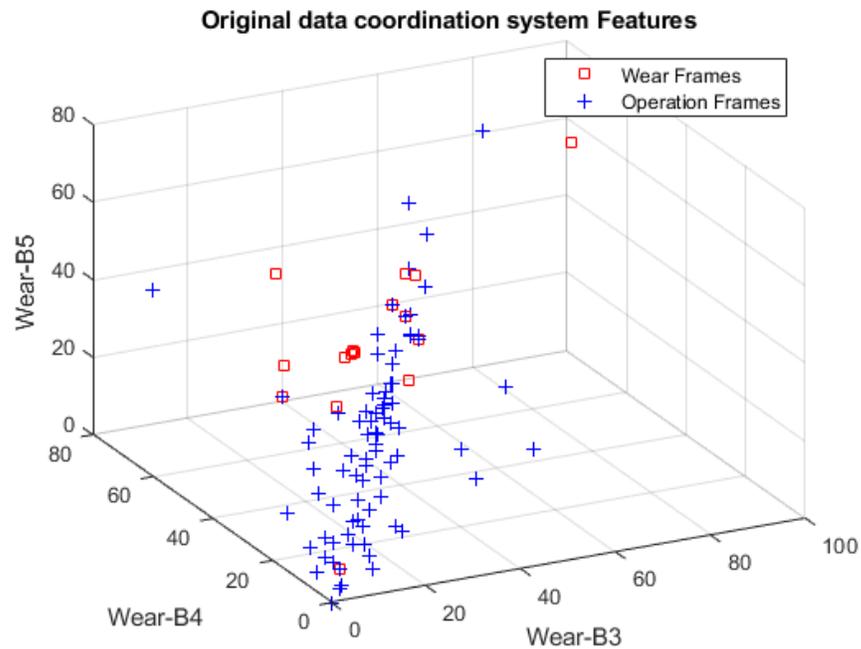


Figura 33 Análisis de datos de falla y operación normal (Rodillo 4, rodillo 5 y rodillo 3)



Para una mayor claridad sobre el comportamiento de los datos se realiza el análisis estadístico mediante un diagrama de caja, donde se visualiza una alta variabilidad en los datos sobre todo en falla, al igual que un alto número de datos atípicos. (Figura 34 y 35)

Luego se procede a definir dos clases, en este caso condición del componente, representado con el numero 3 el modo de falla por desgaste y con el numero 4 la operación normal del componente, y es simulada la SVM usando las 6 funciones Kernel: Lineal, cuadrática, cubica y las 3 Gaussianas, cuyos resultados se pueden observar en la tabla 2.

Figura 34 Distribución de operación normal del bastidor, normalizado y características

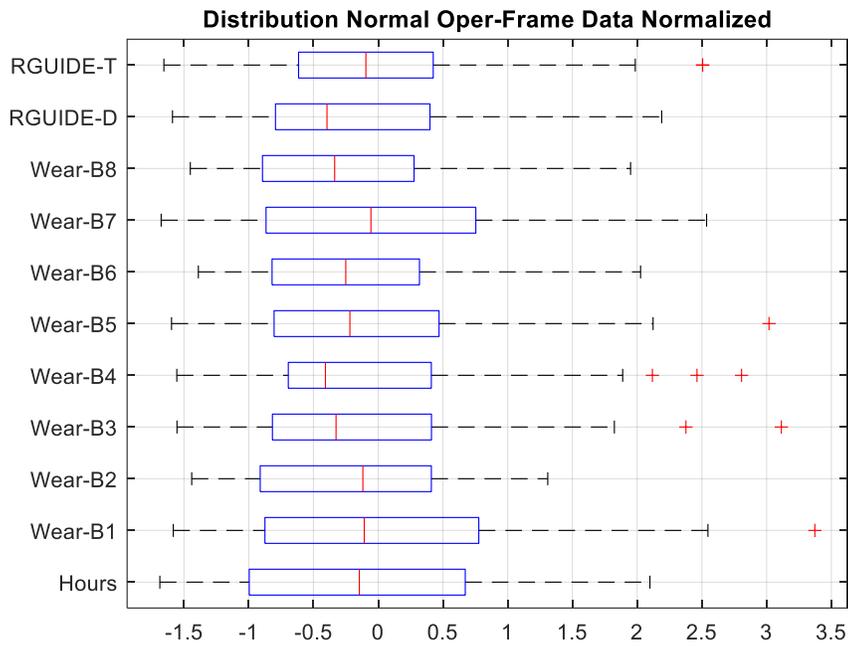
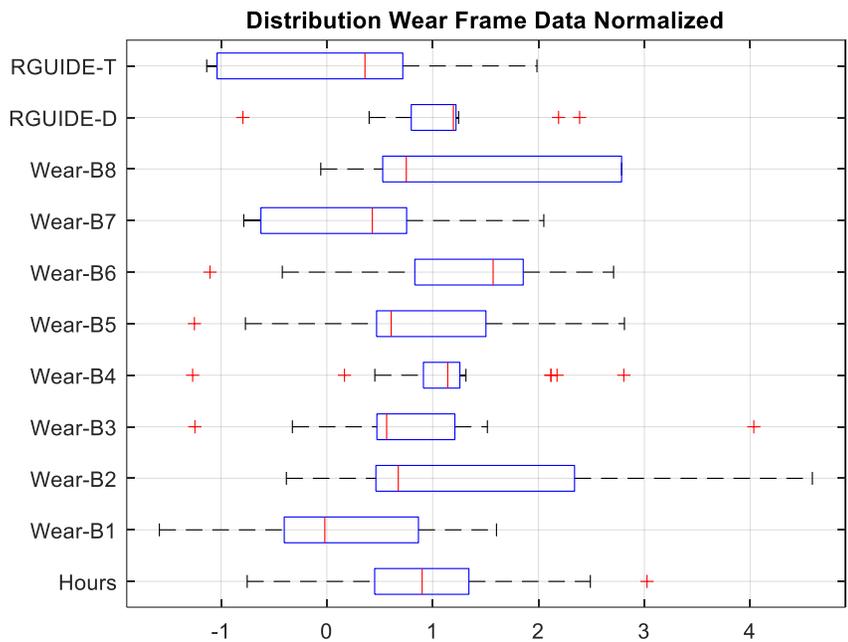


Figura 35 Distribución de desgastes del bastidor, normalizado y características



Con una precisión del 100% el algoritmo SVM gaussiano de granularidad fina o Fine Gaussian SVM clasifica de forma correcta obteniendo así solo valores verdaderos positivos. También se obtienen altas precisiones con algoritmo cuadrático y cubico con valores de 97.7% y 98.1% respectivamente.

Tabla 2 Resultados del SVM para diferentes algoritmos

Tipo de Machine learning Kernel	Precisión con PCA al 95%
Linear SVM	87.0%
Quadratic SVM	97.7%
Cubic SVM	98.1%
Fine Gaussian SVM	100%
Medium Gaussian SVM	96.6%
Coarse Gaussian SVM	86.1%

Figura 36 Resultado SVM usando Fine Gaussian para bastidores

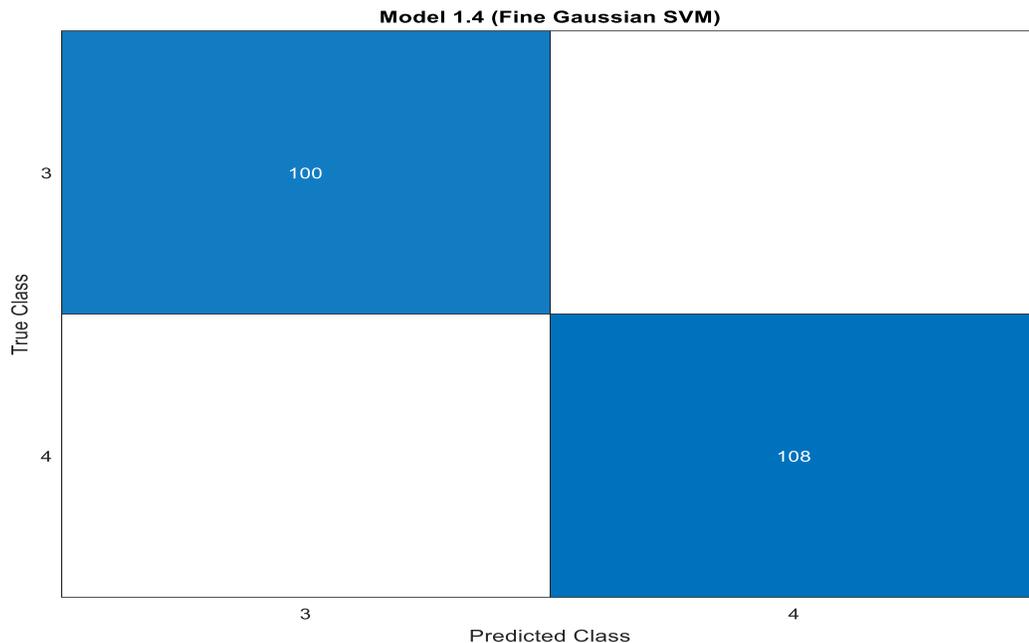


Figura 37 Rata de verdaderos positivos y valores falsos negativos para bastidores

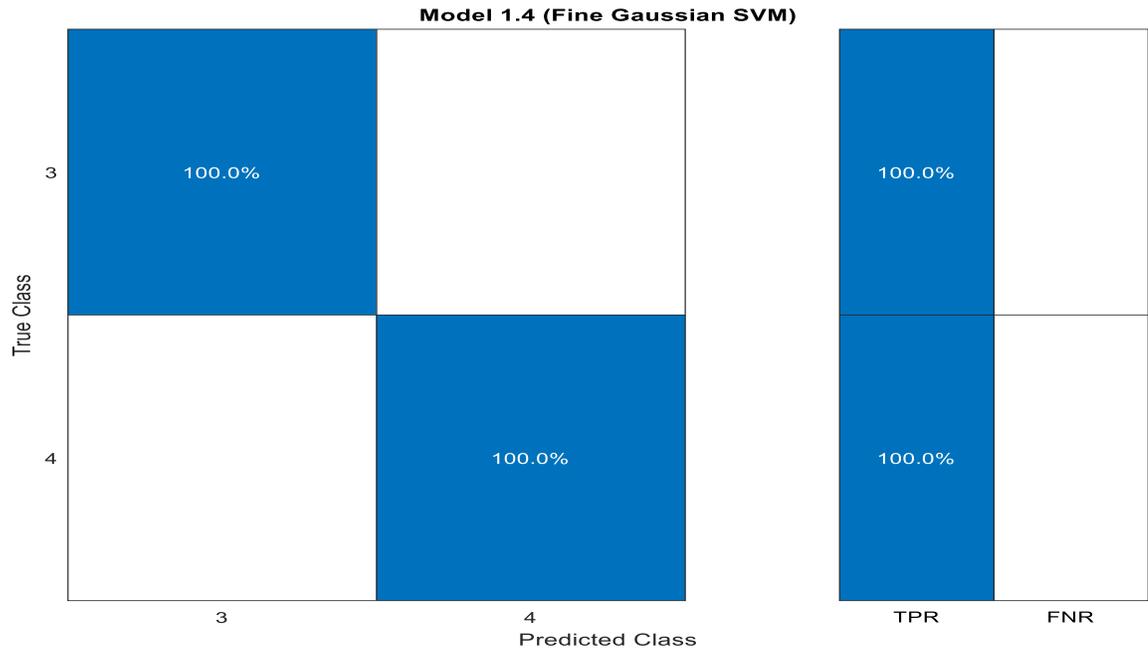


Figura 38 Rata de verdaderos positivos predictivo y falsos descubiertos

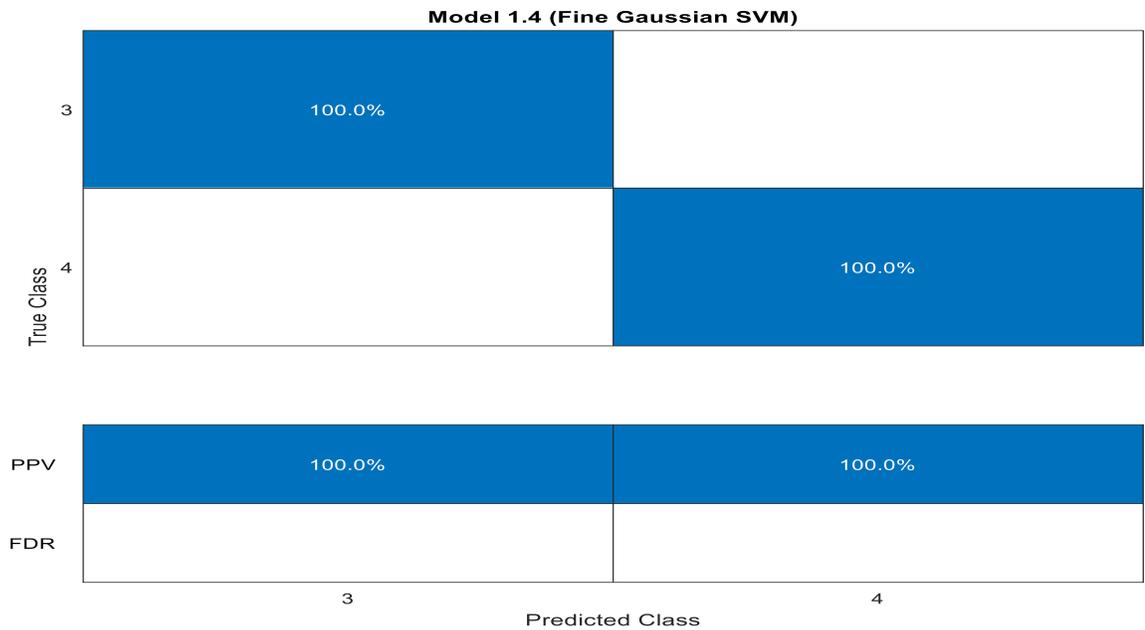
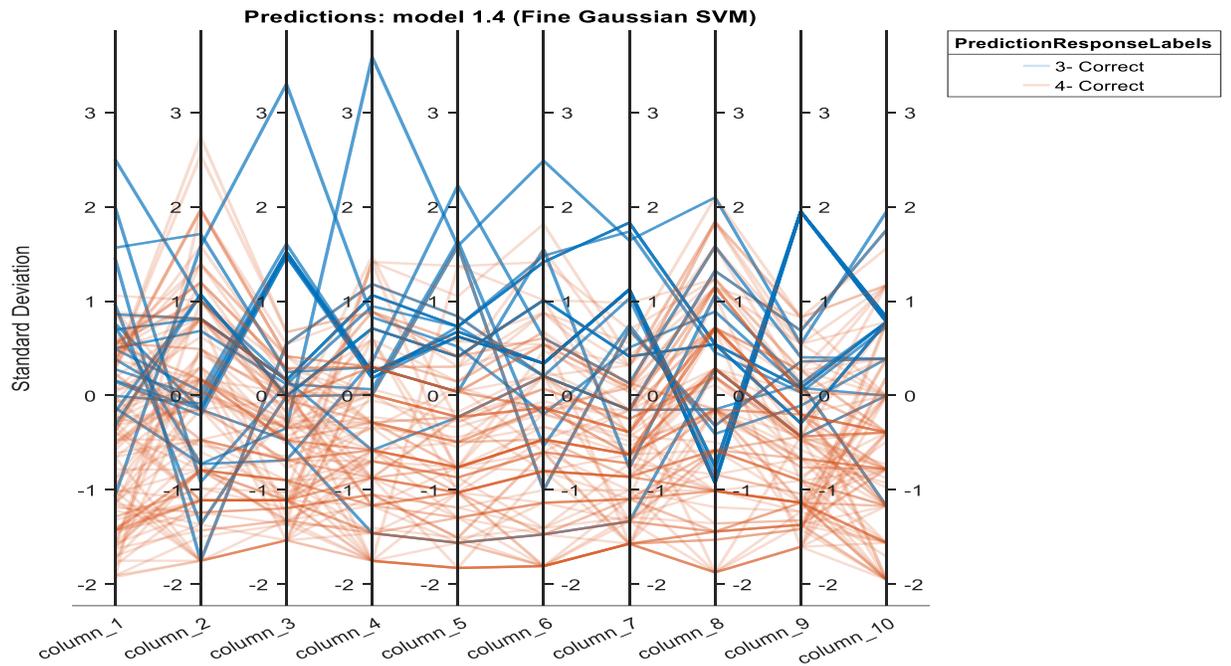


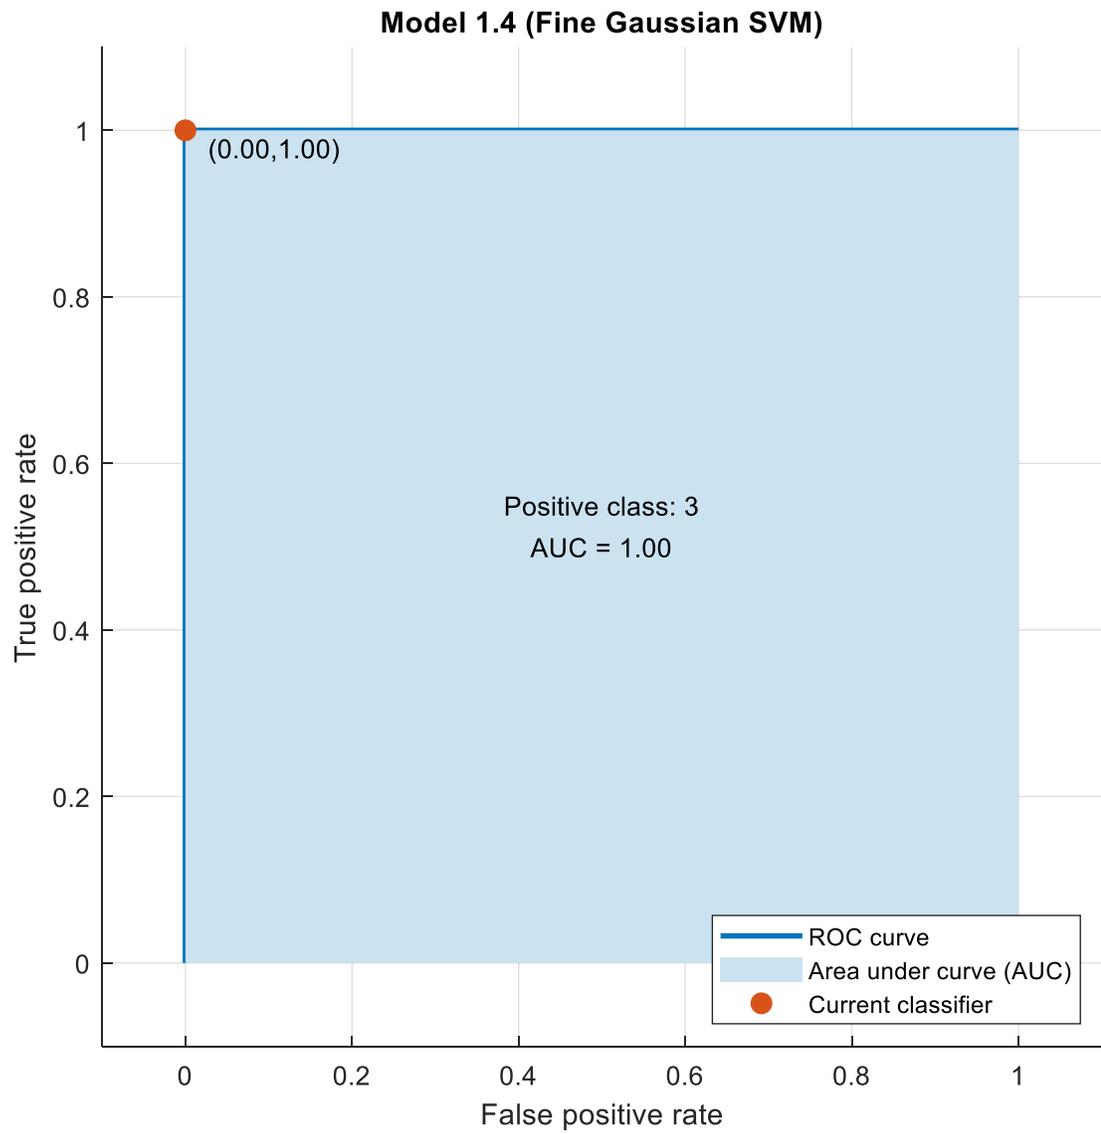
Figura 39 Desviación estándar de Fine Gaussian Kernel para bastidores



La curva ROC, representa gráficamente la relación de la tasa de verdaderos positivos y verdaderos negativos para un sistema clasificador binario. Uno de los análisis que se realizan de la curva ROC es el área bajo la curva (AUC)²² y cuanto mayor sea, mejor sería el clasificador, interpretado como la posibilidad de obtener una mayor tasa de verdaderos positivos que de verdaderos negativos. En este caso la curva ROC del modelo Fine Gaussian se observa en la Figura 40, la cual obtuvo un AUC de 1, que indica la probabilidad que, al escoger aleatoriamente dos puntos, siendo uno de cada clase, se clasificara siempre de manera correcta o el 100% de las veces.

²² HEREDIA, Pablo. Aplicación de SVM para la decodificación neural de los estímulos recibidos por primates. Universidad Politécnica de Madrid. Madrid 2017 p 47

Figura 40 Curva ROC para SVM *Fine Gaussian Kernel*

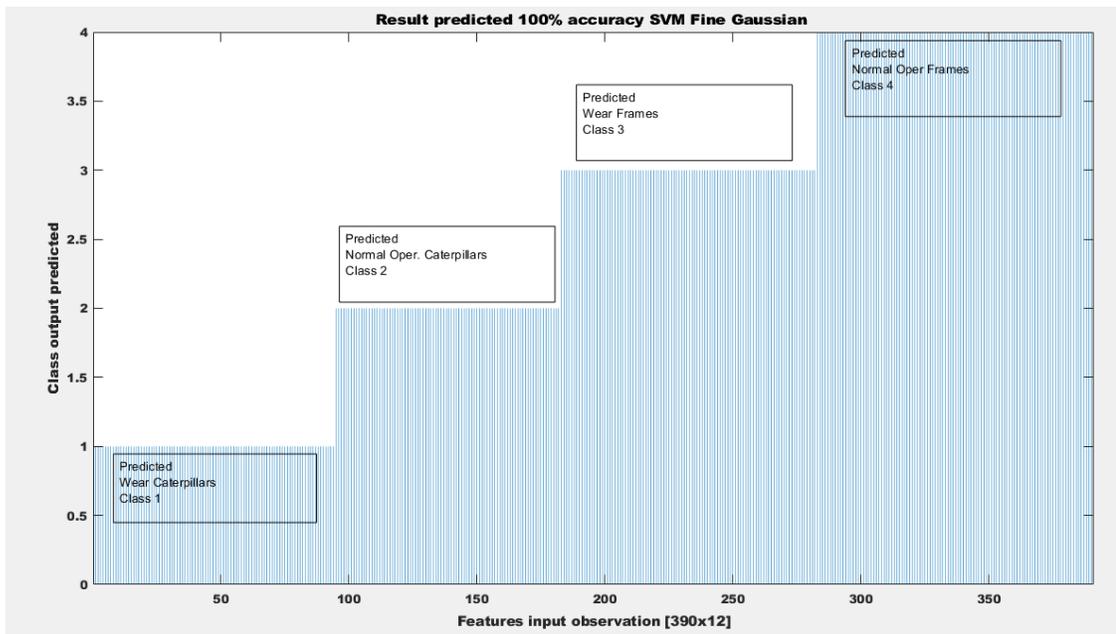


6.3. ANALISIS DE RESULTADOS

La aplicación de máquina de soporte vectorial utilizando la función Kernel Fine Gaussian para la clasificación del problema propuesto arrojo excelentes resultados con precisiones del 98% y 100% para orugas y bastidores respectivamente. Así como valores superiores al 93% y hasta 98% en la rata de verdaderos positivos y rata de verdaderos positivos predictivos.

La siguiente figura representa la respuesta de la máquina de soporte vectorial frente a las entradas, donde se observa una correcta clasificación de los grupos, clase 1 y 2 para orugas y clase 3 y 4 para bastidores, tanto en la fase de entrenamiento de datos como en el 15% de los datos que nunca se usaron para entrenar y no fueron presentados al modelo de SVM. Esto se traduce en una alta probabilidad de predicción de entrada del modelo clasificador para ambos componentes

Figura 41 Respuesta del SVM a las entradas



7. CONCLUSIONES

De acuerdo con el análisis de los diferentes modos de falla en bastidores y orugas de los tractores de la empresa Cerrejón, se determina el desgaste como la principal causa de falla porque representa el 70% de los casos analizados. Debido a la frecuencia con que se presenta el desgaste y la repercusión que tiene en la funcionalidad, confiabilidad y mantenibilidad, se define como el modo de falla de mayor criticidad operacional. Por esta razón para el desarrollo del modelo se seleccionó el desgaste como único modo de falla, además por ser el único con data registrada para analizar, como lo son las mediciones del porcentaje de desgaste de distintas partes de estos componentes, sin embargo, su registro no fue constante en el tiempo lo que llevo a realizar un modelo de clasificación y no un modelo de predicción al futuro como se buscaba en un principio.

Al analizar los datos de ambos componentes se observó un comportamiento no separable linealmente lo que llevo a la selección de un modelo de clasificación de máquina de soporte vectorial utilizando Kernels de tipo no lineal, de tipo cúbico. Se realizó la clasificación de 2 tipos para cada componente, desgaste y condición normal, utilizando las diferentes clases de algoritmos de Kernel y se obtuvo como resultados una precisión del 98% para las orugas y del 100% para los bastidores con el algoritmo *Cubic kernel* al igual que se usó el *Fine Gaussian* de SVM, es decir un comportamiento de clasificación excelente y reconocimiento del problema.

En este trabajo se resalta la importancia del análisis de datos para la toma de decisiones y gestión en mantenimiento, en este caso por los buenos resultados en clasificación predictiva, y se abre la oportunidad de aplicar técnicas avanzadas de mantenimiento a diferentes componentes de la flota. Sin embargo, es importante destacar la relevancia que tienen un registro de la data, correcto y constante en el

tiempo, para que además de desarrollar clasificadores se puedan formular modelos predictores en el futuro.

BIBLIOGRAFÍA

ANGULO, Cecilio. Aprendizaje con máquinas núcleo en entornos de multclasificación. Tesis. Dpto. Ciencia del ordenados. 2001.

BENÍTEZ IGLÉSIAS, Raúl Inteligencia artificial avanzada. España: Editorial UOC 2013

BORRÁS PINILLA, Carlos y STALFORD, Harold L. Pattern recognition in hydraulic backlash using neural network. En: Proceedings of the American Control Conference (1: 8-10, mayo: Anchorage, USA). Memorias. Anchorage: IEEE, 2002. p. 400-405

BORRÁS PINILLA, Carlos. Técnicas avanzadas de mantenimiento. Bucaramanga. Grupo de investigación ingeniería mecánica DICBoT, Universidad Industrial de Santander.

et al, BORRÁS PINILLA, Carlos., A methodology for detection of wear in hydraulic axial piston pumps. International Journal on Interactive Design and Manufacturing (IJIDeM) (2020)., Springe., Vol 14., pag 1103-1119., 08 2020.

BURGES, Christopher A tutorial on support vector machines for pattern recognition. Bell Laboratories, Lucent Technologies, USA. Data Mining and Knowledge Discovery, 2, 121–167. 1998.

BURKOV, Andriy The Hundred-Page Machine Learning Andriy Burkov 2019

CATERPILLAR, Products Large dozers [en línea] disponible en: https://www.cat.com/es_US/products/new/equipment/dozers/large-dozers.html

CERREJÓN Página principal [en línea] disponible en: <https://www.cerrejon.com/>

GONZÁLEZ, Samuel Abad. Detección de Anomalías Cardíacas con Aprendizaje Automático (Machine Learning) [en línea] disponible en: <http://samuelabad1991.blogspot.com/2014/02/analisis-con-maquinas-de-vectores.html>

HASTIE, T., TIBSHIRANI, R., & FRIEDMAN, J. The elements of statistical learning: data mining, inference, and prediction, Springer Series in Statistics. 2009

HEREDIA, Pablo. Aplicación de SVM para la decodificación neural de los estímulos recibidos por primates. Universidad Politécnica de Madrid. Madrid 2017 p 47

HUDDLESTON, S. Machine Learning. Informs Analytics Body of Knowledge, 2018

HSUEH, YW. & YANG, CY Prediction of tool breakage in face milling using support vector machine The International Journal of Advanced Manufacturing Technology Vol 37 Num. 9-10 2008 Pag. 37

IBERDROLA Machine learning aprendizaje automático [en línea] disponible en: <https://www.iberdrola.com/innovacion/machine-learning-aprendizaje-automatico>

JONES, Herbert Aprendizaje Automático: El Aprendizaje Automático para principiantes que desean comprender aplicaciones, Inteligencia Artificial, Minería de Datos, Big Data y más Independently published 2019

J. MARADEY L., C. BORRÁ P., Detection and Classification of Wear Fault in Axial Piston Pumps: Using ANNs and Pressure Signals., Pattern Recognition

Applications in Engineering., IGI Global., pag 286-316., 2020

MORALES, Eduardo Maquinas de Soporte Vectorial [en línea] disponible en: <https://ccc.inaoep.mx/~emorales/Cursos/NvoAprend/Acetatos/svm2017.pdf#page41>

ORELLANA PIMENTEL, Marco Tulio Programa de mantenimiento preventivo para tractores sobre orugas Caterpillar, en sigma constructores, S.A. Guatemala 2009

PORTAFOLIO Caída en precio del carbón ya afecta la operación en el país [en línea] disponible en: <https://www.portafolio.co/economia/caida-en-precio-del-carbon-ya-afecta-la-operacion-en-el-pais-530425>

RICARDO, H. S., CATALANI, G. Manual práctico de escavação - Terraplenagem e escavação de rocha Pini, São Paulo 1990

SALAMANCA, Luis Generacion de conjuntos de maquina de soporte vectorial mediante tecnicas de remuestreo e inyeccion de ruido en las etiquetas. Universidad Autonoma de Madrid 2017

SCHOLKOPF, Bernhard Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond Germany The MIT Press 2001

TAN, Ying A support vector machine with a hybrid kernel and minimal Vapnik-Chervonenkis dimension IEEE Transactions on Knowledge and Data Engineering,2004

TOMAS, David (UPV). Una aproximación multilingüe a la clasificación de preguntas basada en aprendizaje automático. 2005.

VALLE, Fernando Implementación eficiente de clasificadores Prior-SVM para MATLAB, Tesis Universidad Carlos II de Madrid, 2010

VAN VAERENBERGH, S Metodos Kernel para clasificacion [en línea] disponible en: https://gtas.unican.es/files/docencia/APS/apuntes/07_svm_kernel.pdf

VAPNIK, Vladimir. Pattern recognition using generalized portraid method. Automation and remote control, 24. 1963.

ANEXOS

Anexo A Formato de registro de medición de rodaje de tractores de orugas



FORMATO DE REGISTRO DE MEDICION DE RODAJE
TRACTORES DE ORUGAS

Código: FO-MAT-MEDROD
Versión 1. Fecha: 2020 / 02 / 05

Nombre Inspector:		Equipo:			Fecha:		
Número de oruga RH:		Número de oruga LH:					
Número de baatidor RH:		Número de baatidor LH:					
COMPONENTE	LADO DERECHO			LADO IZQUIERDO			
	mm	%	Observaciones	mm	%	Observaciones	
BAST	Rodillo # 1						
	Rodillo # 2						
	Rodillo # 3						
	Rodillo # 4						
	Rodillo # 5						
	Rodillo # 6						
	Rodillo # 7						
	Rodillo # 8						
	Rueda guía del						
	Rueda guía tras						
	Tensor: Máx. Extensión D11T: 7", D10T: 6.5", D8T: 6.5"		N / A			N / A	
ORUG	Bujes						
	Eslabones						
	Paso (Elongación)						
	Zapata						
	Comba D11T: 7", D10T: 6", D8T: 5", D6T: 4"		N / A			N / A	
SPRK	Desgaste Sprocket						
Ítem a inspeccionar		OK	Reparar	Observaciones	OK	Reparar	Observaciones
Estado de los pad							
Estado del link master							
Estado de tornillos link master							
Estado tornillos de Zapata							
Estado tornillos de los segmentos sprocket							
Estado sello pistón tensor							
Estado de bogies							

NOTA IMPORTANTE: DOCUMENTE TODOS LOS INCIDENTES QUE SE IDENTIFIQUEN EN LA INSPECCION, ENTREGUE ESTE FORMATO DILIGENCIADO AL SUPERVISOR.

ITEM	COMENTARIO DEL TECNICO QUE INSPECCIONA	COMENTARIO DE QUIEN REPARA

Nombre de quien registra mediciones en Elipse		Fecha de registro de mediciones en Elipse:	
-----------------------------------------------	--	--------------------------------------------	--

Anexo B Tabla guía de medición del desgaste de los eslabones de las orugas

D11N, D11R, D11T - 12.50 in. (317.5 mm)

Track Links ⁽¹⁾
200-6325 & 26
Optional Tall Link



Depth Gauge			Ultrasonic	
Inches	(mm)	% Worn	Inches	(mm)
8.07	(205.0)	0	2.51	(63.8)
8.03	(204.0)	5	2.47	(62.7)
7.99	(203.0)	10	2.43	(61.7)
7.95	(202.0)	15	2.39	(60.7)
7.91	(201.0)	20	2.35	(59.7)
7.87	(200.0)	25	2.31	(58.7)
7.83	(199.0)	30	2.27	(57.7)
7.79	(198.0)	35	2.23	(56.6)
7.75	(197.0)	40	2.19	(55.6)
7.71	(196.0)	45	2.15	(54.6)
7.67	(195.0)	50	2.11	(53.6)
7.63	(194.0)	55	2.07	(52.6)
7.59	(193.0)	60	2.03	(51.6)
7.55	(192.0)	64	1.99	(50.5)
7.51	(191.0)	68	1.95	(49.5)
7.47	(189.5)	72	1.91	(48.5)
7.43	(188.5)	76	1.87	(47.5)
7.39	(187.5)	80	1.83	(46.5)
7.35	(186.5)	84	1.79	(45.5)
7.31	(185.5)	88	1.75	(44.5)
7.27	(184.5)	92	1.71	(43.4)
7.23	(183.5)	96	1.67	(42.4)
7.19	(182.5)	100	1.63	(41.4)
7.15	(181.5)	104	1.59	(40.4)
7.11	(180.5)	108	1.55	(39.4)
7.07	(179.5)	112	1.51	(38.4)
7.03	(178.5)	116	1.47	(37.3)
6.99	(177.5)	120	1.43	(36.3)