Digital Twin model for Predictive Maintenance of Volvo FH Trucks on the Lima–Yanacocha Mining Route: ASEL SAC Case Study

Pacherres-Castañeda Jeremy Leandro, Estudiante Ing. Industrial[1]; Bazan-Soriano Arath Alfonso, Estudiante Ing. Industrial[2]; Fernandez-Bernal Mateo Alejandro, Estudiante Ing. Industrial[3]; Campos-Ramos Jhoel Isaac, Estudiante Ing. Industrial[4]; Quispe-Vásquez Luis Roberto, Doctor en Ciencias Económicas[5]
[1-5]Universidad Privada del Norte, Perú, *n00332025@upn.pe, n00317987@upn.pe, n00319734@upn.pe, n00338591@upn.pe, luis.quispe@upn.edu.pe*

Abstract– ***Mining transport on high-mountain routes subjects the braking systems of heavy vehicles to severe demands that corrective maintenance cannot anticipate. This study proposes a decision-support prototype oriented toward a digital twin for the predictive maintenance of the braking systems of three Volvo FH trucks from ASEL SAC on the Lima–Yanacocha route, utilizing internal operational records and without telemetry. A Brake Degradation Index (BDI) with a multiplicative structure is developed, parameterized from an assumed reference lifespan, and implemented through a three-layer architecture: an SQLite database, a Python module, and an Excel interface. The mileage since the last service is automatically calculated from the odometer. The application identifies one unit at an alert level, with approximately 20 days remaining until the critical threshold, while the other two present margins of several months. Sensitivity and Monte Carlo analyses show that the priority among units remains stable and that the most exposed unit requires intervention within 90 days for reference lifespans up to 68% higher than the initial assumption, although the exact date presents uncertainty. The ex-ante economic analysis indicates a break-even point of one corrective event every 6.8 years, conditioned on scheduling preventive interventions during operational shutdowns. The prototype constitutes a proof of concept whose calibration requires empirical measurements of pad wear.***

Keywords-- Digital twin, Predictive maintenance, Brake system, Mining transport, Degradation index

Gemelo Digital para el Mantenimiento Predictivo de Camiones Volvo FH en la Ruta Minera Lima–Yanacocha: Estudio de Caso de ASEL SAC

Pacherres-Castañeda Jeremy Leandro, Estudiante Ing. Industrial[1]; Bazan-Soriano Arath Alfonso, Estudiante Ing. Industrial[2]; Fernandez-Bernal Mateo Alejandro, Estudiante Ing. Industrial[3]; Campos-Ramos Jhoel Isaac, Estudiante Ing. Industrial[4]; Quispe-Vásquez Luis Roberto, Doctor en Ciencias Económicas[5]
[1-5]Universidad Privada del Norte, Perú, *n00332025@upn.pe, n00317987@upn.pe, n00319734@upn.pe, n00338591@upn.pe, luis.quispe@upn.edu.pe*

Resumen– ***El transporte minero en rutas de alta montaña somete los sistemas de frenos de vehículos pesados a una exigencia severa que el mantenimiento correctivo no permite anticipar. Este estudio propone un prototipo de soporte a decisiones, orientado a gemelo digital, para el mantenimiento predictivo de los sistemas de frenos de tres camiones Volvo FH de ASEL SAC en la ruta Lima–Yanacocha, utilizando registros operacionales internos y sin telemetría. Se desarrolla un Índice de Degradación del Freno (IDF) de estructura multiplicativa, parametrizado a partir de una vida de referencia supuesta, e implementado mediante una arquitectura de tres capas: base de datos SQLite, módulo Python e interfaz Excel. El kilometraje desde el último servicio se calcula automáticamente a partir del odómetro. La aplicación identifica una unidad en nivel de alerta, con aproximadamente 20 días hasta el umbral crítico, mientras las otras dos presentan holguras de varios meses. Los análisis de sensibilidad y Monte Carlo muestran que la prioridad entre unidades se mantiene estable y que la unidad más expuesta requiere intervención dentro de 90 días para vidas de referencia de hasta 68 % superiores al supuesto inicial, aunque la fecha exacta presenta incertidumbre. El análisis económico ex ante indica un punto de equilibrio de un evento correctivo cada 6,8 años, condicionado a programar las intervenciones preventivas durante paradas operativas. El prototipo constituye una prueba de concepto cuya calibración requiere mediciones empíricas del desgaste de las pastillas.***

Palabras clave-- ***Gemelo digital, Mantenimiento predictivo, Sistema de frenos, Transporte minero, Índice de degradación***

I. Introducción

El transporte de materiales en operaciones mineras representa una de las actividades logísticas más críticas dentro de la cadena de suministro industrial, debido a las severas condiciones operativas a las que se encuentran sometidos los vehículos pesados. Factores como largas distancias, pendientes pronunciadas, variaciones de altitud y cargas elevadas generan desgaste acelerado en componentes mecánicos esenciales, incrementando la probabilidad de fallas y los costos asociados al mantenimiento. En este contexto, las estrategias tradicionales basadas únicamente en mantenimiento preventivo programado resultan insuficientes frente a la necesidad de mejorar la disponibilidad operativa y reducir paradas no planificadas. Diversos estudios recientes destacan que las tecnologías de mantenimiento predictivo permiten anticipar fallas mediante el análisis continuo de datos operacionales y condiciones reales de funcionamiento [1,2].

Actualmente, la transformación digital impulsada por la Industria 4.0 ha favorecido la incorporación de tecnologías inteligentes orientadas a la supervisión y gestión avanzada de activos industriales. Entre estas tecnologías, el gemelo digital (Digital Twin) ha adquirido gran relevancia debido a su capacidad de representar virtualmente un activo físico mediante la integración de datos históricos, sensores y modelos computacionales en tiempo real. Según diversos autores, un gemelo digital permite monitorear el comportamiento operativo de los equipos, simular escenarios de degradación y optimizar la toma de decisiones relacionadas con mantenimiento y confiabilidad [3,4]. Asimismo, investigaciones recientes evidencian que la integración de machine learning y análisis predictivo dentro de arquitecturas Digital Twin mejora significativamente la precisión en la detección temprana de fallas en sistemas industriales y vehículos pesados [5].

En el sector del transporte pesado, especialmente en vehículos de carga utilizados en minería, el mantenimiento predictivo ha comenzado a emplearse como una alternativa para disminuir tiempos muertos y optimizar los recursos de mantenimiento. Estudios desarrollados en flotas de camiones pesados Scania y otros vehículos industriales demuestran que el análisis de datos operacionales permite identificar patrones asociados al desgaste y fallas inminentes de componentes críticos [6,7]. Del mismo modo, investigaciones recientes sobre vehículos comerciales y sistemas de transporte muestran que los modelos basados en gemelos digitales permiten mejorar el seguimiento de variables como temperatura, presión, vibración y carga, facilitando la predicción del deterioro mecánico bajo condiciones severas de operación [8,9].

En cuanto al estado del conocimiento, estudios de referencia [1] demostraron mejoras significativas en la precisión del diagnóstico mediante modelos multinivel de gemelo digital aplicados a manufactura inteligente, mientras que en otro estudio [10] se identificaron cuatro componentes arquitectónicos esenciales en toda implementación robusta: adquisición de datos, modelado del sistema, motor de inferencia predictiva e interfaz de decisión. No obstante, la mayoría de estas investigaciones se han desarrollado en contextos europeos o norteamericanos con flotas de gran escala y acceso a infraestructura avanzada de sensorización [6,7,9], limitando su

aplicabilidad directa en entornos latinoamericanos. Borisenko [11] constituye una excepción relevante al abordar condiciones geográficas extremas en operaciones mineras, reportando reducciones en el costo por kilómetro de mantenimiento mediante gemelos digitales; sin embargo, el sistema de frenos en rutas de alta montaña como componente específico de modelado predictivo permanece como un área escasamente explorada en la literatura [3,5].

En el caso de ASEL SAC, empresa dedicada al transporte de materiales entre Lima y la mina Yanacocha mediante camiones Volvo Trucks FH, las condiciones geográficas y operacionales de la ruta generan altos niveles de exigencia mecánica sobre componentes críticos como el sistema de frenos. Las continuas variaciones de altitud, las pendientes prolongadas y las cargas pesadas contribuyen al desgaste acelerado de dichos componentes, lo que expone a la flota al riesgo de intervenciones correctivas no programadas y de pérdida de disponibilidad. A pesar del creciente desarrollo de tecnologías digitales aplicadas al mantenimiento industrial, aún existe limitada aplicación de modelos de gemelo digital orientados al transporte minero pesado en rutas de alta montaña, particularmente en empresas latinoamericanas de pequeña y mediana escala [10].

Por ello, el presente estudio presenta como objetivo general diseñar un prototipo orientado a gemelo digital para el mantenimiento predictivo del sistema de frenos en los camiones Volvo FH de la empresa ASEL SAC que opera en la ruta minera Lima–Yanacocha, mediante la integración de variables operacionales, registros internos de la empresa y un modelo paramétrico de degradación, evaluando la robustez de sus resultados frente a los supuestos adoptados.

Y como objetivos específicos se presentan:

- Caracterizar las condiciones operacionales y el estado actual del mantenimiento de los tres camiones Volvo FH de la flota ASEL SAC en la ruta Lima–Yanacocha.
- Identificar las variables operacionales críticas e implementar un modelo de degradación del sistema de frenos mediante el Índice de Degradación del Freno (IDF).
- Desarrollar una arquitectura orientada a gemelo digital con implementación computacional en SQLite, Python y Excel, adaptada a las capacidades tecnológicas reales de la empresa.
- Establecer umbrales de alerta predictiva y proyecciones de Vida Útil Remanente (VUR) que permitan anticipar intervenciones con margen mínimo de un ciclo de viaje completo.
- Evaluar el estado actual de la flota mediante la aplicación del modelo, identificando prioridades de intervención por unidad y evaluando su robustez y su viabilidad económica frente a los supuestos del modelo.

II. METODOLOGÍA

A. Tipo y diseño de la investigación

La presente investigación es de tipo descriptiva y propositiva, con enfoque cuantitativo. Es descriptiva porque caracteriza el comportamiento operacional y el estado actual del mantenimiento de los tres camiones Volvo FH de ASEL SAC en la ruta Lima–Yanacocha; es propositiva porque, a partir de dicho diagnóstico, formula un modelo de gemelo digital orientado al mantenimiento predictivo del sistema de frenos. El enfoque cuantitativo se sustenta en que las variables analizadas se expresan en unidades numéricas verificables: kilometraje, carga transportada, frecuencia de viajes, indicadores de degradación y costos de mantenimiento [12].

El diseño es no experimental y de corte transversal, dado que no se manipulan las variables operacionales, sino que se analizan los datos disponibles en un período definido para construir y parametrizar el modelo [12].

B. Unidad de análisis, fuentes de datos y variables operacionales

La unidad de análisis está constituida por los tres tractocamiones Volvo FH activos de ASEL SAC. La ruta de operación Lima–Mina Yanacocha comprende aproximadamente 878 km por sentido, con un perfil altitudinal que varía desde el nivel del mar hasta los 3,800 m s. n. m., lo que impone condiciones severas de frenado continuo en los tramos de descenso de la sierra.

Las fuentes de datos son de naturaleza secundaria e interna y comprenden los registros de viajes de la empresa (kilometraje, frecuencia y carga transportada), el kilometraje recorrido por cada unidad desde su última intervención en frenos, los costos de mantenimiento y de parada, y el perfil cartográfico de la ruta. Las unidades cuentan con frenos neumáticos de control electrónico (EBS) y freno motor auxiliar VEB+, pero la flota no dispone del sistema de telemetría Dynafleet, por lo que toda la información es de origen manual. La empresa no registra de forma sistemática el espesor de las pastillas ni las fechas de las intervenciones en frenos, y en el período analizado no se registraron fallas del sistema de frenos; el único evento no planificado documentado fue el daño de un parabrisas, con tres días de indisponibilidad. En consecuencia, el estudio distingue entre datos reales de la empresa (características de la flota, frecuencia de viajes, carga, kilometraje desde la última intervención y costos) y supuestos de ingeniería (vida de referencia del sistema de frenos, coeficientes β y γ y umbrales de alerta), cuyo efecto se evalúa mediante análisis de sensibilidad.

Las variables seleccionadas para alimentar el modelo fueron determinadas en función de su incidencia documentada

en el desgaste del sistema de frenos bajo condiciones de operación en alta montaña.

C. Fases de desarrollo del gemelo digital

El desarrollo del modelo se estructura en cinco fases secuenciales que articulan el diagnóstico operacional con la construcción e implementación del gemelo digital:

Fase 1 – Diagnóstico operacional: Se analizan los registros operacionales de la empresa para caracterizar cada unidad según su antigüedad, kilometraje acumulado, régimen de mantenimiento, frecuencia de viajes, carga transportada y kilometraje desde la última intervención en frenos.

Fase 2 – Modelado de degradación: A partir del kilometraje desde la última intervención, la carga transportada y el perfil de pendientes de la ruta, se formula un índice de degradación de estructura multiplicativa. Ante la ausencia de mediciones de desgaste, sus coeficientes se parametrizan a priori a partir de una vida de referencia supuesta del sistema de frenos.

Fase 3 – Construcción del gemelo digital: Se integran el modelo de degradación y las variables operacionales en un entorno desarrollado en Python y Excel, estructurado sobre una base de datos SQLite que centraliza los registros de viajes y de intervenciones y deriva por consulta el kilometraje desde la última intervención en frenos. El entorno representa el estado del sistema de frenos de cada camión y proyecta su evolución en función de los parámetros de operación planificados.

Fase 4 – Definición de umbrales y alertas predictivas: Se definen umbrales de alerta y crítico como criterio de diseño, más conservadores para la unidad de mayor antigüedad y régimen correctivo, generando un sistema de alertas que anticipa la necesidad de intervención con un margen mínimo de un viaje completo Lima–Yanacocha.

Fase 5 – Análisis de sensibilidad y evaluación económica: Se evalúa el efecto de los supuestos sobre las decisiones del modelo mediante un análisis local (±20 %), el cálculo de valores de conmutación de la vida de referencia y una simulación de Monte Carlo, y se estima la viabilidad económica mediante un análisis ex ante de punto de equilibrio basado en los costos reales de la empresa.

D. Nivel de madurez del gemelo digital

Según la clasificación de Kritzinger et al. [13], un gemelo digital se distingue de un modelo digital y de una sombra digital por el grado de automatización del flujo de datos entre el activo físico y su representación virtual: en el modelo digital ambos flujos son manuales, en la sombra digital el flujo del activo hacia el modelo es automático y en el gemelo digital lo son ambos. Dado que en ASEL SAC los datos se registran manualmente y las decisiones se ejecutan a través del personal de mantenimiento, el sistema propuesto corresponde a un prototipo de soporte a decisiones con arquitectura orientada a gemelo digital, en el nivel de modelo digital. Su diseño contempla una hoja de ruta de madurez: automatizar primero la captura del odómetro y de la carga, incorporar luego mediciones del desgaste de las pastillas —obtenidas en las inspecciones de taller o, en configuraciones con frenos de disco, a partir de los sensores de desgaste que algunos sistemas EBS pueden registrar— e integrar finalmente telemetría continua, con lo que el sistema evolucionaría hacia una sombra digital y, posteriormente, hacia un gemelo digital pleno.

III. Resultados

A. Caracterización de las condiciones operacionales y del estado del mantenimiento

La ruta de operación Lima–Mina Yanacocha comprende aproximadamente 878 km por sentido, con un perfil altitudinal que varía desde el nivel del mar hasta los 3,800 m s. n. m. Las características operacionales de cada unidad de la flota ASEL SAC se detallan en la Tabla I.

TABLA I
CARACTERIZACIÓN DE LA FLOTA Y KILOMETRAJE MENSUAL POR UNIDAD

Unidad	Modelo	Viajes /Mes	Km por Viaje	Km Mensual
Volvo FH #1	Volvo FH 480 año 2011	5 viajes	1,756 km	8,780 km
Volvo FH #2	Volvo FH 540 año 2021	4 viajes	1,756 km	7,024 km
Volvo FH #3	Volvo FH 540 año 2025	3 viajes	1,756 km	5,268 km

La heterogeneidad técnica y operacional de la flota determina que cada unidad presenta condiciones de desgaste radicalmente distintas, tal como se resume en la Tabla II.

TABLA II
CARACTERIZACIÓN TÉCNICA Y OPERACIONAL DE LA FLOTA ASEL SAC

Unidad	Modelo	Año	Km acumulados	Carga	Horas op./día	Mantenimiento actual
Volvo FH #1	FH 480	2011	~610,000 km	Carga general	~18 h	Correctivo
Volvo FH #2	FH 540	2021	~240,000 km	Mat. diversos (mina)	16 h	Preventivo
Volvo FH #3	FH 540	2025	~30,000 km	MATPEL	12 h	Preventivo

La combinación de antigüedad, kilometraje acumulado y régimen de mantenimiento configura tres perfiles de riesgo claramente distintos: FH #1 concentra la mayor exposición acumulada al deterioro con 610,000 km y mantenimiento exclusivamente correctivo; FH #2 presenta condiciones

intermedias bajo régimen preventivo; y FH #3, con apenas 30,000 km y preventivo, representa la línea base de referencia de la flota.

B. Identificación de variables operacionales e implementación del modelo IDF

Las variables operacionales incluidas en el estudio fueron seleccionadas en función de su incidencia documentada en el desgaste del sistema de frenos bajo condiciones de operación en alta montaña, y se presentan en la Tabla III.

TABLA III
VARIABLES OPERACIONALES DEL MODELO DE GEMELO DIGITAL

Variable	Fuente	Unidad
Kilometraje acumulado	Registro de viajes	km
Temperatura del sistema de frenos	Tablero Volvo / registros	°C
Perfil de pendientes de la ruta	Datos GPS / cartografía	%
Frecuencia de frenadas por viaje	Reporte de conductor	Eventos/viaje
resión del sistema neumático de freno	Tablero Volvo	PSI
Horas motor acumuladas	Tablero Volvo	h
Carga transportada por viaje	Guía de remisión	t
Intervenciones correctivas en frenos	Historial de mantenimiento	N.° eventos

El kilometraje, la carga transportada por viaje y el perfil de pendientes de la ruta alimentan directamente la ecuación del IDF. Las demás variables constituyen variables de contexto que enriquecen el registro operacional y sirven como insumo para futuras expansiones del modelo, pero no intervienen en el cálculo actual del índice.

Para cuantificar el estado de degradación del sistema de frenos se define el Índice de Degradación del Freno (IDF) según la ecuación (1):

$$IDF = \alpha \cdot \Delta km \cdot (1 + \beta \cdot \bar{C} + \gamma \cdot \bar{P}) \qquad (1)$$

Donde Δkm es el kilometraje acumulado desde la última intervención en frenos; $\bar{C}$ es la carga promedio transportada por viaje en toneladas; $\bar{P}$ es el factor de pendiente promedio de la ruta (fijo en 0.50 para Lima–Yanacocha según perfil cartográfico); y α, β, γ son coeficientes de ponderación. La estructura multiplicativa de la ecuación garantiza que la carga y la pendiente actúen como amplificadores de la tasa de desgaste por kilómetro —y no como desplazamientos constantes—, de modo que una unidad con mayor carga presenta una curva de degradación más empinada desde el inicio del ciclo de servicio. Cuando Δkm = 0 (unidad recién intervenida), el IDF es igual a cero independientemente de la carga y la pendiente, lo que es físicamente coherente con el estado de un freno en condición nueva. El IDF toma valores en el rango [0, 1], donde 0 representa condición óptima y 1 degradación máxima.

Dado que la empresa no dispone de mediciones del desgaste de las pastillas ni de fallas de frenos registradas, los coeficientes no pueden estimarse empíricamente. Por ello, el modelo se parametriza a priori a partir de una vida de referencia L, definida como el kilometraje desde el último servicio en el que cada unidad alcanzaría su umbral crítico operando con su carga promedio, mediante la ecuación (2):

$$\alpha = \frac{IDF_{crít}}{L \cdot S_{ref}}, \quad S_{ref} = 1 + \beta \cdot C_{ref} + \gamma \cdot \bar{P} \qquad (2)$$

Donde $IDF_{crít}$ es el umbral crítico de la unidad y S_{ref} es el multiplicador de severidad evaluado con la carga de referencia C_{ref}. Con esta parametrización, cuando la carga coincide con la de referencia el índice se reduce a $IDF = IDF_{crít} \cdot \Delta km / L$, de modo que L es el parámetro que gobierna las predicciones. Los valores de L, β y γ constituyen supuestos de ingeniería y no mediciones; su efecto sobre los resultados se evalúa en la Sección III-F. La Tabla IV presenta los parámetros de cada unidad.

TABLA IV
PARÁMETROS DEL MODELO DE DEGRADACIÓN POR UNIDAD (L, Β Y Γ: SUPUESTOS DE INGENIERÍA)

Unidad	L supuesto (km)	α (por km)	β (por t)	γ (ruta)	Umbral alerta	Umbral crítico
Volvo FH #1	30,000	2.13×10^{-5}	0.010	0.30	0.65	0.85
Volvo FH #2	55,000	1.19×10^{-5}	0.010	0.30	0.70	0.90
Volvo FH #3	80,000	8.52×10^{-6}	0.010	0.30	0.75	0.92

El coeficiente α varía por unidad para reflejar la diferente vida de referencia asumida según la antigüedad, el kilometraje acumulado y el régimen de mantenimiento de cada vehículo; los coeficientes β y γ son compartidos, dado que la sensibilidad a la carga y a la pendiente depende de las condiciones de la ruta y no de la unidad. Los umbrales son más conservadores para FH #1 por su mayor kilometraje acumulado y régimen correctivo. Cabe precisar que, al derivarse α con la carga de referencia, β y γ solo modifican los resultados cuando la carga real se aparta de dicha referencia, y que el término de pendiente probablemente sobreestima el desgaste de las pastillas, pues el freno motor VEB+ absorbe parte de la energía de frenado en los descensos. Las curvas de degradación proyectadas para cada unidad en función del Δkm desde la última intervención se presentan en la Fig. 1.

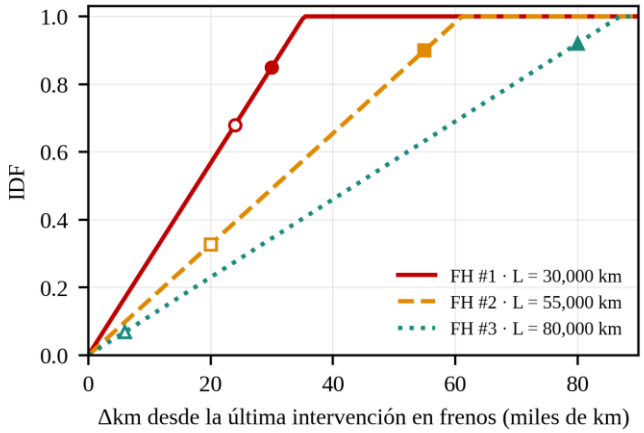


Fig. 1 Curvas de degradación del IDF por unidad en función del kilometraje desde la última intervención en frenos, con la carga de referencia. Marcadores llenos: umbral crítico (Δkm = L); marcadores vacíos: estado al 24/06/2026.

C. Arquitectura del gemelo digital e implementación computacional

El prototipo adopta una arquitectura de tres capas adaptada a las capacidades tecnológicas reales de la empresa. La capa de datos consolida los registros de viajes (odómetro y carga), los servicios de frenos, las guías de remisión y el perfil cartográfico de la ruta en una base de datos relacional SQLite; al tratarse de un único archivo sin servidor, incluido de forma nativa en Python, su adopción no implica costo ni infraestructura adicional. Su principal ventaja metodológica es que el kilometraje desde la última intervención (Δkm) y la carga media del período se derivan por consulta —Δkm como la diferencia entre el odómetro del último viaje y el registrado en el último servicio de frenos— en lugar de ingresarse manualmente. La capa de modelado, implementada en Python, deriva α a partir de L, calcula el IDF mediante la ecuación (1), estima la VUR, proyecta la degradación y ejecuta los análisis de sensibilidad y de Monte Carlo; además, incluye un procedimiento de calibración de L que se activará cuando existan mediciones del espesor de las pastillas, con el IDF observado definido como la fracción consumida del espesor útil, $IDF_{obs} = (e_{nuevo} - e_{medido})/(e_{nuevo} - e_{mín})$. La capa de salida, en Excel, presenta los niveles de alerta y el estado por unidad. La Fig. 2 ilustra esta arquitectura.

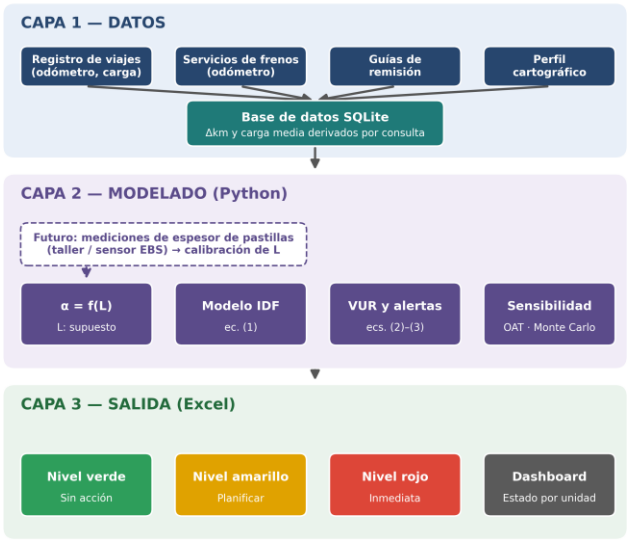


Fig. 2 Arquitectura del prototipo orientado a gemelo digital propuesto para ASEL SAC.

El módulo Excel actúa como interfaz operativa diaria: el encargado de mantenimiento registra en la hoja REGISTRO_VIAJES la fecha, la unidad, el odómetro al cierre del viaje y la carga transportada, y en la hoja SERVICIOS_FRENO el odómetro de cada intervención en frenos. A partir de ambos registros, el Δkm, la carga media desde el último servicio y el IDF se calculan automáticamente, y el panel DASHBOARD actualiza los indicadores de estado por unidad a la fecha de corte indicada. La hoja PARÁMETROS contiene la vida de referencia L de cada unidad, a partir de la cual se calcula α, de modo que una futura recalibración de L con mediciones reales se propaga a todos los cálculos sin intervención adicional.

D. Umbrales de alerta predictiva y proyecciones de Vida Útil Remanente

El sistema de alertas opera en tres niveles definidos sobre el IDF: nivel verde cuando IDF < umbral de alerta, indicando operación normal sin acción requerida; nivel amarillo cuando el IDF se encuentra entre el umbral de alerta y el umbral crítico, señalando la necesidad de planificar una intervención; y nivel rojo cuando IDF ≥ umbral crítico, requiriendo intervención inmediata antes del siguiente viaje.

La Vida Útil Remanente (VUR) en días hasta el umbral crítico se calcula mediante la ecuación (3):

$$VUR = \frac{(IDF_crítico - IDF_actual)}{\alpha \cdot km_día \cdot (1 + \beta \cdot \bar{C} + \gamma \cdot \bar{P})} \quad (3)$$

Donde km_día es el kilometraje promedio recorrido por día, calculado como el producto entre la frecuencia de viajes mensual y los kilómetros por viaje, dividido entre 30. Esta formulación garantiza que la tasa de degradación diaria

empleada en el cálculo de la VUR sea matemáticamente consistente con la ecuación (1), resolviendo la inconsistencia que emerge cuando se emplean formulaciones distintas para el modelo y para la proyección.

La aplicación del modelo de Índice de Degradación del Freno (IDF) a los datos operacionales vigentes de la flota ASEL SAC se ejecutó mediante el módulo Python desarrollado, tomando como insumos el Δkm acumulado desde la última intervención en el sistema de frenos de cada unidad, la carga promedio transportada por viaje, la frecuencia mensual de viajes y el factor de pendiente fijo de la ruta Lima–Yanacocha ($\bar{P}$ = 0.50). Con fecha de corte al 24 de junio de 2026, los resultados obtenidos, incluyendo la tasa de degradación diaria calculada, los días proyectados hasta cada umbral y el nivel de alerta actual, se consolidan en la Tabla V.

TABLA V
Resultados del modelo IDF — Estado actual por unidad

Parámetro	Volvo FH #1	Volvo FH #2	Volvo FH #3
IDF actual	0.68	0.33	0.07
Umbral de alerta	0.65	0.70	0.75
Umbral crítico	0.85	0.90	0.92
Tasa de degradación (IDF/día)	0.0083	0.0038	0.0020
Días hasta umbral de alerta	0 (ya en alerta)	97 (29 sep.)	337 (27 may. 2027)
Días hasta umbral crítico	20.5 (14 jul.)	149.5 (20 nov.)	421.4 (19 ago. 2027)
Nivel de alerta actual	AMARILLO	VERDE	VERDE

El resultado más relevante de la Tabla V es la diferenciación de riesgo que el modelo revela entre unidades cuyo estado aparente no anticipa por sí solo su urgencia. La unidad FH #1 ya superó su umbral de alerta (IDF = 0.68 > 0.65) y se encuentra en nivel amarillo, con aproximadamente 20 días de margen antes de alcanzar el umbral crítico, lo que corresponde a sus 24,000 km de operación desde la última intervención frente a una vida de referencia supuesta de 30,000 km. Sin una intervención programada, FH #1 alcanzaría el umbral crítico hacia el 14 de julio de 2026; no obstante, esta fecha depende directamente del supuesto de L y debe interpretarse junto con el análisis de sensibilidad de la Sección III-F. La unidad FH #2 opera en nivel verde con un margen amplio: su trayectoria la llevaría a zona de alerta hacia el día 97 y a zona crítica hacia el día 150 (20 de noviembre de 2026). La unidad FH #3, con 6,000 km desde su última intervención, exhibe el IDF más bajo (0.07) y no se aproxima a ningún umbral dentro del horizonte de 90 días. La tasa de degradación de FH #1 (0.0083 IDF/día) más que duplica la de FH #2 y cuadruplica la de FH #3.

El estado actual del IDF de cada unidad, representado mediante indicadores gauge con zonas de degradación codificadas y el indicador predictivo de días hasta umbral crítico, se presenta en la Fig. 3.

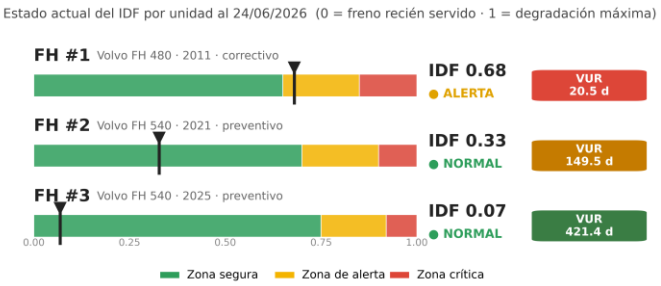


Fig. 3 Estado actual del IDF por unidad. FH #1 ya se encuentra en zona de alerta (amarillo); FH #2 y FH #3 operan en zona segura. El indicador de días hasta el umbral crítico refleja la urgencia predictiva del modelo.

La distribución temporal de los días en cada zona de riesgo dentro del horizonte de 90 días.

E. Evaluación del estado actual de la flota e identificación de prioridades de intervención

La Tabla VI presenta la proyección del IDF a intervalos de 30 días para cada unidad, confirmando la evolución de las trayectorias de degradación bajo el supuesto de ausencia de intervención.

TABLA VI
Proyección del IDF a 30, 60 y 90 días sin intervención — datos exportados del modelo

Unidad	IDF día 0	IDF día 30	IDF día 60	IDF día 90	Umbral crítico
FH #1	0.68	0.93	1.00	1.00	Día 20.5 (14 jul.)
FH #2	0.33	0.44	0.56	0.67	Día 149.5 (20 nov.)
FH #3	0.07	0.13	0.19	0.25	Día 421.4 (19 ago. 2027)

La Tabla VI evidencia tres trayectorias claramente diferenciadas. FH #1 cruza el umbral crítico hacia el día 20 y satura el índice (IDF = 1.00) hacia el día 60, permaneciendo en zona crítica el 77 % del horizonte de 90 días si no se interviene. FH #2 evoluciona de 0.33 a 0.67 a lo largo de los 90 días, manteniéndose en zona verde durante todo el horizonte, por debajo de su umbral de alerta (0.70). FH #3 apenas alcanza un IDF de 0.25 al día 90, muy por debajo de su umbral de alerta (0.75), lo que indica que tanto su vida útil remanente como su régimen preventivo resultan adecuados para las condiciones actuales de operación. El valor predictivo del modelo radica precisamente en anticipar estas trayectorias divergentes a partir de un estado actual que, para FH #2 y FH #3, hoy no presenta señal de alarma alguna.

A partir de estos resultados, el gemelo digital genera el plan de intervenciones detallado en la Tabla VII, traduciendo los valores técnicos del IDF en fechas concretas de acción y niveles de prioridad.

TABLA VII
Plan de intervenciones predictivas recomendado — Flota ASEL SAC (junio–agosto 2026)

Unidad	Estado actual	Alerta prevista	Crítico previsto	Fecha límite intervención	Tipo de intervención	Prioridad
FH #1	AMARILLO	Ya en alerta	14 jul. 2026	Antes del 14 jul.	Revisión y reemplazo del sistema de frenos	URGENTE
FH #2	VERDE	29 sep. 2026	20 nov. 2026	Antes del 20 nov.	Inspección y mantenimiento preventivo	MEDIA
FH #3	VERDE	27 may. 2027	19 ago. 2027	Próxima escala programada	Revisión de rutina	RUTINA

El panel principal del dashboard Excel operativo con el estado de las tres unidades a la fecha de corte se muestra en la Fig. 4, y la salida del módulo Python se presenta en la Fig. 5.

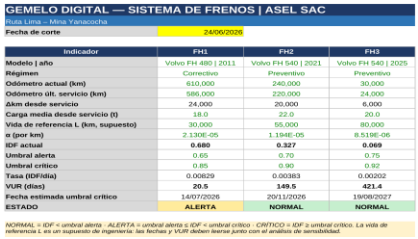


Fig. 4 Panel principal del dashboard Excel operativo — estado de la flota ASEL SAC.

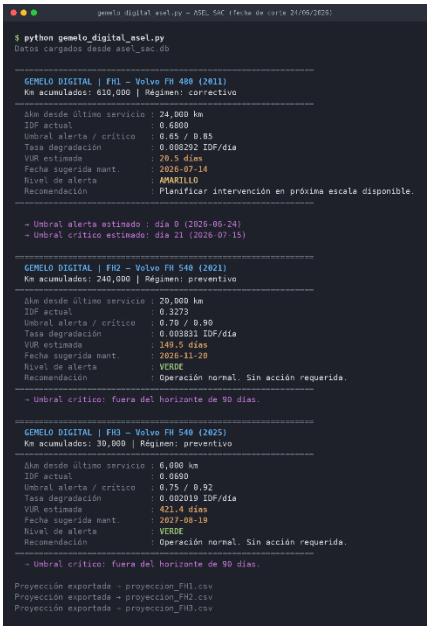


Fig. 5 Salida del módulo Python — reporte generado por el modelo para la flota ASEL SAC.

F. Análisis de sensibilidad e incertidumbre

Dado que la vida de referencia L de cada unidad es un supuesto de ingeniería, se evaluó su efecto sobre las decisiones del modelo mediante tres análisis complementarios. En el análisis local, cada parámetro se varió en ±20 % manteniendo los demás constantes: L resultó el parámetro dominante, con una VUR de FH #1 entre 0 y 41 días, frente a variaciones de entre 3 y 5 días por la carga media o el kilometraje diario, mientras que β y γ no alteran los resultados en el estado actual, porque α se deriva de L con la carga de referencia y ambos términos solo actúan cuando la carga real se aparta de ella.

La Tabla VIII presenta los valores de conmutación de L, es decir, aquellos a partir de los cuales cambia la decisión de mantenimiento; con la carga de referencia se obtienen analíticamente de $IDF = IDF_{crít} \cdot \Delta km / L$. FH #1 requiere intervención dentro de un horizonte de 90 días para cualquier L ≤ 50,340 km, lo que equivale a tolerar un error de hasta 68 % en el supuesto; en cambio, su clasificación actual en nivel de alerta solo se mantiene para L entre 24,000 y 31,385 km, por lo que la fecha exacta de intervención es sensible al supuesto. FH #2 solo requeriría intervención en ese horizonte si su vida real fuera un 25 % inferior a la supuesta, y FH #3 si lo fuera en un 73 %. La Fig. 6 muestra la VUR de las tres unidades en función de L.

TABLA VIII
Valores de conmutación de la vida de referencia L (km)

Unidad	L supuesto	Crítico hoy si L ≤	Alerta hoy si L ≤	VUR ≤ 90 días si L ≤
FH #1	30,000	24,000	31,385	50,340 (168 %)
FH #2	55,000	20,000	25,714	41,072 (75 %)
FH #3	80,000	6,000	7,360	21,804 (27 %)

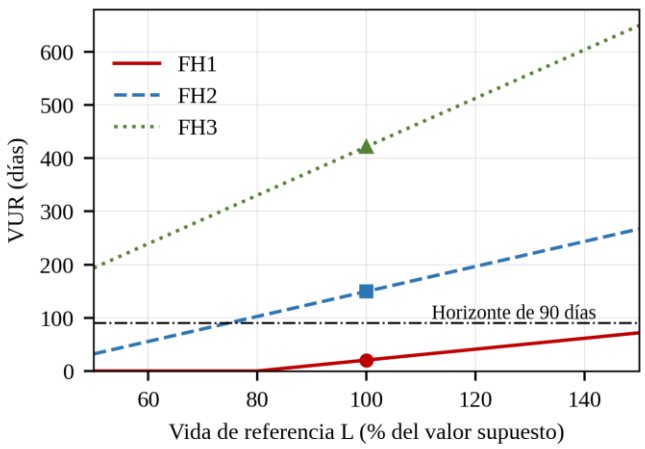


Fig. 6 Vida útil remanente de cada unidad en función de la vida de referencia L (50 %–150 % del valor supuesto). Los marcadores indican el caso base y la línea discontinua, el horizonte de 90 días.

Finalmente, se propagó la incertidumbre de los supuestos mediante una simulación de Monte Carlo de 10,000 iteraciones, en la que L se modeló con distribución uniforme de ±30 %, la carga media con distribución normal de coeficiente de variación de 10 % y el kilometraje diario con distribución uniforme de ±15 %; estos rangos son a su vez supuestos y no provienen de datos observados. Como se aprecia en la Tabla IX y en la Fig. 7, FH #1 alcanza el umbral crítico antes de 90 días en el 100 % de las simulaciones y antes de 30 días en el 66.3 %, mientras que FH #2 lo hace antes de 90 días solo en el 8.0 % y FH #3 en ninguna. En todos los análisis se mantuvo el orden de prioridad FH #1 > FH #2 > FH #3. Estos resultados cuantifican el efecto de los supuestos sobre las decisiones, pero no sustituyen la validación del modelo con mediciones de desgaste.

TABLA IX
Propagación de incertidumbre mediante simulación de Monte Carlo (n = 10,000)

Unidad	IDF P50 [P5–P95]	VUR (días) P50 [P5–P95]	P(crítico hoy)	P(VUR < 30 d)	P(VUR < 90 d)
FH #1	0.681 [0.536–0.932]	20.4 [0.0–49.2]	16.9 %	66.3 %	100 %
FH #2	0.327 [0.257–0.448]	150.4 [85.2–221.8]	0 %	0 %	8.0 %
FH #3	0.069 [0.054–0.094]	422.7 [291.1–578.1]	0 %	0 %	0 %

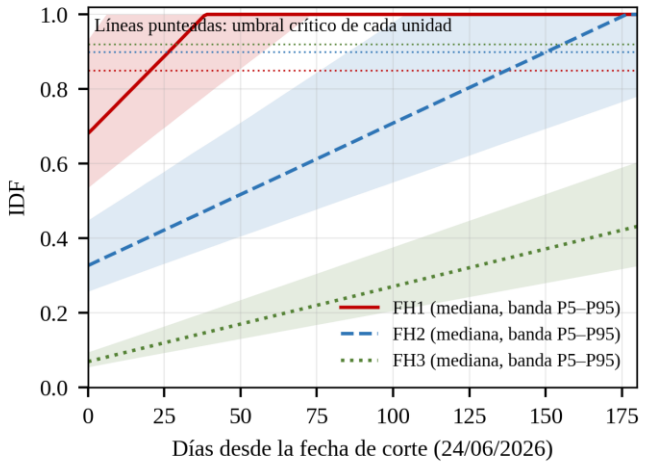


Fig. 7 Proyección del IDF a 180 días desde la fecha de corte: mediana y banda P5–P95 de la simulación de Monte Carlo. Las líneas punteadas indican el umbral crítico de cada unidad.

G. Evaluación económica ex ante

Dado que ASEL SAC no registra fallas del sistema de frenos en el período analizado, no es posible estimar un ahorro histórico, por lo que se adoptó un análisis económico ex ante basado en el punto de equilibrio. Se emplearon los costos reales de la empresa (USD 500 por intervención preventiva, USD 1,200 por intervención correctiva y USD 3,000 por día de parada) y tres escenarios de tiempo de parada, que constituyen supuestos. El costo anual del programa incluye el registro de datos (2 h mensuales a USD 5/h, supuesto) y el reemplazo anticipado de pastillas derivado de intervenir en el umbral de alerta en lugar del crítico, estimado en 1.7 servicios adicionales por año para la flota con los valores de L supuestos. La Tabla X presenta los resultados.

TABLA X
Análisis económico ex ante de punto de equilibrio (USD)

Concepto	Pesimista	Base	Optimista
Días de parada por evento correctivo (supuesto)	1	2	3
Días de parada por intervención preventiva (supuesto)	0.5	0	0
Costo por evento correctivo	4,200	7,200	10,200
Costo por intervención preventiva	2,000	500	500
Costo evitado por evento	2,200	6,700	9,700
Costo anual del programa	3,562	981	981
Equilibrio: evitar 1 evento cada…	0.6 años	6.8 años	9.9 años

En el escenario base, el sistema alcanza el equilibrio si evita un solo evento correctivo de frenos cada 6.8 años en toda la flota. En el escenario pesimista, en cambio, cada intervención preventiva implica medio día de parada y el equilibrio exigiría evitar 1.6 eventos por año, lo que indica que el beneficio económico depende de programar las intervenciones dentro de las paradas operativas existentes. Como referencia del costo de una parada no planificada, el único evento imprevisto registrado por la empresa —el daño de un parabrisas, con tres días fuera de servicio— representó una pérdida operativa de USD 9,000. El análisis no monetiza el riesgo de seguridad asociado a una falla de frenos en una ruta de montaña ni los costos de grúa, que constituyen la principal justificación del enfoque predictivo. La implementación no requiere inversión en infraestructura tecnológica: opera sobre herramientas de uso libre (SQLite y Python) y Microsoft Excel, sin la instalación de sistemas de telemetría como Dynafleet.

IV. Discusión de Resultados

La aplicación del modelo a la flota arrojó un resultado central: la unidad FH #1 —la más antigua y de régimen correctivo— se ubicó en nivel de alerta (IDF = 0.68), con unos 20 días de margen hasta el umbral crítico, mientras que FH #2 y FH #3 permanecieron en nivel verde con holguras de 150 y 421 días, respectivamente. El análisis de sensibilidad muestra que lo robusto de este resultado es el orden de prioridad entre unidades

y la necesidad de intervenir FH #1 en el corto plazo, no la fecha exacta de intervención, que depende de la vida de referencia supuesta. En un plano más general, el estudio muestra que un prototipo orientado a gemelo digital, construido sobre una base de datos SQLite, un módulo de cálculo en Python y una interfaz en Excel —sin telemetría y a partir de registros internos—, puede transformar un índice de degradación en un plan de mantenimiento priorizado por unidad, siempre que sus supuestos se declaren y se evalúen explícitamente.

El primer objetivo, caracterizar las condiciones operacionales y el estado del mantenimiento, se cumplió al identificar tres perfiles de riesgo distintos, en los que se combinan la antigüedad, el kilometraje acumulado y el régimen de mantenimiento; FH #1 concentró la mayor exposición al confluir 610,000 km y una gestión exclusivamente correctiva. El segundo objetivo, identificar las variables críticas e implementar el IDF, se concretó mediante una formulación multiplicativa en la que la carga y la pendiente amplifican la tasa de desgaste por kilómetro y el índice se anula tras cada intervención; su parametrización, sin embargo, descansa en una vida de referencia supuesta. El tercer objetivo se concretó en una arquitectura de tres capas ajustada a las capacidades reales de la empresa, en la que el Δkm se deriva automáticamente del odómetro. El cuarto objetivo, establecer umbrales y proyecciones de VUR con un margen mínimo de un ciclo de viaje, se satisfizo en el caso base, dado que los 20 días de margen de FH #1 superan la duración de un viaje completo Lima–Yanacocha. Finalmente, el quinto objetivo se alcanzó al derivar un plan que clasifica a FH #1 como intervención urgente y a FH #2 y FH #3 como acciones preventiva y de rutina, prioridades que se mantuvieron en todos los escenarios de sensibilidad evaluados y cuya viabilidad económica depende de programar las intervenciones en paradas ya previstas.

Los hallazgos coinciden con lo reportado por Borisenko [11], quien evidenció que la aplicación de gemelos digitales a camiones de acarreo en condiciones geográficas extremas reduce el costo de mantenimiento por kilómetro; en ambos casos, la severidad de la ruta constituye el factor determinante del deterioro. No obstante, el presente estudio se distingue de la mayoría de los antecedentes en un aspecto sustantivo: los trabajos desarrollados sobre flotas pesadas Scania y vehículos terrestres [6], [7], [9] dependen de infraestructura avanzada de sensorización y telemetría continua, mientras que el modelo propuesto opera exclusivamente con registros manuales internos. De este modo, la investigación extiende la aplicabilidad de los marcos descritos en las revisiones de Wang et al. [3] e Ismail et al. [5] hacia un contexto de pequeña y mediana empresa con recursos limitados. Asimismo, frente a los enfoques que privilegian algoritmos de aprendizaje automático para maximizar la precisión [2], [6], [7], este estudio opta por un modelo paramétrico y determinístico que prioriza la interpretabilidad y la viabilidad bajo escasez de datos, y cuya arquitectura de tres capas simplifica deliberadamente los cuatro componentes canónicos — adquisición de datos, modelado, motor de inferencia e interfaz de decisión— identificados en la literatura de referencia [5], [10].

Desde la perspectiva operativa, el principal aporte del modelo es la conversión de un índice técnico en un plan de intervenciones priorizado por unidad, que permite coordinar las reparaciones con el taller de forma anticipada. El análisis económico ex ante indica que este beneficio no proviene de un ahorro histórico —la empresa no registra fallas de frenos—, sino de evitar eventos poco frecuentes pero costosos, y que depende de ejecutar las intervenciones preventivas dentro de las paradas operativas existentes. En el plano metodológico, el estudio muestra que es posible construir un prototipo funcional sobre datos preexistentes y herramientas de uso libre, sin inversión en telemetría, lo que reduce la barrera de adopción de estas tecnologías en el transporte minero latinoamericano de menor escala, segmento escasamente representado en la literatura especializada. En términos de gestión, los resultados sugieren migrar progresivamente las unidades gestionadas de forma correctiva hacia un esquema predictivo.

Los resultados deben interpretarse considerando varias limitaciones. En primer lugar, la empresa no dispone de mediciones del desgaste de las pastillas ni de fallas de frenos registradas, por lo que la vida de referencia L, los coeficientes β y γ y los umbrales son supuestos de ingeniería y no estimaciones empíricas; el análisis de sensibilidad acota su efecto sobre las decisiones, pero no sustituye la calibración. En segundo lugar, β no es identificable sin intervalos de una misma unidad con cargas distintas, γ no lo es mientras el factor de pendiente permanezca constante, y el término de pendiente no considera la acción del freno motor VEB+, que absorbe parte de la energía de frenado en los descensos y cuyo uso depende del conductor. En tercer lugar, la proyección asume continuidad de las condiciones operacionales y una tasa de degradación constante, sin capturar factores como la temperatura del sistema, la frecuencia de frenado, la variabilidad de la carga o las condiciones climáticas. En cuarto lugar, con flujos de datos manuales el sistema corresponde a un modelo digital en la clasificación de Kritzinger et al. [13], y no a un gemelo digital pleno. Finalmente, el estudio abarca solo tres unidades y el análisis económico se basa en escenarios de parada supuestos. Estas limitaciones delinean las líneas de trabajo futuro: registrar el espesor de las pastillas en cada inspección, o a partir de los sensores de desgaste del sistema EBS cuando estén disponibles, para calibrar L; medir el desempeño predictivo del modelo (error de predicción y tasa de falsas alertas) frente a las condiciones observadas; segmentar la ruta por tramos para estimar el efecto de la pendiente; ampliar el estudio a más unidades y ciclos de mantenimiento; y automatizar la captura de datos.

V. CONCLUSIONES

El estudio cumplió su objetivo general de diseñar un prototipo orientado a gemelo digital para el mantenimiento predictivo del sistema de frenos de los camiones Volvo FH de la empresa ASEL SAC en la ruta minera Lima–Yanacocha. A partir de la caracterización operacional de la flota, se formuló un Índice de Degradación del Freno (IDF) de estructura multiplicativa, parametrizado a partir de una vida de referencia supuesta; se implementó una arquitectura de tres capas sustentada en SQLite, Python y Excel, en la que el kilometraje desde la última intervención se deriva automáticamente; y se establecieron umbrales de alerta con proyecciones de Vida Útil Remanente para cada unidad, cuya robustez se evaluó mediante análisis de sensibilidad y de Monte Carlo.

El principal hallazgo es la capacidad del modelo para revelar un riesgo diferenciado entre unidades cuyo estado aparente no lo anticipa. La unidad FH #1, la más antigua y de régimen correctivo, se identificó en nivel de alerta con unos 20 días de margen hasta el umbral crítico en el caso base, mientras que FH #2 y FH #3 dispusieron de holguras de 150 y 421 días. El orden de prioridad FH #1 > FH #2 > FH #3 se mantuvo en todos los escenarios evaluados, y FH #1 requiere intervención dentro de 90 días para cualquier vida de referencia de hasta 68 % superior a la supuesta, aunque su fecha exacta de intervención es sensible a dicho supuesto.

La contribución principal del trabajo es mostrar que un prototipo funcional de mantenimiento predictivo puede construirse sobre registros internos preexistentes y herramientas de uso libre, sin inversión en telemetría, declarando y evaluando explícitamente sus supuestos. En términos económicos, el análisis ex ante indica que el sistema se justifica si evita un evento correctivo de frenos cada 6.8 años en el escenario base, siempre que las intervenciones preventivas se programen dentro de las paradas operativas existentes.

No obstante, el estudio constituye una prueba de concepto: la vida de referencia y los coeficientes del modelo son supuestos que deberán calibrarse con mediciones del desgaste de las pastillas, y el desempeño predictivo del sistema frente a condiciones reales permanece por validar. Como trabajo futuro se plantea incorporar dichas mediciones, evaluar el error de predicción y la tasa de falsas alertas durante un período de operación efectivo, y avanzar hacia una sombra digital mediante la captura automática de datos. En conjunto, la investigación sugiere que la adopción del mantenimiento predictivo puede iniciarse en contextos de recursos limitados mediante el aprovechamiento sistemático de la información operacional disponible.

REFERENCIAS

[1] Feng Q, Zhang Y, Sun B, Guo X, Fan D, Ren Y, et al. Multi-level predictive maintenance of smart manufacturing systems driven by digital twin: A matheuristics approach. J Manuf Syst. 1 de junio de 2023;68:443-54. doi:10.1016/j.jmsy.2023.05.004

[2] Giannoulidis A, Gounaris A. A context-aware unsupervised predictive maintenance solution for fleet management. J Intell Inf Syst. 2023;60(2):521-47. doi:10.1007/s10844-022-00744-2

[3] Wang C, Fan IS, King S. A Review of Digital Twin for Vehicle Predictive Maintenance System. En: SAE Techni. Paper. SAE International; 2023. doi:10.4271/2023-01-1024

[4] Hiwase SD, Jagtap P. Predictive Maintenance of Automotive Component Using Digital Twin Model. En: SAE Techni. Paper. SAE International; 2022. doi:10.4271/2022-28-0075

[5] Ismail L, Abdelmoti A, Basu A, Berini ADE, Naouss M. A Systematic Review of Digital Twin-Driven Predictive Maintenance in Industrial Engineering: Taxonomy, Architectural Elements, and Future Research Directions. arXiv.org [Internet]. 29 de septiembre de 2025 [citado 26 de mayo de 2026]. Disponible en: https://arxiv.org/abs/2509.24443v1

[6] Dimidov V, Jafarnejad S, Frank R. An Empirical Study on Predictive Maintenance for Component X in Heavy-Duty Scania Trucks. En: 2025 IEEE International Conference on Prognostics and Health Management (ICPHM) [Internet]. 2025 [citado 26 de mayo de 2026]. p. 1-9. Disponible en: https://ieeexplore.ieee.org/document/11061822 doi:10.1109/ICPHM65385.2025.11061822

[7] Kim SW, Kim YS. Two-Stage LightGBM Framework for Cost-Sensitive Prediction of Impending Failures of Component X in Scania Trucks. Comput Mater Contin. 12 de enero de 2026;86(3). doi:10.32604/cmc.2025.073492

[8] Bongards A, Liu X, Beemer M, Gajowski D, Rama N, Shah K, et al. Cloud Based Digital Twin Development for High-Voltage Battery Systems in Commercial Vehicles [Internet]. SAE International; abril de 2025 [citado 26 de mayo de 2026]. Disponible en: https://saemobilus.sae.org/papers/cloud-based-digital-twin-development-high-voltage-battery-systems-commercial-vehicles-2025-01-8214 doi:10.4271/2025-01-8214

[9] Eddy CW, Castanier M, Wagner J. Predictive Maintenance of a Ground Vehicle Using Digital Twin Technology - Journal Article [Internet]. 9 de abril de 2024 [citado 26 de mayo de 2026]. Disponible en: https://saemobilus.sae.org/articles/predictive-maintenance-a-ground-vehicle-using-digital-twin-technology-2024-01-2867 doi:10.4271/2024-01-2867

[10] Ma S, Flanigan KA, Bergés M. State-of-the-art review and synthesis: A requirement-based roadmap for standardized predictive maintenance automation using digital twin technologies. Adv Eng Inform. 1 de octubre de 2024;62:102800. doi:10.1016/j.aei.2024.102800

[11] Borisenko A. Enhancement of the maintenance and repair system for haul trucks in cold regions using a digital twin of the transportation enterprise. Archit Constr Transp. 1 de diciembre de 2024;0:88-97. doi:10.31660/2782-232X-2024-4-88-97

[12] Hernández-Sampieri R, Mendoza Torres CP. Metodología de la investigación: las rutas cuantitativa, cualitativa y mixta. Ciudad de México: McGraw-Hill Interamericana; 2018.

[13] Kritzinger W, Karner M, Traar G, Henjes J, Sihn W. Digital Twin in manufacturing: A categorical literature review and classification. IFAC-PapersOnLine. 2018;51(11):1016-22. doi:10.1016/j.ifacol.2018.08.474