

DESARROLLO DE SISTEMA INTELIGENTE PARA LA GENERACIÓN DE ESCENARIOS DE MANTENIMIENTO

Fecha de recepción: 28 de diciembre de 2020

Fecha de aceptación: 29 de febrero de 2021

Sr. Diabb L. Zegpi Delgado.¹
TCL. Héctor R. Reyes Campaña²

Resumen: La División Mantenimiento (DIVMAN) por medio de su Departamento de Ingeniería, Investigación y Desarrollo (DI2D) se encuentra desarrollando una herramienta que permita generar escenarios de mantenimiento, con una incertidumbre medible, para solucionar problemáticas relacionadas con la demanda de mantenimiento. Este estudio propone un sistema inteligente basado en aprendizaje automático para predecir costos de Mantenimiento Recuperativo Básico (MRB) por escenario, donde los datos para el entrenamiento y prueba del modelo son Solicitudes Internas de Compra (SIC) obtenidas del Sistema de Información para la Gestión Logística del Ejército (SIGLE). Se entrenó un modelo mixto para detección de anomalías y predicción de costos, con los algoritmos STL y Random Forests, respectivamente, desarrollados con el lenguaje de programación R. Para complementar la predicción, se ajusta un modelo estocástico con distribución Weibull, el cual simula las condiciones iniciales para la predicción basándose en simulación Monte Carlo. Los resultados son alentadores, porque el sistema inteligente predice escenarios de costos anuales con error estándar equivalente a $\pm 0,02$ veces el costo anual medio de mantenimiento.

Palabras clave: aprendizaje automático, detección de anomalías, mantenimiento recuperativo básico, simulación.

DEVELOPMENT OF AN INTELLIGENT SYSTEM FOR MAINTENANCE SCENARIOS GENERATION

Abstract: The Maintenance Division (DIVMAN) through its Engineering, Research and Development Department (DI2D) is developing a tool that allows generating maintenance scenarios, with measurable uncertainty, to solve problems related to maintenance demand. This study proposes an intelligent system based on machine learning to predict costs of Basic Recuperative Maintenance (MRB) by scenario, where the data for model training and testing are Internal Purchase Requests (SIC) obtained from the Army's Information System for Logistics Management (SIGLE). A mixed model was trained for anomaly detection and cost prediction, with the STL and Random Forests algorithms, respectively, developed with the R programming language. To complement the prediction, a stochastic model with Weibull distribution is fitted, which simulates the initial conditions for the prediction based on Monte Carlo simulation. The results are that the intelligent system predicts annual cost scenarios with a standard error equal to ± 0.02 times the mean.

KEY WORDS: machine learning, anomaly detection, basic recuperative maintenance, simulation.

¹ Ingeniero Civil Industrial; Ejército de Chile. División de Mantenimiento (DIVMAN). Departamento de Ingeniería, Investigación y Desarrollo (DI2D). Santiago, Chile. E-mail: diabluis@gmail.com. ORCID: <https://orcid.org/0000-0002-1091-1831>

² Ingeniero Politécnico Militar en Sistemas de Armas, mención Mecánico. Magíster en Gestión de Activos y Mantenimiento de la Universidad Técnica Federico Santa María. Doctor en Ingeniería de la Universidad de Nottingham, Reino Unido. Jefe del Departamento de Ingeniería, Investigación y Desarrollo (DI2D) de la División de Mantenimiento (DIVMAN), Ejército de Chile. E-mail: hector.reyes@ejercito.cl. ORCID: <https://orcid.org/0000-0001-6941-8198>

1. INTRODUCCIÓN

La Jefatura de Mantenimiento (JEFMAN), dependiente de la División de Mantenimiento (DIVMAN), está encargada de gestionar las Solicitudes Internas de Compra (SIC) emitidas por la totalidad de las Unidades de Mantenimiento del Ejército de Chile. La causa raíz de las solicitudes mencionadas es la falla de un activo de defensa, detectada por los operadores de las Unidades Operativas del Ejército. Todas estas fallas componen la categoría de Mantenimiento Recuperativo Básico Conservativo (MRBC). Las SIC son registradas en la plataforma virtual SIGLE, que es el planificador de recursos empresariales (ERP) del Ejército de Chile, cuyo proveedor es Oracle Corp.

La Figura 1 muestra el flujo de las SIC por MRBC, desde que las generan las unidades de mantenimiento, son informadas al escalón superior a través de SIGLE y las recibe la JEFMAN de la DIVMAN. El personal militar de la DIVMAN está encargado de recopilar las SIC en una Ficha de Fundamento del Gasto (FFG), ajustarla al presupuesto fiscal, presentar esta ficha y velar por que las necesidades de mantenimiento recuperativo de las unidades militares sean solventadas.

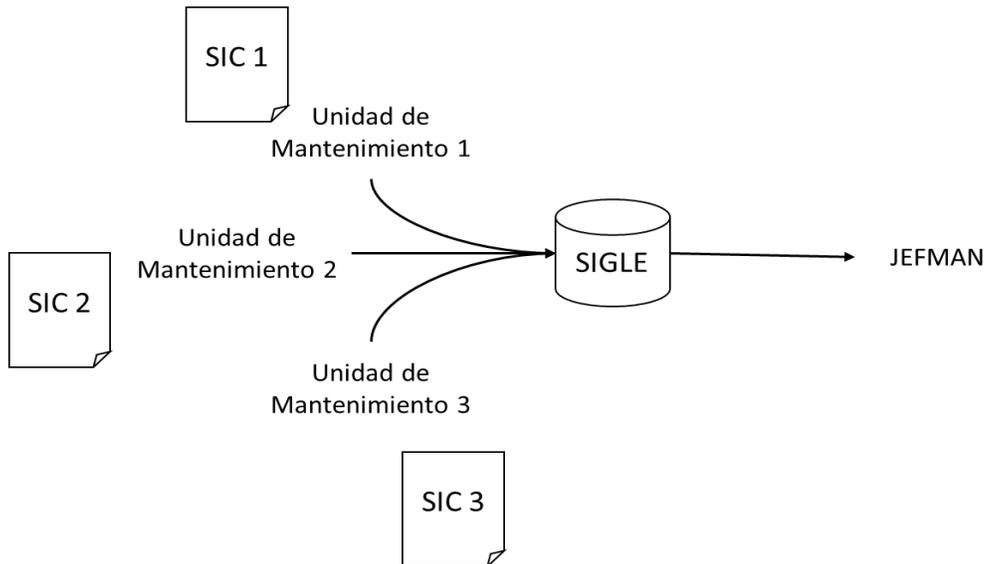


Figura 1: “Diagrama flujo de una SIC por MRBC.”
Fuente: elaboración propia.

El proceso de aprobación de una FFG es un trámite administrativo que puede demorar desde meses hasta años, lo que genera un apremio financiero al interior de la JEFMAN, debido a que se deben costear los requerimientos del presente con los recursos del pasado o, análogamente, los requerimientos de meses o años futuros con los recursos del presente.

La burocracia administrativa obliga a la DIVMAN a anticiparse meses e incluso años a los requerimientos de sus Unidades de Mantenimiento a cargo. La forma tradicional de gestionar múltiples escenarios bajo incertidumbre es mediante el correcto uso de herramientas de ingeniería para el control de gestión, como cartas de control, análisis de sensibilidad y riesgo, o herramientas de estadística clásica y moderna, como análisis de regresión, series de tiempo y estadística bayesiana. Hoy en día, la DIVMAN necesita contar con las herramientas de estadística, clásicas o modernas, para proyectar escenarios de demanda de mantenimiento.

El objetivo de este estudio es proponer una herramienta moderna de predicción para la demanda de MRBC que gestiona la DIVMAN a través de la JEFMAN. Esta herramienta se desarrolla con métodos de aprendizaje automático y es encauzada por la metodología de extracción de conocimiento a partir de bases de datos (KDD). Adicionalmente, esta publicación incluye una revisión bibliográfica que busca obtener información relevante acerca de los enfoques teóricos relacionados al objeto de estudio, de las tendencias y de las perspectivas metodológicas.

1.1. Estado del arte

Las aplicaciones de aprendizaje automático son transversales a todas las áreas del conocimiento, sea salud, mantenimiento, finanzas, entre otras. Los árboles de decisión son modelos de aprendizaje automático de baja complejidad y rápido entrenamiento, cualidad que explotó Tianqi Chen (2016) para introducir los métodos de *ensemble*, dado que combinan predicciones de conjuntos de árboles, obteniendo de esta manera un modelo más robusto y preciso. El principal exponente de los métodos de *ensemble* es *Random Forest* (bosques aleatorios), modelo que se ha vuelto extremadamente popular en la comunidad de practicantes de aprendizaje automático, por su rapidez de entrenamiento, versatilidad para simular multitud de funciones matemáticas, y por su desempeño excepcional, superando a veces a las Redes Neuronales Profundas (DNN).

En 2018, Paolanti y otros investigadores describen una arquitectura de aprendizaje automático para mantenimiento predictivo, basado en el enfoque de conjuntos de árboles. Este enfoque fue probado en la industria, desarrollando una colección de datos y un sistema de análisis con aprendizaje automático. Los resultados del análisis fueron comparados con el desempeño de la herramienta de simulación más usada para el mantenimiento predictivo de motores eléctricos, mejorando la confiabilidad del sistema; los datos fueron recolectados por variedad de sensores.

Bosques aleatorios es un poderoso algoritmo de machine learning con éxito demostrado. Gong *et al.* (2018) desarrollaron un modelo de regresión basado en bosques aleatorios (RFR) para estimar el índice de aspereza internacional (IRI) de pavimentos

flexibles, a partir de medidas de desgaste, tráfico, clima, mantenimiento y datos de estructura. El desempeño del modelo RFR fue comparado con el de un modelo de Regresión Lineal con regularización. Los resultados revelaron que el modelo RFR superó significativamente al modelo de regresión lineal, con un coeficiente de determinación mayor que 0,95 en ambos conjuntos, de entrenamiento y prueba.

Otro algoritmo poderoso es eXtreme Gradient Boosting (XGBoost), perteneciente a la familia de métodos de ensemble, cuya arquitectura es similar al modelo de bosques aleatorios, porque utiliza diversos modelos menos sofisticados para resolver una tarea, agrupa sus predicciones y crea una nueva predicción a partir de éstas. XGBoost tiene la ventaja de no asumir determinación ni independencia, y claramente puede manejar gran cantidad de variables importantes para el mantenimiento (Lim & Chi, 2019).

En la revisión de Bojer y Meldgaard (2020), confirman que en las competencias de pronósticos de Kaggle (plataforma de competencias de inteligencia artificial), los modelos de ensemble (XGBoost, bosques aleatorios y sus variantes) que usan aprendizaje cruzado tienden a superar a los modelos locales de series de tiempo, y que tanto XGBoost como las redes neuronales son métodos poderosos para producir pronósticos.

De acuerdo a Boussabaine y Kirkham (2004), la capacidad de predecir con exactitud los costos de mantenimiento puede proveer una herramienta esencial para la gestión durante las etapas operacionales de un negocio. Los investigadores recopilaron técnicas y métricas usadas para predecir costos, con el objeto de proponer un enfoque innovador, basado en simulación, para el modelamiento de los costos de mantenimiento de los edificios deportivos de localidades del Reino Unido. El estudio presenta una comparación entre métodos de regresión lineal simple y regresión no lineal múltiple, análisis de falla integrada, modelos de teoría de lógica difusa y técnicas de inteligencia artificial. Estas últimas superaron el desempeño de los modelos predecesores, pero prevaleció el problema de determinar la incertidumbre del modelo. Con el fin de superar el obstáculo mencionado, se aplicaron modelos Markovianos, obteniendo estimaciones satisfactorias de la incertidumbre, pero estos modelos fallan al no incorporar específicamente los costos de mantenimiento, lo que es un factor determinante para la toma de decisiones.

Una forma de incorporar los costos de mantenimiento es usando algoritmos de aprendizaje automático. Ibrahim y Khatib (2017) exploraron los beneficios de utilizar modelos de bosques aleatorios y los criterios de impureza para discriminar atributos importantes. Sin embargo, la omisión de hiperparámetros en su explicación denota que su trabajo no considera los avances más recientes en optimización por métodos de *grid search*. Un año después (2018), Quiroz et al. proponen un nuevo enfoque para diagnosticar fallas en barras de rotor usando Random Forests. Como resultado, obtuvieron métricas de

precisión excepcionales, de 98,8% y 98,4% para dos modelos con diferentes atributos, calibrados de acuerdo al criterio de impureza de Gini.

Ninguno de los trabajos mencionados presenta un caso de uso de técnicas de aprendizaje automático/simulación a la industria militar. Este hecho permite a Sharma, Kulkarni y Yadav (2017) introducir una novedad: “modificar el proceso de simulación y optimización con algoritmos genéticos para abordar el *modus operandi* exacto que emplea el Ejército para desarrollar equipamiento para la paz, ejercicios de entrenamiento y la guerra, separadamente.” (Sharma, Kulkarni & Yadav, 2017). Los autores se refieren a predecir la necesidad por piezas de repuesto como una tarea difícil, pero abordable mediante la utilización de calendarios de períodos de uso de los activos de defensa. Con base a estos períodos, generaron escenarios de duración variable, en los que distintas piezas de repuesto eran requeridas. Para la simulación de escenarios, asumieron que la falla de los componentes sigue una distribución Weibull de dos parámetros. De esta manera pudieron calcular la confiabilidad del sistema en función del tiempo de operatividad de los activos. Los autores concluyen que el mejor enfoque para abordar el problema de mantenimiento de activos militares es selectivo, por los períodos de uso intenso seguidos de inactividad que puede sufrir cada activo individual.

Para el caso particular de la DIVMAN y este estudio, se recogen e implementan las ideas de Cardoso *et al.* (2008), debido a la necesidad de generar gigabytes de datos de forma eficiente. Además, se implementó el flujo de trabajo secuencial de la forma simulación-predicción, mejorando la eficiencia de la memoria RAM. El uso de optimización con algoritmos genéticos de Sharma, Kulkarni y Yadav es indicio de carencia de métodos especializados para la optimización de funciones de mantenimiento en la industria militar, dado que “hay evidencia de que los algoritmos genéticos no garantizan una solución óptima” (Sivanandam & Deepa, 2008). Este estudio propone resolver la simulación de escenarios de mantenimiento mediante la conexión en serie de un modelo de simulación Monte Carlo y un modelo regresor de bosques aleatorios.

2. DESARROLLO

El sistema inteligente en cuestión se compone por dos modelos complementarios: un modelo de predicción y un modelo de simulación. Como muestra la Figura 2, el modelo de simulación genera datos de escenarios de mantenimiento y es ajustable de acuerdo al criterio de un usuario experto; el modelo de predicción utiliza estos escenarios como *inputs* y produce predicciones de costos por escenario.

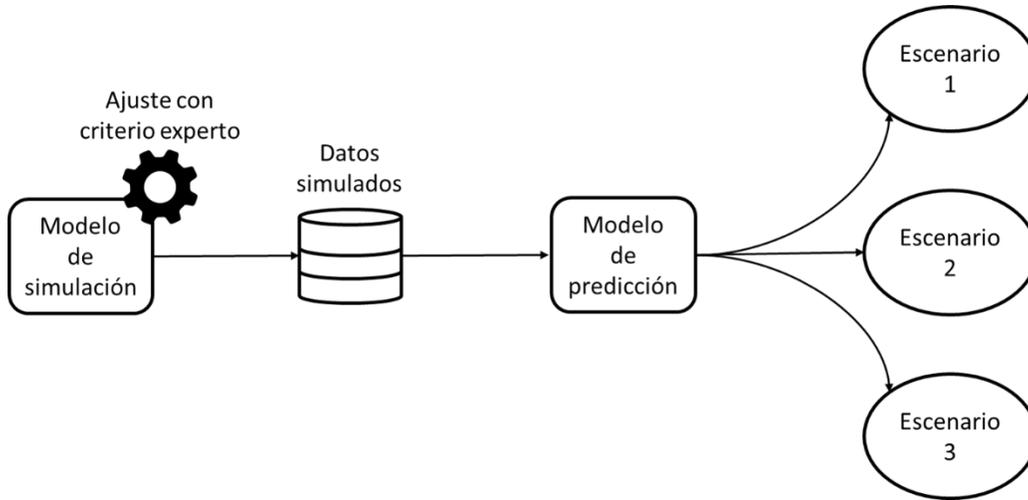


Figura 2: “Integración del sistema inteligente.”

Fuente: elaboración propia.

Ambos modelos (simulación y predicción) se ajustan a los datos de SIC obtenidas de SIGLE, por ende, se comienza mostrando la estructura de los datos. Después, los datos son preparados para la minería de datos. Posteriormente, se procede a aplicar técnicas de *selección y transformación de atributos*, *afinación de hiperparámetros* y aprendizaje automático en un proceso iterativo, hasta alcanzar un desempeño satisfactorio (Figura 3). Por último, se desarrolla un modelo de simulación con Monte Carlo, en el que se establecen las condiciones iniciales para generar escenarios de MRBC. La composición del sistema inteligente consiste en la integración en serie de los dos modelos, tal que se predicen los costos de escenarios generados bajo condiciones conocidas y controladas. Este método es eficiente porque resume los escenarios simulados en una predicción, liberando el espacio en la memoria RAM que ocupan las simulaciones. Además, las simulaciones son conducidas con computación paralela en una computadora cuyo procesador tiene 8 núcleos, lo que reduce los tiempos de cómputo hasta por un factor de 3.

La metodología empleada es el proceso *Knowledge Discovery from Databases* (KDD), para extraer conocimiento de conjuntos de datos.

Análisis de datos, gráficos y aprendizaje automático se desarrollan en el lenguaje de programación R en su versión 4.0.3 (10-10-2020) y el IDE RStudio versión 1.3.1093. Los paquetes que se utilizan son: tidyverse; tidymodels; lubridate; scales; patchwork; univariateML; furrr; janitor; skimr; anomalize.

Debido al carácter confidencial de los datos del Ejército de Chile, las tablas y figuras de esta publicación contendrán datos estimados y ponderados, que permitan demostrar la potencialidad del modelo.

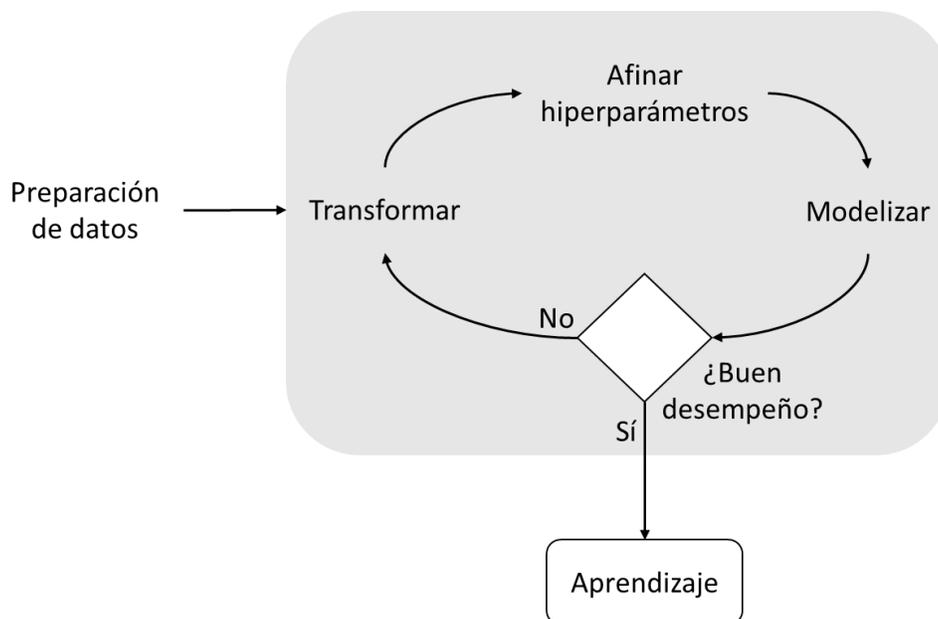


Figura 3: “Proceso iterativo de minería de datos.”
Fuente: elaboración propia.

2.1. Estructura de datos: SIC

SIGLE dispone el reporte de SIC en forma tabular; cada fila es un artículo/servicio que la Unidad Militar solicita, y cada columna es un atributo de la solicitud. La tabla N°1 provee una demostración sintética de los datos.

Fecha	N° SIC	Descripción	Cantidad	Precio unitario (\$)
26-10-2018	161.185	Perno del paquete de resorte	2	25.000
26-10-2018	161.185	Amortiguadores traseros	2	230.000
07-11-2018	162.198	Servicio de alineación vehículo campaña	1	350.000
10-12-2018	166.084	Batería vehicular 12volt 120 ah	2	195.000

Tabla 1: “Ejemplo de reporte SIGLE de SIC.”
Fuente: elaboración propia.

El reporte contiene datos de tipo numéricos, categóricos y fechas. El análisis exploratorio de los datos evidencia errores en los registros, columnas incompletas y otras

características que introducen ruido a los modelos de aprendizaje automático. Por esta razón, es necesario preparar el conjunto de datos.

2.2. Preparación de datos

El tratamiento de los datos de SIC sigue un proceso estándar de limpieza de datos. Las etapas de la limpieza se enumeran a continuación.

- 1) Eliminación de registros y atributos con alta proporción de valores faltantes ($> 60\%$).
- 2) Eliminación de atributos con varianza igual o cercana a cero.
- 3) Eliminación de atributos con información irrelevante.
- 4) Identificación y tratamiento de valores fuera de rango.
- 5) Detección de incoherencias.
- 6) Imputación de valores faltantes con algoritmo *K-Nearest Neighbors* (KNN).

Como resultado de la preparación de datos, se produce un conjunto de datos en formato largo (una fila por observación; cada columna es un atributo), listo para la minería de datos.

2.3. Minería de datos

El proceso iterativo de la minería de datos inicia con la selección de los atributos del conjunto de datos que poseen mayor poder predictivo, reteniéndolos, y se crean nuevos atributos. A esta subetapa de retener y crear atributos suele encontrarse en la literatura como *ingeniería de características*.

Los modelos de aprendizaje automático usualmente trabajan con variables numéricas y no con categóricas. La codificación de las variables categóricas a numéricas produce que el conjunto de datos se reorganice, pasando de formato largo a formato ancho. Esto implica que el número de columnas aumente y el número de filas disminuya.

Una característica interesante para añadir al modelo, es que aprenda a reaccionar ante eventos poco frecuentes, pero de gran impacto, dado que estos eventos contienen información sobre el riesgo sistémico que existe en el mundo real. Un ejemplo de este tipo de eventos es el “estallido social” de octubre del 2019, cuyo impacto se debe a que provocó la movilización de activos de defensa, desembocando en aumentos sustanciales de los costos por mantenimiento recuperativo. Debido a su escasa frecuencia, un modelo de aprendizaje automático robusto no reconoce patrón alguno en los eventos excepcionales o *anomalías*. Para solucionar este problema y extraer información de las anomalías, se procede a detectarlas con el método de descomposición estacional y de tendencia usando regresión local (STL). La Figura 4 ilustra los resultados de la aplicación de la descomposición temporal STL.

Detección de anomalías con descomposición STL

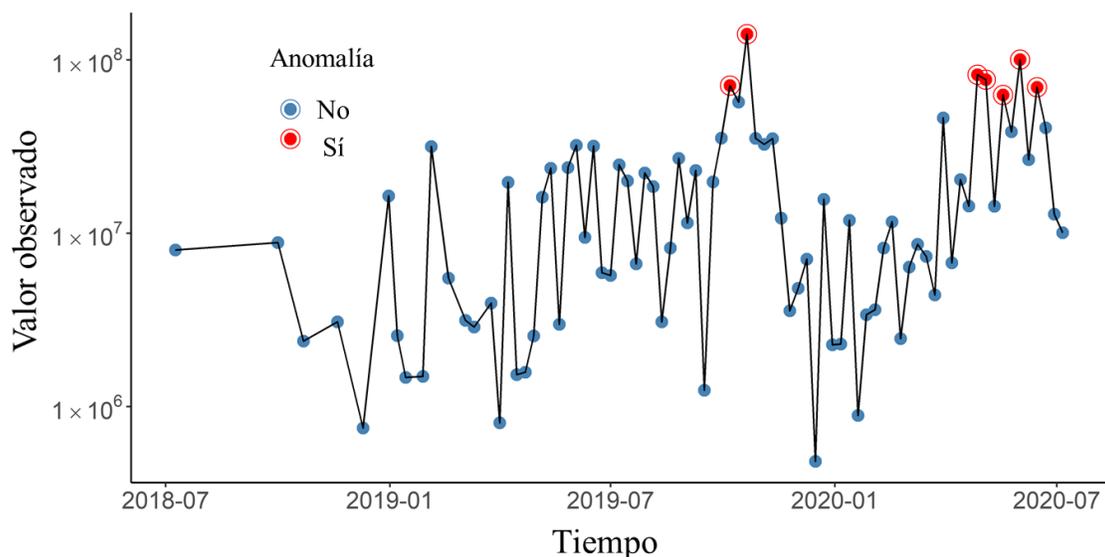


Figura 4: “Detección de anomalías con descomposición temporal STL.”

Fuente: elaboración propia.

Una vez que se estima que el conjunto de datos contiene la información relevante para entrenar a un modelo preciso y robusto, se procede a dividir el conjunto de datos en subconjuntos de entrenamiento y prueba, y ajustar un modelo usando aprendizaje automático al conjunto de entrenamiento. El conjunto de prueba se reserva para evaluar el desempeño del modelo finalizado.

El procedimiento de entrenamiento consiste en generar múltiples combinaciones de hiperparámetros, ajustar k modelos a cada combinación y medir su desempeño individual. El desempeño de una combinación de hiperparámetros es la media de los desempeños individuales. La métrica de desempeño a medir es la Raíz del Error Cuadrático Medio (RMSE). Mientras menor sea el RMSE, mejor es el ajuste del modelo.

Los hiperparámetros del modelo de bosques aleatorios son:

- Número de árboles de decisión contenidos en el modelo. El valor de este hiperparámetro se fija en 1.000.
- Número de predictores que son muestreados aleatoriamente en cada división cuando se crean los modelos de árbol de decisión (Mtry).
- Cantidad mínima de datos necesarios para que el nodo de un árbol continúe separándose (Min n).

Para afinar los hiperparámetros del modelo de bosques aleatorios se usan métodos de *grid search* para 200 combinaciones de hiperparámetros, y *10-fold cross validation* como

método de remuestreo. Para cada combinación de hiperparámetros, se ajustan 10 modelos, cuyas métricas de desempeño referenciales se ilustran en la Figura 5. Cada punto del gráfico representa el desempeño medio de 10 modelos para una configuración de hiperparámetros determinada. La mejor combinación para el modelo final es el punto más cercano al eje horizontal, es decir, con menor RMSE.

Una vez que la mejor combinación es elegida, corresponde validar el modelo mediante la evaluación de su desempeño en el conjunto de prueba. Se comparan los datos observados del conjunto de prueba con las predicciones del modelo para este mismo conjunto, cometiendo un error de $\pm 7\%$. Dado que no hay precedente en la JEFMAN para efectuar una comparación, el modelo de predicción establece un marco de referencia para trabajos posteriores con aprendizaje automático.

Resultado de afinación de hiperparámetros para modelos de bosques aleatorios

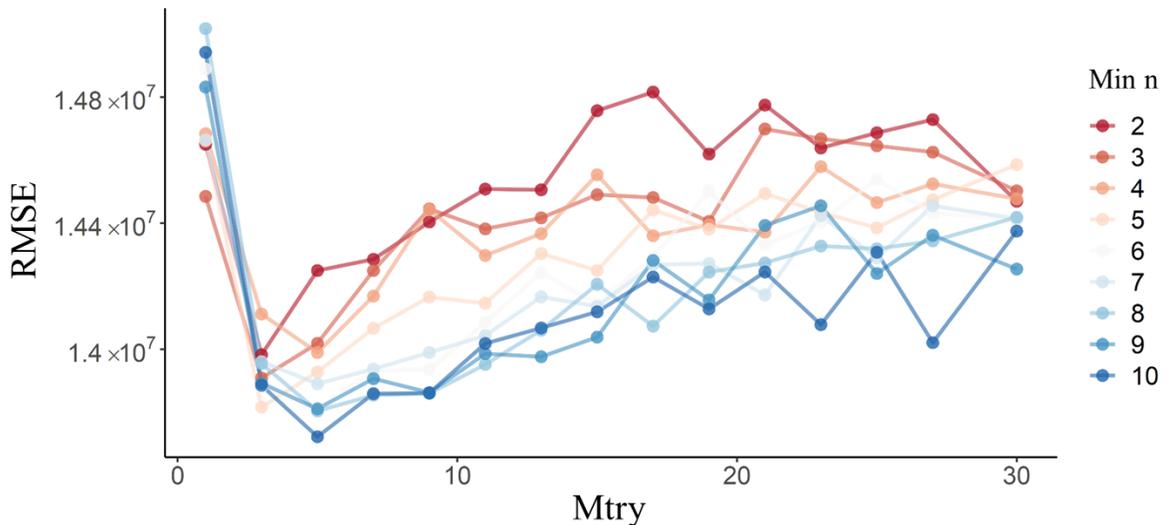


Figura 5: "Ajuste de dos hiperparámetros para Random Forest."
Fuente: elaboración propia.

Para implementar el modelo predictor y producir pronósticos para los costos por MRBC, son necesarios los datos de SIC del período que se desea predecir. Debido a que el reporte SIGLE para períodos futuros todavía no existe, surge la necesidad de una fuente de datos sustituta. Por esta razón, se desarrolla un modelo de simulación Monte Carlo para generar escenarios de mantenimiento.

2.4. Simulación Monte Carlo

Esta etapa del desarrollo consta de dos subetapas: ajuste de un modelo estocástico y análisis de convergencia de la simulación. El modelo de simulación tiene una restricción

importante de carácter computacional: debe simular las mismas variables que usa el modelo de predicción como *input*.

En la Tabla 2 se muestran los 9 mejores ajustes de modelos estocásticos a distribuciones de probabilidad multipropósito. Los parámetros de cada modelo fueron estimados con el *estimador de máxima verosimilitud*. Tanto el Índice de Información de Akaike (AIC) y el Índice de Información Bayesiano (BIC) son interpretaciones diferentes del mismo indicador: la distancia entre el verdadero modelo que subyace en los datos y el modelo propuesto. Aunque existen criterios de información más complejos y específicos, no existe evidencia suficiente de su aplicación a la industria del mantenimiento que justifique su uso. El propósito de esta comparación es elegir el modelo que presente el menor índice.

Modelo	AIC	BIC
<i>Weibull</i>	818,4097	823,1986
<i>Log-normal</i>	820,0192	824,8081
<i>Gamma</i>	820,6250	825,4139
<i>Exponencial</i>	829,5348	831,9292
<i>Weibull inversa</i>	837,9313	842,7202
<i>Gaussiana inversa</i>	838,2192	843,0081
<i>Beta prima</i>	842,4531	847,2420
<i>Gamma inversa</i>	848,3012	853,0901
<i>Rayleigh</i>	1.041,5399	1.043,9343

Tabla 2: "Comparación de ajustes por índice de información."

Fuente: elaboración propia.

De acuerdo a los criterios de información AIC y BIC, el modelo que mejor se ajusta a los datos es un modelo Weibull, con parámetros de escala y forma $\alpha = 50,64$ y $\beta = 0,75$, respectivamente. Aun así, las diferencias de los criterios de información son pequeñas entre los dos primeros modelos, Weibull y Log-normal. Por ende, se procede a realizar una comparación gráfica de los ajustes.

La Figura 6 ilustra cómo se ajustan los modelos Weibull y Log-normal a las distribuciones de densidad (A) y densidad acumulada (B) de los datos. En el gráfico A de la

Figura 6 se observa que el modelo Log-normal tiene más curvatura negativa, lo que indica que la cola de la distribución Log-normal es más gruesa que la cola de la distribución Weibull. Si esta última afirmación se correspondiera con el fenómeno de estudio “Cantidad de SIC por semana”, implicaría que el 5% de las semanas habría más de 305 SIC. Sin embargo, la verdadera distribución de los datos indica que el 5% de las semanas presentan más de 194 SIC. Por otra parte, el modelo Weibull se aproxima mucho más a la realidad, indicando que el 5% de las semanas la cantidad de SIC es superior a 218.

El gráfico B sugiere que el modelo Weibull se aproxima mejor a la distribución de densidad acumulada de la variable de estudio, Cantidad de SIC por semana.

Comparación de ajustes por Método de Máxima Verosimilitud para dos modelos estocásticos

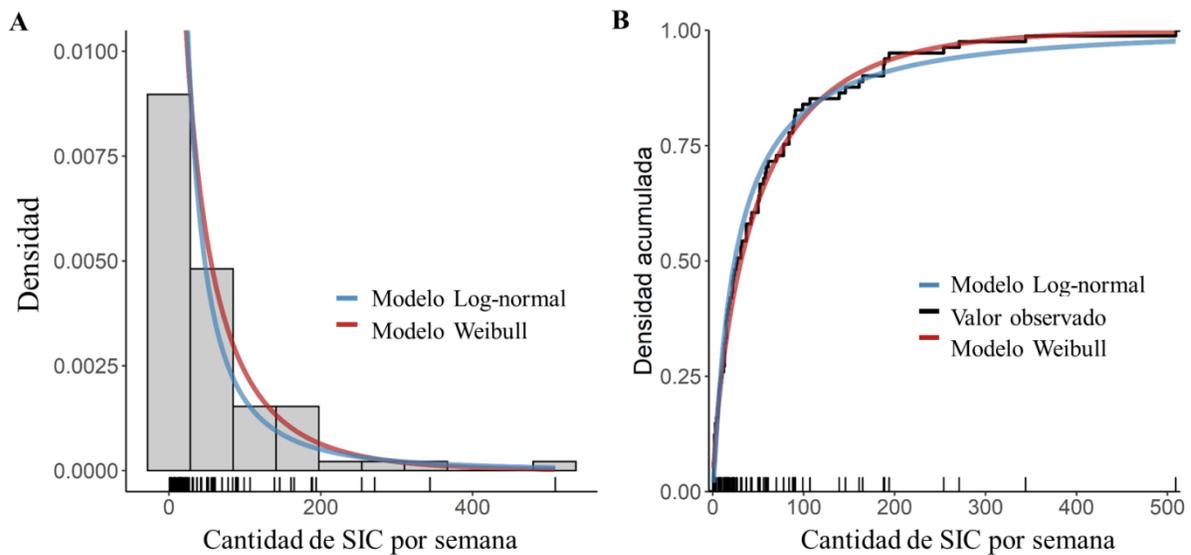


Figura 6: "Gráficos de densidad teórica versus observada."

Fuente: elaboración propia.

Se concluye que el modelo Weibull se ajusta mejor a la distribución de los datos y será el modelo utilizado para el desarrollo del modelo de simulación. Usando bootstrapping paramétrico, se obtiene el intervalo de confianza del 95% para los parámetros estimados:

$$\alpha \in [38,58 ; 63,75] \quad , \quad \beta \in [0,65 ; 0,87] \quad ,$$

Con potencia estadística $\frac{L(\theta)_{Weibull}}{L(\theta)_{Log-normal}} = 2,2360$.

En otras palabras, la evidencia respalda 2,2 a 1 que el modelo Weibull se ajusta mejor a los datos. Posteriormente y debido a que el período de entrenamiento del modelo es superior a un año, se establece el supuesto de que cada atributo aparece en una proporción constante. Esta conjetura permite simplificar la determinación de los coeficientes de cada

atributo en el modelo de simulación. De esta manera, el coeficiente paramétrico de simulación para cada variable equivale a la proporción que representa esta variable en el conjunto de datos.

Para analizar la convergencia de la simulación, se examinan las predicciones para cada escenario generado. La simulación se conduce para tamaños de muestra incrementales, iniciando en 200 y aumentando en 200, hasta llegar a 10.000. Después, se calcula el intervalo de confianza para la predicción media anual. El objetivo de esta etapa es descubrir cuál es el tamaño de muestra para un error estándar determinado.

La Figura 7 muestra tres aristas del análisis de convergencia, desagregadas por gráfico:

- A. El primer gráfico muestra un intervalo del 95% para la predicción media anual de los costos por concepto de mantenimiento recuperativo. La media muestral \bar{X} (línea puntuada roja) es \$1.040 millones de pesos, con intervalo de confianza para $\mu \approx 1040 \pm 3,56$ millones de pesos. La cantidad de simulaciones más grande para la que la predicción está fuera del intervalo es $n = 1300$.
- B. La asimetría del gráfico de densidad sugiere una distribución normal bimodal. La cola izquierda de la distribución fue generada por la variabilidad asociada a los primeros ensayos, de menos de 600 réplicas.
- C. El gráfico de error estándar muestra que, para tener un error de $0,01\bar{X}$ hacen falta 1.400 simulaciones.

Análisis de convergencia de la simulación Monte Carlo

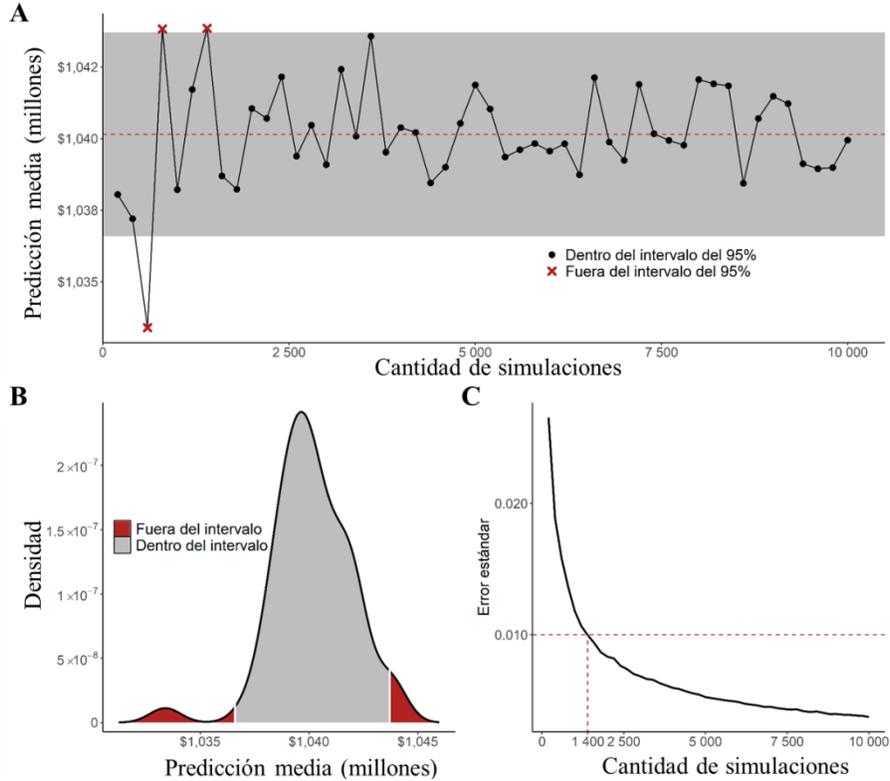


Figura 7: "Gráficos de convergencia de simulación Monte Carlo."

Fuente: elaboración propia.

Del análisis de convergencia se concluye que 1.400 simulaciones son suficientes para generar escenarios de mantenimiento confiables, con 1% de margen respecto al verdadero costo medio.

En la implementación del sistema inteligente, se explorarán alternativas con menos de 1.400 simulaciones, con el fin de reducir costos computacionales y dotar de rapidez al proceso de generar y comparar escenarios. La disminución en la precisión de las predicciones causada por disminuir la cantidad de simulaciones es aceptable hasta $0,04 \bar{X}$, conforme a lo manifestado por la DIVMAN, de acuerdo a estimaciones de años anteriores.

3. CONCLUSIONES

El sistema propuesto cumple con el objetivo de generar predicciones con incertidumbre medible, por lo tanto, se comprueba la factibilidad de la implementación de técnicas de aprendizaje automático para satisfacer las necesidades de la función de mantenimiento de la DIVMAN. Para conseguir desarrollar la herramienta de predicción, se recurrió a una metodología generalizada para la minería de datos (proceso KDD). El flujo

de trabajo y los algoritmos utilizados en este estudio, tienen aplicabilidad en todas las funciones de logística del Ejército que utilicen SIGLE como fuente de datos.

Bosques aleatorios es un algoritmo que ha existido por más de 20 años, y la revisión literaria confirma la versatilidad que tiene para ajustarse a usos diversos en variedad de industrias, por lo tanto, las predicciones generadas difícilmente serán insatisfactorias en el escenario actual, en el que no existe una herramienta semejante a disposición de la DIVMAN. Por esta razón, la confiabilidad de la predicción entregada por el sistema inteligente, dependerá de la calidad de los datos entregados por el modelo de simulación. Para que el sistema sostenga pronósticos confiables en el tiempo, el modelo de simulación debe ser actualizado y mejorado.

Alternativas para mejorar el modelo de simulación son: pronóstico de variables predictoras con modelos de series de tiempo; utilización de variables “retrasadas” para el ajuste del modelo predictor (este enfoque no usaría simulación); tratamiento de anomalías y predicción de costos como modelos paralelos en lugar de mixto.

Para que la utilización de técnicas más poderosas y sofisticadas (por ejemplo: Redes Neuronales Profundas, DNN) tenga éxito, debe existir significativa cantidad de datos, dado que estos algoritmos superan a los métodos de *ensemble* cuando el volumen de datos está en el orden de los millones de registros. Esta condición no se cumple en el contexto de este estudio, por lo que el uso de DNN se considera inadecuado e impráctico.

Con este trabajo culmina el desarrollo de un sistema inteligente para la predicción de costos. El próximo paso es diseñar un flujo de trabajo para que el modelo se reentrene con datos recientes, mediante una integración con SIGLE o la Intranet del Ejército.

Finalmente, es menester mencionar que este estudio aporta un precedente para la predicción de costos en la DIVMAN, que servirá como marco de referencia para la validación de modelos futuros.

BIBLIOGRAFÍA

- Bojer, C. S., & Meldgaard, J. P. (2020). Kaggle forecasting competitions: An overlooked learning opportunity. *International Journal of Forecasting*.
- Boussabaine, A. H., & Kirkham, R. J. (2004). Simulation of maintenance costs in UK local authority sport centres. *Construction Management and Economics*, 22(10), 1011-1020.
- Cardoso, J. B., de Almeida, J. R., Dias, J. M., & Coelho, P. G. (2008). Structural reliability analysis using Monte Carlo simulation and neural networks. *Advances in Engineering Software*, 39(6), 505–513.
- Chen, T., & Guestrin, C. (2016, August). Xgboost: A scalable tree boosting system. In *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining* (pp. 785-794).
- Gong, H., Sun, Y., Shu, X., & Huang, B. (2018). Use of random forests regression for predicting IRI of asphalt pavements. *Construction and Building Materials*, 189, 890-897.
- Ibrahim, I. A., & Khatib, T. (2017). A novel hybrid model for hourly global solar radiation prediction using random forests technique and firefly algorithm. *Energy Conversion and Management*, 138, 413–425.
- Lim, S., & Chi, S. (2019). Xgboost application on bridge management systems for proactive damage estimation. *Advanced Engineering Informatics*, 41, 100922.
- Paolanti, M., Romeo, L., Felicetti, A., Mancini, A., Frontoni, E., & Loncarski, J. (2018, July). Machine learning approach for predictive maintenance in industry 4.0. In *2018 14th IEEE/ASME International Conference on Mechatronic and Embedded Systems and Applications (MESA)* (pp. 1-6). IEEE.
- Quiroz, J. C., Mariun, N., Mehrjou, M. R., Izadi, M., Misron, N., & Mohd Radzi, M. A. (2018). Fault detection of broken rotor bar in LS-PMSM using random forests. *Measurement*, 116, 273–280.
- Sharma, P., Kulkarni, M. S., & Yadav, V. (2017). A simulation based optimization approach for spare parts forecasting and selective maintenance. *Reliability Engineering & System Safety*, 168, 274–289.
- Sivanandam, S. N., & Deepa, S. N. (2008). Genetic algorithms. In *Introduction to genetic algorithms* (pp. 15-37). Springer, Berlin, Heidelberg.