
PRONÓSTICO DE LA DEMANDA INTERMITENTE DE REPUESTOS AERONÁUTICOS MEDIANTE MÉTODOS CLÁSICOS ESTADÍSTICOS Y MODELOS LINEALES DINÁMICOS.

FORECASTING DEMAND FOR AERONAUTICAL SPARE PARTS USING EXPONENTIAL SMOOTHING, CROSTON METHODS, BOOTSTRAP SIMULATIONS AND DYNAMIC LINEAR MODELS.

Cristian Esteban Rivas Alarcón.^a
cristianrivas@usantotomas.edu.co

Wilmer Pineda Ríos.^b
wilmerpineda@usantotomas.edu.co

Resumen

La aviación militar es fundamental para el cumplimiento del Orden Constitucional y los fines del Estado, es por esto, que se deben centralizar esfuerzos para garantizar la disponibilidad, seguridad y fiabilidad de las aeronaves, por tal motivo, este estudio, buscó implementar metodologías estadísticas a través de métodos clásicos de pronóstico, simulaciones bootstrapping y modelos lineales dinámicos para generar un pronóstico en la demanda de repuestos aeronáuticos con características de intermitencia y variabilidad y de esta manera contribuir a la mejora continua en los procesos logísticos de la administración aeronáutica. Dentro de los métodos clásicos de pronósticos, se usó la familia de suavización exponencial (Croston, Aproximación Syntetos-Boylan), simulaciones bootstrapping y modelo lineal dinámico polinomial de primer orden, el error cuadrático medio (RMSE) y error absoluto medio (MAE) fueron utilizados para comparación y selección del mejor modelo, arrojando como resultado que el modelo lineal dinámico tiene un mejor desempeño en comparación con los demás.

-

Palabras clave: (Aviación Militar, Confiabilidad, Croston, Demanda intermitente, Modelos lineales dinámicos, Simulaciones BOOTSTRAP).

^aEstudiante

^bDirector

Índice

1	INTRODUCCIÓN	5
2	MARCO TEÓRICO REFERENCIAL	6
2.1	Confiabledad aeronáutica	6
2.2	Método clásico de suavizamiento exponencial	8
2.3	Método de Croston	9
2.4	Método de Syntetos and Boylan	10
2.5	Modelos Bootstrap	10
2.5.1	Familia de modelos de suavización exponencia	11
2.5.2	Transformación de BOX-COX	11
2.5.3	Descomposición de la serie de tiempo	11
2.5.4	Bootstrap a los residuales	12
2.5.5	Algoritmo Método Bagging Exponential Smoothing	13
2.6	Modelos lineales dinámicos	13
2.6.1	Estimación y predicción	14
2.6.2	Modelo polinomial dinámico de primer orden	15
2.6.3	Modelo lineal dinámico Generalizado Poisson de primer orden	16
3	METODOLOGÍA	16
3.1	Tipo de Investigación	16
3.1.1	Diseño de investigación no experimental	16
3.1.2	Localización del estudio	17
3.1.3	Población de estudio	18
3.1.4	Recolección de datos	18
3.2	Variables de estudio	19
4	DESARROLLO	20
4.1	Gestión de la información	20
4.1.1	Procesamiento de lenguaje natural para clasificación sistema aeronáutico	20
4.2	Análisis de la información	24
4.3	Identificación de los modelos	28
4.3.1	Criterios de evaluación del modelo	29
5	DISCUSIÓN DE RESULTADOS	30
6	BIBLIOGRAFÍA	31
7	ANEXOS	33
7.1	Programas	33
7.2	Codificación JAGS	37

Índice de figuras

1	Helicóptero HUEY en vuelo, Fuente propia.	5
2	Flujograma de un sistema de confiabilidad, Fuente: [Bugaj, 2012].	8
3	Descomposición serie de tiempo, Fuente: [Bergmeir et al., 2016].	12
4	Territorio Colombiano, Fuente: [Cancillería de Colombia, 2022].	17
5	Registro de falla, Fuente: libro de vuelo de una aeronave HUEY.	18
6	Reporte sin procesamiento.	21
7	Longitud de textos sin procesamiento.	21
8	Nube de palabras sin procesamiento.	22
9	Longitud de textos procesados.	22
10	Nube de palabras con procesamiento.	23
11	Word embedding de 9 palabras representativas para los sistemas de comunicación JASC 23, motor JASC 72 y navegación JASC 34.	23
12	Pareto sistemas helicópteros HUEY II.	25
13	Serie de 01 repuesto del sistema de navegación y sus modelos	29

Índice de cuadros

1	Variables de estudio.	19
2	Codificación JASC del sistema 21 al 33	20
3	Resultados muestra de entrenamiento	24
4	Resultados muestra de validación	24
5	Resultados muestra de entrenamiento con validación cruzada y variación de hiperparámetros	24
6	Sistemas donde se concentra el 80 % de las fallas	25
7	P valores prueba Kolmogorov-Smirnov	26
8	MTBF por aeronave sistema de navegación	27
9	Confiabilidad por sistema	28
10	Resutados RMSE	29
11	Resultados MAE	30
12	Codificación JAGS	37

1. INTRODUCCIÓN

La Confiabilidad Aeronáutica es una herramienta muy valiosa para los operadores aéreos ya que, a través de la medición del desempeño de los sistemas en las aeronaves e identificación de los componentes que presentan mayor cantidad de fallas y tiempos de parada, permite mejoras en cuanto a costos y tiempos, es por esto, que inicialmente este trabajo detectó los sistemas y componentes con menor confiabilidad en una flota de 28 helicópteros utilitarios UH-1H HUEY, los cuales desempeñan misiones de transporte, evacuaciones aeromédicas, abastecimientos entre otras, durante un periodo analizado del año 2010 al 2021 y posterior a esto, se propusieron modelos de pronóstico de fallas y demanda de repuestos asociados a estas fallas.



Figura 1: Helicóptero HUEY en vuelo, Fuente propia.

La Fuerza Aérea Colombiana dentro de sus políticas institucionales [Fuerza Aérea Colombiana, 2020], en el proceso de gestión de la ciencia, tecnología e innovación, tiene la necesidad de desarrollar proyectos para cumplir la misión y avanzar tecnológicamente. En contraste con esto y analizando las fallas, la gestión de inventarios y rotación de los componentes aeronáuticos, se puede evidenciar un gran número de repuestos aeronáuticos con una rotación nula, lo cual genera una acumulación de stock y aumento de costos en los almacenes, ocasionando que gran parte del inventario sea un producto obsoleto.

Una buena gestión en la administración del mantenimiento aeronáutico, tiene como resultado el seguimiento a la rotación de inventarios, ya que permite asegurar el abastecimiento de repuestos y suplir la demanda de repuestos para las aeronaves, esta poca rotación de inventarios y la disminución del tiempo medio entre fallas (MTBF) en sus siglas en inglés Mean Time Between Failure, es ocasionada por el aumento de fallas en los componentes, y en consecuencia a esto, presenta una demanda de repuestos aeronáuticos, lo cual a su vez genera tiempos de parada altos y aeronaves en tierra (AOG) en sus siglas en inglés Aircraft On Ground, afectando directamente la disponibilidad de las aeronaves para el cumplimiento de la misión institucional [Fuerza Aérea Colombiana, 2020].

Teniendo en cuenta lo anterior, se establecen metodologías de pronóstico de inventarios para evitar el sobre stock y mantener la demanda de repuestos, entre los métodos propuestos se encuentran: el método clásico de suavizamiento exponencial [Ostertagova and Ostertag, 2011], Método Croston [Croston, 1972], Modificación al método Croston [Syntetos and Boylan, 2005], Métodos Bootstrapping [Snyder, 2002] y Modelos Lineales Dinámicos [Harrison and Stevens, 1976].

Inicialmente se presenta el marco teórico referencial de los modelos aplicados, posterior, la metodología usada, recolección de datos, organización de la información, métodos de pronóstico y por último comparación y discusión de resultados.

Durante el desarrollo del trabajo, en la etapa de organización de la información, se implementó un caso aplicado de clasificación de textos a través de procesamiento del lenguaje natural, el cual permitió contar con la totalidad de los sistemas de las fallas para calcular la *confiabilidad* de los sistemas de las aeronaves, a través de un modelo lineal generalizado mixto con efecto aleatorio.

2. MARCO TEÓRICO REFERENCIAL

La circular informativa No CI-5103-082-17 [Aeronáutica Civil Colombiana, 2010] establece los lineamientos para el control de mantenimiento por métodos de confiabilidad en Colombia, el alcance de esta circular es reconocer la necesidad de adoptar y establecer acciones correctivas y determinar la efectividad de estas acciones. Teniendo en cuenta esto y en alineación con lo establecido en el Reglamento Aeronáutico Colombiano, parte 4 donde se establecen las Normas de Aeronavegabilidad y Operación de aeronaves [Aeronáutica Civil Colombiana, 2019] el desarrollo de esta investigación estará direccionado al pronóstico de fallas y su relación con los repuestos requeridos para la solución de las mismas, esta investigación será abordada mediante metodologías estadísticas de pronóstico de inventarios.

2.1. Confiabilidad aeronáutica

Según [Biryukov, 2019] en su estudio analiza diversas técnicas y algoritmos para determinar el valor cuantitativo de la confiabilidad en un proceso de investigación y desarrollo de productos de aviación, misiles y tecnología aeroespacial, este estudio analiza el desarrollo de la confiabilidad y se ejemplifica en el diseño de un motor de cohete para un funcionamiento sin fallas.

Con el fin de identificar los elementos más críticos y con menor confiabilidad, [Wang et al., 2020] realiza una evaluación del sistema de potencia eléctrica de una aeronave, mediante la función de *confiabilidad*, el cual está dado por $R(t)$, por su sigla en inglés *reliability*, Ahora la probabilidad de que un evento ocurra está dada por la función de distribución de probabilidad $F(t)$:

$$F(t) = \int_0^t f(s)ds,$$

entonces la Confiabilidad $R(t)$ está dada por:

$$R(t) = 1 - F(t) \tag{1}$$

Ahora, se desarrolla la función de confiabilidad (1) mediante la función de densidad de probabilidad de la distribución exponencial (2), dado que se cuenta con las horas voladas en sucesos consecutivos, que en este caso es cada una de las fallas presentadas.

$$f(s) = \lambda e^{-\lambda s}; \quad s > 0 \tag{2}$$

La probabilidad de que este componente funcione, bajo las condiciones de diseño para el cual fue desarrollado durante un tiempo t , está dada por:

$$\begin{aligned} R(t) &= 1 - \int_0^t \lambda e^{-\lambda s} ds \\ &= 1 - [1 - e^{-\lambda t}] \\ &= e^{-\lambda t} \end{aligned} \tag{3}$$

Y función de riesgo o tasa de falla es:

$$\begin{aligned} h(t) &= \frac{f(t)}{R(t)} \\ &= \frac{\lambda e^{-\lambda t}}{e^{-\lambda t}} \\ &= \lambda \end{aligned}$$

Por lo tanto, el desempeño de los sistemas es medido con la ecuación (3), donde λ es la tasa de ocurrencia del evento por unidad de tiempo, es decir, el número de fallas por sistema sobre las horas voladas de las aeronaves, o inversamente llamado MTBF por sus siglas en inglés (Mean Time Between Failure).

$$MTBF = \frac{\text{Horas de vuelo}}{\text{Numero de fallas}}$$

y

$$\lambda = \frac{1}{MTBF}$$

Los equipos aeronáuticos complejos están compuestos por una gran cantidad de partes y conjuntos. Todas esas partes son susceptibles a fallar en un tiempo u otro, sin embargo, algunas fallas tienen más consecuencias que otras dependiendo la clase del producto aeronáutico clase I (Aeronave, motor o hélice), clase II (Componentes cuya falla pueda afectar la seguridad de un producto Clase I) o clase III (Un producto que no es ni clase I o II), [Aeronáutica Civil Colombiana, 2017]. Por lo que, cierto tipo de fallas tienen un efecto directo en la seguridad en vuelo y otras afectan la capacidad operacional del equipo sin afectar la seguridad en vuelo.

Teniendo en cuenta lo anterior, y en concordancia con el desarrollo de un sistema de confiabilidad aeronáutica para las aeronaves [Bugaj, 2012] en su artículo realiza un acercamiento al análisis de fallas y como paso inicial para aplicar un programa de mantenimiento centrado en confiabilidad lo organiza de la siguiente manera:




Figura 2: Flujograma de un sistema de confiabilidad, Fuente: [Bugaj, 2012].

Esta metodología, busca determinar acciones correctivas tendientes a la mejora continua de la aeronave o el componente aeronáutico, tal cual como lo establece la aeronáutica civil en la Circular Informativa No. CI-5103-082-17 [Aeronáutica Civil Colombiana, 2010].

Una vez identificados los componentes o sistemas con menor confiabilidad, es necesario establecer alguna metodología que me permita pronosticar las fallas, así como la demanda de repuestos requeridos para la acción correctiva.

Dado lo anterior, se propone un pronóstico de la demanda intermitente de repuestos usando los siguientes métodos:

1. Método de suavización exponencial [Billah et al., 2006].
2. El método de Croston [Croston, 1972], [Cruz R. and Correa, 2017].
3. El Método de Syntetos y Boylan [Syntetos and Boylan, 2005], modificación al método de Croston.
4. Modelos bootstrap [Willemain et al., 2004].
5. Modelos lineales dinámicos [Valencia Cárdenas et al., 2015].

2.2. Método clásico de suavizamiento exponencial

El método de suavización exponencial es probablemente el mas usado en el sentido de pronosticar el futuro a corto plazo y su objetivo es suavizar la serie original de la misma manera que las demandas promedio y utilizar la serie suavizada para el pronóstico. [Ostertagova and Ostertag, 2011], dada la demanda de repuestos observadas $y_1, y_2, y_3, \dots, y_n$ en los tiempos $t = 1, 2, \dots, n$, la suavización exponencial toma la forma:

$$\hat{y}_{t+1} = \alpha y_t + (1 - \alpha) \hat{y}_t$$

Donde y_t es el valor actual de la demanda de repuestos en el periodo t , $\hat{y}_t$ es el pronóstico de la demanda de repuestos en el periodo t , $\hat{y}_{t+1}$ es el pronóstico de la demanda en el periodo $t+1$ y α es la constante de suavizado, que tiene un valor comprendido entre 0 y 1, aunque en la aplicación real su valor suele variar entre 0.05 y 0.50, en esta escala para valores de alfa pequeños se disminuyen las variaciones de corto plazo asociadas al pronóstico lo cual es razonable cuando la demanda real tiene un comportamiento estable. Sin embargo, si la demanda presenta cambios significativos en el corto plazo nos interesará seguir éstos más de cerca y en ese caso debiéramos seleccionar una constante alfa más grande.

El pronóstico $\hat{y}_{t+1}$ es calculado con la demanda real del periodo actual con un peso α mas el pronóstico en el periodo t con un peso $(1 - \alpha)$.

La constante de suavizado puede tomar un valor entre cero y uno, cuando $\alpha = 1$ el pronóstico en el periodo $t+1$ es igual a la demanda en el periodo t , en el otro extremo, si $\alpha = 0$, el pronóstico en el periodo $t+1$ es el equivalente al pronóstico en el periodo t .

Rescribiendo la ecuación (8) tenemos:

$$\begin{aligned}\hat{y}_{t+1} &= \hat{y}_t + \alpha(y_t - \hat{y}_t) \\ &= \hat{y}_t + \alpha\epsilon_t\end{aligned}\tag{4}$$

donde $\epsilon_t = y_t - \hat{y}_t$ y corresponde al residual del pronóstico.

Sin embargo, este método puede presentar grandes sesgos cuando hay periodos con demandas cero y un incremento en el stock de inventarios, ya que si tenemos una demanda constante por varios periodos de tiempo y de repente se presentan demandas cero en dos o mas periodos, el pronóstico de suavizado sigue generando una demanda de repuestos e incrementando su stock en los inventarios.

2.3. Método de Croston

Uno de los pioneros en establecer un método de pronósticos con periodos de demanda cero fue [Croston, 1972], este método utiliza como base la atenuación exponencial simple, separando la serie de tiempo en dos partes, la primera una serie con valores positivos de demanda y la segunda con los tiempos entre demandas consecutivas no nulas, en cada una se estima la previsión por suavización exponencial y luego se unen los dos valores cuando existe un valor no nulo de la demanda. Entonces si la demanda en el periodo $d_t > 0$, el pronóstico de la demanda no nula $\hat{d}_t$ para el próximo periodo t y el pronóstico del intervalo de la demanda $\hat{n}_t$ siendo estas las dos series de tiempo, presentan la siguiente atenuación exponencial.

$$\begin{aligned}\hat{d}_t &= \hat{d}_{t-1} + \alpha(d_t - \hat{d}_{t-1}) \\ \hat{n}_t &= \hat{n}_{t-1} + \alpha(k - \hat{n}_{t-1}) \\ k &= 1\end{aligned}$$

donde, d_t es la demanda en el periodo t , $\hat{d}_t$ el pronóstico de la demanda no nula para el periodo t , $\hat{n}_t$ el pronóstico del intervalo de demanda no nula, k es el intervalo desde la última demanda no nula y α es el parámetro de atenuación.

Entonces, la demanda promedio estimada en el periodo t es la razón entre $\hat{d}_t$ y $\hat{n}_t$

$$\hat{y}_t = \frac{\hat{d}_t}{\hat{n}_t}\tag{5}$$

Si $d_t = 0$ entonces:

$$\hat{d}_t = \hat{d}_{t-1}$$

$$\begin{aligned}\hat{n}_t &= \hat{n}_{t-1} \\ k &= k + 1\end{aligned}$$

Entonces la demanda promedio estimada para el periodo t está dada por la ecuación (5).

Este método es ampliamente usado y probablemente el más conocido para generar pronóstico en la demanda de repuestos cuando se presentan demandas cero.

2.4. Método de Syntetos and Boylan

La demanda intermitente se presenta esporádicamente para cierto tipo de repuestos lo cual presenta dificultad para su predicción y errores en el pronóstico, por lo cual, representan costos en términos de sobrestock de repuestos y obsolescencia de los mismos, el método simple de suavizado exponencial (SES) es frecuentemente aplicado para hacer frente a la demanda intermitente de repuestos, sin embargo, el método Croston [Croston, 1972] es el método mas usado para este tipo de demanda [Syntetos and Boylan, 2005].

De acuerdo al método croston, separamos las estimaciones de suavizado de la demanda de repuestos (d'_t , $E(d_t) = E(d'_t) = \mu$) y el promedio de los periodos consecutivos con demandas nulas (n'_t , $E(n_t) = E(n'_t) = n$), usando el mismo parámetro α de suavización. El pronóstico y'_t , para el próximo periodo, está dado por la ecuación (5), Entonces el valor esperado para el periodo t esta dado por $E(y'_t) = E(d'_t/n'_t) = E(d'_t)/E(n'_t) = \mu/n$, si hay demandas en todos los periodos el método es el mismo a suavizado exponencial simple.

Sin embargo [Syntetos and Boylan, 2005] mostró que el estimador del método Croston es sesgado, por que se asume que los estimadores del tamaño de la demanda y el tamaño del intervalo son independientes, entonces:

$$E\left(\frac{d'_t}{n'_t}\right) = E(d'_t)E\left(\frac{1}{n'_t}\right)$$

y

$$E\left(\frac{1}{n'_t}\right) \neq \frac{1}{E(n'_t)}$$

Es por esto, que con el fin de disminuir el sesgo, [Syntetos and Boylan, 2005] sugiere una modificación al método Croston, la cual se puede describir como una función de corrección al sesgo con un factor de $\frac{\alpha}{2}$ como se describe en la ecuación (6)

$$\hat{y}_t = \left(1 - \frac{\alpha}{2}\right) \frac{\hat{d}_t}{\hat{n}_t} \quad (6)$$

2.5. Modelos Bootstrap

En el trabajo de [Bergmeir et al., 2016], se plantea un modelo bagging (Bootstrap aggregating) [Breiman, 1996] para modelos de suavización exponencial usando descomposición STL (Seasonal, Trend, Loess) [Cleveland et al., 1990] y Bootstrap de bloques MBB (Moving Block Bootstrap) [Lahiri and Lahiri, 2003] en los residuos de la descomposición y posterior transformación Box-Cox en la serie temporal para datos no estacionarios.

En resumen [Bergmeir et al., 2016], propone aplicar una transformación de Box-Cox para corregir la asimetría de la serie de tiempo, varianzas diferentes o no linealidad a los datos, y de este modo, generar

nuevas series de tiempo que son similares a las series observadas, la serie se descompone en componentes (Descomposición estacional y de tendencias usando LOESS o regresión local). Luego, se realiza un MBB con los residuales, para posterior, agregar la tendencia y los componentes estacionales y por último, invertir la transformación de Box-Cox. De esta manera, genera un aleatorio conjunto de series de tiempo con arranque similares, y para cada una de estas series de tiempo, elige un modelo entre varios modelos de suavizado exponencial, los cuales son comparados utilizando el mejor AIC, luego, los pronósticos puntuales son calculados usando todos los diferentes modelos y los pronósticos resultantes se promedian.

2.5.1. Familia de modelos de suavización exponencia

El suavizado exponencial, divide la serie de tiempo en la tendencia, estacionalidad y el error, por ejemplo, el método aditivo Holt Winters, se define mediante las siguientes ecuaciones:

$$l_t = \alpha(y_t - s_{t-m}) + (1 - \alpha)(l_{t-1} + b_{t-1})$$

$$b_t = \beta(l_t - l_{t-1}) + (1 - \beta)b_{t-1}$$

$$s_t = \gamma(y_t - l_{t-1} - b_{t-1}) + (1 - \gamma)s_{t-m}$$

$$\hat{y}_{t+h} = l_t + hb_t + s_{t-m+h_m}$$

Donde, l_t , b_t y s_t , es el nivel, la tendencia y la estacionalidad en el tiempo t , y_t es el dato observado, α , β y γ son parámetros de suavización, m es la longitud del ciclo estacional y $\hat{y}_{t+h}$ es el pronóstico en el tiempo t con horizonte h .

A través de la familia de modelos de suavización exponencial (ETS) los cuales distinguen, el error (E), tendencia (T) y estacionalidad (S), [Bergmeir et al., 2016] compara 30 modelos de la familia de suavizamiento exponencial [Hyndman et al., 2002], y automáticamente toma el mejor modelo basado en el criterio del mejor AIC o $AICc$.

2.5.2. Transformación de BOX-COX

Esta transformación ayuda a estabilizar la varianza y está definida por:

$$w_t = \begin{cases} \log(y_t), & \lambda = 0; \\ \frac{y_t^\lambda - 1}{\lambda}, & \lambda \neq 0. \end{cases} \quad (7)$$

Dependiendo del λ la transformación es la siguiente:

- La identidad si $\lambda = 1$
- El logaritmo si $\lambda = 0$
- la transformación si $0 < \lambda < 1$

2.5.3. Descomposición de la serie de tiempo

Para la descomposición de una serie de tiempo no estacional, se uso el método (LOESS), el cual esta basado en regresiones locales y descompone la serie en tendencia y lo que queda sin estacionalidad ni tendencia, luego un polinomio de grado 1 es ajustado a la ponderación de cada punto.

Para la descomposición de una serie de tiempo estacional, se uso el método (STL) componentes (Descomposición estacional y de tendencias usando LOESS), el método LOESS es aplicado repetidamente y la serie es dividida en tendencia, estacionalidad y lo que queda sin estacionalidad ni tendencia.




Figura 3: Descomposición serie de tiempo, Fuente: [Bergmeir et al., 2016].

2.5.4. Bootstrap a los residuales

El bootstrap de bloques intenta replicar la correlación volviendo a muestrear bloques de datos en lugar de valores individuales, puede usarse en datos correlacionados con el tiempo ya sea anual, semestral, trimestral etc, [Bergmeir et al., 2016] usa bloques de $l = 8$ para datos anuales y trimestrales, y $l = 24$ para datos mensuales, para capturar cualquier estacionalidad, el bootstrap de bloques fue propuesto por [Liu and Tang, 1996], el cual consiste en remuestrear bloques de observaciones consecutivas en el tiempo. El método procede del siguiente modo [Lahiri, 1993]:

1. Fijar un entero positivo, b , el tamaño del bloque, y tomar k igual al menor entero mayor o igual que $\frac{n}{b}$.
2. Definir los bloques o submuestras, $B_{i,b} = (X_i, X_{i+1}, \dots, X_{i+b-1})$, o B_i , para $i = (1, 2, 3, \dots, q(q = n - b + 1))$.
3. Arrojar k observaciones o bloques $\xi_1, \xi_2, \dots, \xi_k$, con distribución equiprobable sobre el conjunto de posibles bloques $(B_1, B_2, \dots, B_q)$, donde ξ_i es un vector b -dimensional $(\xi_{i,1}, \xi_{i,2}, \dots, \xi_{i,b})$.
4. Donde $\vec{X}$ es el vector formado por las n primeras componentes de $\xi_{1,1}, \xi_{1,2}, \dots, \xi_{1,b}, \xi_{2,1}, \xi_{2,2}, \dots, \xi_{2,b}, \dots, \xi_{k,1}, \xi_{k,2}, \dots, \xi_{k,b}$.

Hay que tener presente que si $b = 1$, entonces $k = n$ y con ello se obtiene un Bootstrap ordinario, pero si $b = n$, entonces $k = 1$ esto hará que tengamos todas las réplicas coincidentes con la muestra o serie original.

2.5.5. Algoritmo Método Bagging Exponential Smoothing

Se aplica la descomposición de Box-Cox a la serie de tiempo, con esto, se tiene la componente de tendencia, estacional e irregular, esta ultima componente se le aplica Bootstrap por bloques luego las otras componentes son agregadas y por último se invierte la transformación de Box-Cox.

El algoritmo del método Bagging Exponential Smoothing presentado por [Bergmeir et al., 2016] está dado por:

```

1: procedure BOOTSTRAP(ts, num.boot)
2:    $\lambda \leftarrow \text{BoxCox.lambda}(\text{ts})$   $\triangleright$  use automatic procedure to determine  $\lambda$ 
3:    $\text{ts.bc} \leftarrow \text{BoxCox}(\text{ts}, \lambda)$ 
4:   if ts is seasonal then
5:      $[\text{trend}, \text{seasonal}, \text{remainder}] \leftarrow \text{stl}(\text{ts.bc})$ 
6:   else
7:      $\text{seasonal} \leftarrow 0$ 
8:      $[\text{trend}, \text{remainder}] \leftarrow \text{loess}(\text{ts.bc})$ 
9:   end if
10:   $\text{recon.series}[1] \leftarrow \text{ts}$   $\triangleright$  add the original series as a sample
11:  for i in 2 to num.boot do
12:     $\text{boot.sample}[i] \leftarrow \text{MBB}(\text{remainder})$ 
13:     $\text{recon.series.bc}[i] \leftarrow \text{trend} + \text{seasonal} + \text{boot.sample}[i]$ 
14:     $\text{recon.series}[i] \leftarrow \text{InvBoxCox}(\text{recon.series.bc}[i], \lambda)$ 
15:  end for
16:  return recon.series
17: end procedure

```

2.6. Modelos lineales dinámicos

Supongamos que consideramos dos variables, en este caso y_t , que es la variable respuesta y se quiere relacionar con una variable x_t que es la variable explicativa, las cuales están medidas secuencialmente en el tiempo.

$$y_t = \beta x_t + \epsilon_t, t = 1, 2, \dots, T$$

Entonces si queremos ajustar un modelo bayesiano, vamos a suponer que hay una distribución previa, la cual expresa toda la información en el parámetro β antes de recibir los datos y queremos aprender sobre este parámetro a nivel secuencial $p(\beta|y_{1:t})$ para realizar pronóstico $p(y_{t+1}|y_{1:t})$, dada toda la información que tengo hasta el tiempo t .

Ahora consideramos que β varía con el tiempo y esto es lo que hace el modelo lineal dinámico, entonces tenemos nuestra ecuación de observación (8), donde ahora el β varía con el tiempo, es decir, la relación

que hay entre y_t y x_t dependen del tiempo y como estoy imponiendo una estructura temporal en β_t , tengo que decidir como será la evolución de la misma.

Ecuación de observación:

$$y_t = x_t \beta_t + \epsilon_t \quad (8)$$

Una manera markoviana de expresar la evolución en el tiempo es con la ecuación del sistema (9):

Ecuación del sistema:

$$\beta_t = \beta_{t-1} + v_t \quad (9)$$

Se asume que β_0 es independiente de ϵ_t y v_t y este es un ejemplo de un modelo lineal dinámico.

El modelo anteriormente descrito forma parte de la clase general de modelos lineales dinámicos.

$$\begin{aligned} [\text{Observación}] \quad y_t &= F_t' \theta_t + v_t \\ [\text{Sistema}] \quad \theta_t &= G_t \theta_{t-1} + w_t \\ [\text{Previa}] \quad \theta_0 &\sim p(\theta_0 | D_0) \end{aligned} \quad (10)$$

Este conjunto es también llamado modelo de espacio estado, y los parámetros θ_t vector de estados, F_t vector de constantes conocido para todo t , G_t matriz de evolución del sistema, así como la estructura markoviana que θ_t depende de θ_{t-1} , y por último el ruido a nivel observacional v_t y el ruido a nivel del sistema w_t .

Para el caso del modelo normal dinámico (NDLM) se supone que los errores a nivel observacional y del sistema son normales con distribuciones $v_t \sim N(0, v_t)$ y $w_t \sim N(0, w_t)$ y finalmente la distribución de la previa es $(\theta_0 | D_0) \sim N(m_0, C_0)$.

Ahora, suponiendo que se conoce la varianza observacional w_t y a nivel del sistema v_t , así como F_t y G_t , así como una previa no informativa con distribución normal.

El proceso inicia con θ_0 y se va actualizando la previa en el momento cero antes de observar ningún dato, luego con la primera observación y_1 , actualizo la información para θ_1 , luego eso arroja una previa para θ_2 antes de observar y_2 , y así continuo con el filtro hacia adelante.

$$\begin{array}{ccccccccccc} \theta_0 & \longrightarrow & \theta_1 & \longrightarrow & \theta_2 & \longrightarrow & \dots & \longrightarrow & \theta_{t-1} & \longrightarrow & \theta_t & \longrightarrow & \theta_{t+1} & \longrightarrow \\ & & \uparrow & & \uparrow & & & & \uparrow & & \uparrow & & \uparrow & \\ & & y_1 & & y_2 & & & & y_{t-1} & & y_t & & y_{t+1} & \end{array}$$

La manera de usar el filtro hacia adelante es usando el teorema de *Bayes*, para realizar la actualización, $p(\theta_t | D_t) \propto p(y_t | \theta_t) \times p(\theta_t | D_{t-1})$, es decir, la distribución de θ_t dado D_t como algo que es proporcional a la verosimilitud dada por la ecuación de observación y la distribución previa que viene del momento t basada en la información $t - 1$.

2.6.1. Estimación y predicción

Según [Harrison and Stevens, 1976], se plantea un enfoque bayesiano para el pronóstico que tiene facilidades de respuesta cuando ocurren perturbaciones, sin producir fluctuaciones cuando no se tienen datos históricos, es también posible su estimación por medio de las relaciones con el filtro de Kalman.

De acuerdo por lo expuesto por [Terán, 2013] a través del filtro de Kalman se puede probar que el vector aleatorio $(\theta_0, \theta_1, \dots, \theta_t, Y_1, \dots, Y_t)$ tiene una distribución Normal para $t \geq 1$, usando el hecho de la estructura Markoviana del modelo, por lo que las distribuciones marginales y condicionales tienen también

distribución Normal. La manera de resolver el problema de filtración en los DLM, es a través del filtro de Kalman, en el cual, tomando el DLM de la ecuación (10) y suponiendo que $\theta_{t-1}|y_{1:t-1} \sim N(m_{t-1}, C_{t-1})$, entonces los siguientes enunciados se cumplen:

- La distribución predictiva del primer paso de θ_t dado y_{t-1} es Gaussiana con parámetros:

$$a_t = E(\theta_t|y_{1:t-1}) = G_t m_{t-1}$$

$$R_t = \text{Var}(\theta_t|y_{1:t-1}) = G_t C_{t-1} G_t' + W_t$$

- La distribución predictiva del primer paso de Y_t dado y_{t-1} es Gaussiana con parámetros:

$$f_t = E(Y_t|y_{1:t-1}) = F_t a_t$$

$$Q_t = \text{Var}(Y_t|y_{1:t-1}) = F_t R_t F_t' + V_t$$

- la distribución filtrada de θ_t dado y_{t-1} es Gaussiana con parámetros:

$$m_t = E(\theta_t|y_{1:t-1}) = a_t + R_t F_t' Q_t^{-1} \epsilon_t$$

$$C_t = \text{Var}(\theta_t|y_{1:t-1}) = R_t - R_t F_t' Q_t^{-1} F_t R_t$$

Donde $\epsilon_t = Y_t - f_t$, es el error de predicción.

Para la distribución filtrada se aplica el teorema de Bayes, utilizando como distribución a priori a $\pi(\theta_t|y_{1:t-1})$ y como función de verosimilitud a $\pi(y_t|\theta_t)$, lo cual lleva a un problema de inferencia bayesiana en el cual se puede plantear un modelo de regresión lineal dinámico:

$$Y_t = F_t \theta_t + v_t \quad v_t \sim N(0, V_t)$$

Con parámetro de regresión θ_t , y distribución a priori $N(0, V_t)$, donde V_t es conocida.

$$\theta_t|y_{1:t} \sim N(m_t, C_t)$$

2.6.2. Modelo polinomial dinámico de primer orden

Si se toma una serie de tiempo univariada, en la cual los únicos parámetros del sistema son las observaciones en los tiempos t y la evolución de las varianzas V y W , se tiene el modelo lineal dinámico polinomial de primer orden, con las siguientes ecuaciones:

Ecuación de observación:

$$Y_t = \mu_t + v_t, \quad v_t \sim N(0, V_t) \quad (11)$$

Ecuación del sistema:

$$\mu_t = \mu_{t-1} + w_t, \quad w_t \sim N(0, W_t) \quad (12)$$

Y podemos observar que $F_t = G_t = 1$.

2.6.3. Modelo lineal dinámico Generalizado Poisson de primer orden

[West et al., 1985] desarrolla Modelos Bayesianos Dinámicos para aplicaciones no lineales y no normales en series de tiempo y problemas de regresión, realizando una extensión de los modelos lineales generalizados estándar, la clave para estos análisis es usar priori conjugada y distribuciones posteriori con los parámetros de las distribuciones de la familia exponencial.

[West et al., 1985] planteó para las funciones estándar (binomial, Poisson y gamma) el espacio estado estado, de la siguiente manera:

Observación

$$dv(Y_t|\eta_t) = -2\ln[p(Y_t|\eta_t, \phi = 1)/p(Y_t|X_t), \phi = 1] \quad (13)$$

Priori

$$dv(\eta_t|D_{t-1}) = -2\ln[p(\eta_t|D_{t-1})/p(h_t|D_{t-1})] \quad (14)$$

Posterior

$$dv(\eta_t|D_{t-1}) = -2\ln[p(\eta_t|D_t)/p(Z_t|D_t)] \quad (15)$$

Residual

$$dv(Y_t|D_{t-1}) = [dv(Y_t|\eta_t) + dv(\eta_t|D_{t-1})]_{\eta_t=Z_t} \quad (16)$$

Estas funciones satisfacen una generalización de la forma cuadrática de descomposición de los modelos normales que pueden ser deducidos directamente del teorema de Bayes,

$$dv(Y_t|\eta_t) + dv(\eta_t|D_{t-1}) = dv(Y_t|D_{t-1}) + dv(\eta_t|D_t)$$

Para el modelo Poisson, la priori esta definida por $CP[\alpha_t, \beta_t]$ como una forma log-gamma para $\eta_t = \ln(\mu_t)$, donde μ_t es el rate Poisson.

3. METODOLOGÍA

3.1. Tipo de Investigación

El presente trabajo es de investigación aplicada, de carácter explicativo, con un enfoque cuantitativo, ya que busca encontrar metodologías estadísticas y formular un modelo para lograr un objetivo concreto, el cual es asociado a la mejora en los procedimientos de la administración del soporte logístico de una flota de helicópteros, que permita entender el comportamiento de las fallas y su asociación con la demanda de repuestos aeronáuticos, para ser de utilidad en la toma de decisiones a nivel gerencial.

3.1.1. Diseño de investigación no experimental

El estudio es no experimental, ya que en la investigación los datos recolectados fueron de las fuentes reales, tal cual como ocurrieron en su entorno operacional, no es posible la modificación de los mismos, es decir, se observa situaciones ya existentes, mas no provocadas por el investigador.

3.1.3. Población de estudio

La población de estudio son 28 helicópteros utilitario UH-1H HUEY y su relación de fallas durante el periodo comprendido entre (01-01-2010 y 31-07-2021).

3.1.4. Recolección de datos

Toda aeronave cuenta con un libro de vuelo, que es la fuente de información de fallas, ya que en el se registra la información del vuelo de la aeronave, y es el insumo para el desarrollo del presente trabajo. Es a partir del análisis de esta información que se detecta recurrencias y tendencias, se elaboran indicadores y se desarrolla todo tipo de estudios que permitan tener trazabilidad de todas las actividades relacionadas con la funcionalidad de la aeronave.

REPORTES DE MANTENIMIENTO											
TIPO:	1		UBICACIÓN TÉCNICA:		2		UNIDAD:		6-03		Nº
REPORTADO POR	CARGO	MISIÓN	AVISO Nº	CLASE AVISO	COD	PARADA	ELEMENTO AFECTADO	SERIE OFF	SERIE ON		
R1				3	2-1	13-1	X	Electrical	224CG02	4	380
SÍMBOLO	HRS AERONAVE	ATERRIZAJE	MOMENTO	FECHA	FECHA	HORA	REPERCUSIÓN				
2283:46	5749	L	03-10-21	09:00	15-10-21	15	1				
SÍNTOMA/VERIFICACIÓN	CAUSA AVERÍA	AB-GPES	1080	SISTEMA							
DESCRIPCIÓN EVENTO				ACCIONES CORRECTIVAS							
7 Durante arranque para la partida del compresor, culminando los 20 seg y al momento de interrumpir, este no interrumpe el arranque, se procede a apagar switch del panel exterior y de la batería.				8 Se realiza chequeo del Sistema Engine Starting según MM 80-11-50 en Contramando Contactos K0016-ES01 Inspeccionado con bastos de corto circuito. Se efectúa cambio de contactos y se realizan pruebas en zona de prendidos de manera satisfactoria según AMMD 24-31-04 Pág 1-7 Fig 402.							
				9							

Figura 5: Registro de falla, Fuente: libro de vuelo de una aeronave HUEY.

1. Tipo de aeronave.
2. Identificador de aeronave.
3. Identificador de la falla.
4. Elementos utilizados para corregir la falla.
5. Horas de vuelo al momento de la falla.
6. Sistema que se vió afectado por la falla.
7. Descripción de la falla.
8. Descripción de la corrección de la falla.
9. Identificador de la orden de salida de componentes.

La información registrada en el libro de vuelo es digitalizada en el sistema SAP, la cual es la fuente de información del presente trabajo y será exportada al software para análisis estadístico RSTUDIO, para el desarrollo del modelo de suavizado exponencial se usó la función *ses* del paquete *forecast*, para los modelos *Croston* y *Syntetos & Boylan* se usó las función *crost* del paquete *tsintermittent*, para el desarrollo del modelo *Bootstrap* se usó la función *bld.mbb.bootstrap* del paquete *forecast* y para el modelo lineal dinámico se usó la función *jags* del paquete *R2jags*.

3.2. Variables de estudio

La base de datos de fallas de 28 helicópteros HUEY, y sus salidas de repuestos durante el periodo comprendido entre (01-01-2010 y 31-07-2021), el cual presenta las siguientes variables:

Tabla 1: Variables de estudio.

Variable	Descripción	Tipo	Escala	Unidad de medida
Identificación Aeronave	Es el número de matrícula de la aeronave(Aeronave 1, Aeronave 2, ..., Aeronave 28).	Cualitativa	Nominal	No aplica
Fecha	Fecha de ocurrencia de la falla.	Cuantitativa	Intervalo	Días
Horas de vuelo.	Son las horas de vuelo en que ocurrió la falla.	Cuantitativa	Razón	Horas de vuelo
Sistema.	Es el sistema afectado por la falla (Motores, aviónica, etc).	Cualitativa	Nominal	No aplica
Componente.	Parte número del componente.	Cualitativa	Nominal	No aplica

4. DESARROLLO

4.1. Gestión de la información

Inicialmente se identifican los sistemas que más fallan para relacionar los repuestos asociados y teniendo en cuenta que la aviación sigue estándares mundiales, se presenta un código de clasificación que representa el sistema de la aeronave, ésta clasificación es llamada Código JASC (Joint Aircraft System/-Component) [FEDERAL AVIATION ADMINISTRATION, 2008] la cual es una normalización estándar de los diferentes sistemas de la aeronave creada por la Asociación de Transporte Aéreo de América (ATA) y modificada por la FAA (Federal Aviation Administration) el 28 de Octubre de 2008, esta codificación permite un mayor entendimiento de estos sistemas por parte de los pilotos, mecánicos de aviación, ingenieros aeronáutico, entre otros miembros de la rama aeronáutica.

Tabla 2: Codificación JASC del sistema 21 al 33

N.º JASC	Nombre del capítulo de la JASC
JASC 21	AIRE ACONDICIONADO Y PRESURIZACIÓN
JASC 22	PILOTO AUTOMÁTICO
JASC 23	COMUNICACIONES
JASC 24	SISTEMA ELÉCTRICO
JASC 25	EQUIPO Y ACCESORIOS
JASC 26	PROTECCIÓN CONTRA EL FUEGO
JASC 27	CONTROLES DE VUELO
JASC 28	COMBUSTIBLE
JASC 29	POTENCIA HIDRÁULICA
JASC 30	PROTECCIÓN CONTRA HIELO Y LLUVIA
JASC 31	SISTEMAS DE INDICACIÓN Y REGISTRO
JASC 32	TREN DE ATERRIZAJE
JASC 33	LUCES

Este sistema es el registrado en el libro de vuelo de la figura (4) en el numeral (6).

Para el desarrollo del presente trabajo se tomó una base de datos de fallas del año 2010 al 2020, la cual consta de 8.180 fallas y presenta 909 datos faltantes de fallas que no relacionan sistema, lo cual corresponde a un 11 % de los datos, por tal motivo, se realizó mediante metodologías de clasificación o categorización de textos, la asignación del sistema al que corresponden estas fallas que por error humano, no fueron clasificadas.

4.1.1. Procesamiento de lenguaje natural para clasificación sistema aeronáutico

El proceso de clasificación de textos comienza con el indexado del documento, consistente en mapear el documento a una representación compacta de su contenido. Los métodos de indexación normalmente utilizados en la categorización de textos utilizan una representación del documento mediante el Modelo del Espacio Vectorial [Salton et al., 1975], donde un documento en lenguaje natural se representa mediante vectores de términos.

Cada término del documento ocupa una posición en el vector de términos, originando un problema de dimensionalidad en documentos extensos. Por esta razón existe una fase previa que intenta reducir el tamaño del documento. Esta reducción hace el problema más manejable durante el aprendizaje, y repercute positivamente tanto en el tiempo de proceso como en el espacio ocupado. La reducción de la dimensionalidad del vector de términos de un documento normalmente se consigue mediante las siguientes acciones: tokenización, eliminación de stopwords y palabras nulas (que no aportan valor dentro del contexto del documento) y lematización. [Quinteiro et al., 2011]

A continuación se presenta la longitud de los textos sin procesamiento de la base de datos de fallas:

En la figura 6 se muestra un reporte ingresado al sistema y la figura 7 muestra el histograma de frecuencias de las longitudes de textos de todas las fallas analizadas.

```
* 01.03.2019 20:13:47 UTC-5 T. CASTELLANOS CASALLAS (JUANCASC) Tel. 3143..
* RUMBOS HSI PIL DESFASADOS 15
* 02.03.2019 17:21:27 UTC-5 T. CASTELLANOS CASALLAS (JUANCASC) Tel. 3143..
* AERONAVE UBICADA EN MELGAR CON 14155 HRS
* AC:SE CHEQUEO SISTEMA DE INDICACION RUMBOS PIL; SE EFECTUO CORRECCION EN
  SLAVING CONTROL; SE EFECTUARON PRUEBAS OPERACION NORMAL.
* OPERARIO: T4 MEJIA LUIS SAP 24977
* JG:T2 CASTELLANOS JUAN SAP 4563
* INSPECTOR T1 GUERRERO DIEGO SAP 1051
* HOJA FORMA FAC4-282T NUMERO 233255 R1 RUMBOS HSI PIL DESFASADOS 15
AERONAVE UBICADA EN MELGAR CON 14155 HRS
AC:SE CHEQUEO SISTEMA DE INDICACION RUMBOS PIL; SE EFECTUO CORRECCION EN
SLAVING CONTROL; SE EFECTUARON PRUEBAS OPERACION NORMAL.
OPERARIO: T4 MEJIA LUIS SAP 24977
JG: T2 CASTELLANOS JUAN SAP 4563
INSPECTOR T1 GUERRERO DIEGO SAP 1051
HOJA FORMA FAC4-282T NUMERO 233255 R1
```

Figura 6: Reporte sin procesamiento.




Figura 7: Longitud de textos sin procesamiento.

Donde se identifica asimetría hacia la derecha y concentración de longitudes de textos en aproximadamente 500 caracteres, así como unos valores atípicos del orden de 2000 caracteres.

y la Nube de palabras sin procesamiento:



Figura 8: Nube de palabras sin procesamiento.

Identificando presencia de stop words y palabras nulas, las cuales serán tratadas para reducir la dimensionalidad de los textos a través de eliminación del ruido y posterior tokenización.

4.1.1.1 Eliminación del ruido y tokenización

La eliminación del ruido son las tareas que permiten normalizar los textos para posterior realizar la tokenización, y esta comprende, eliminación de stop-words, encabezados de archivos de texto, pies de página, signos de puntuación, etc. en la figura 9 y 10, claramente se presenta la reducción de la dimensionalidad en los textos, donde la concentración de longitud de textos en el histograma es disminuida a 150 aproximadamente con valores atípicos de 600.




Figura 9: Longitud de textos procesados.

y la nube de palabras con procesamiento donde se identifican palabras representativas para la clasificación de los sistemas.



Figura 10: Nube de palabras con procesamiento.

Una vez reducida la dimensionalidad del documento, se calculó la relevancia de cada término del vector de términos. Para este fin, uno de los métodos más extendidos es la obtención del tf-idf [Salton and Buckley, 1988]. El tf-idf comprende la frecuencia del término en el documento (tf) y la inversa de la frecuencia de documentos que poseen el término (idf). El tf representa la importancia local que el término posee en el documento, es decir, cuanto más aparezca un término en un documento, más relevante será ese término para ese documento. El idf representa la importancia global de un término en relación inversa, es decir, cuantos más documentos incluyan el término, este término será menos relevante. [Quinteiro et al., 2011]

Con el fin de comprobar si los modelos podrán diferenciar cada una de las palabras y su relación con las demás, se realizó un Word embedding, el cual consiste en representar palabras con vectores de números, para identificar si la representación vectorial puede diferenciar los sistemas.




Figura 11: Word embedding de 9 palabras representativas para los sistemas de comunicación JASC 23, motor JASC 72 y navegación JASC 34.

Donde se observa que los vectores si estan bien representado para realizar modelos de clasificación de textos de machine learning.

Se realizaron 4 modelos de Machine Learning para poder identificar el mejor Accuracy con una muestra de entrenamiento del 80 % y 20 % de validación, arrojando los siguientes resultados:

Tabla 3: Resultados muestra de entrenamiento

Modelo	Accuracy
Decision tree	0.62
Random forest	0.94
Gradient boosting	0.49
Logistic regression	0.74

Donde podemos observar que el modelo Random Forest tiene un accuracy de 93.70 % sin embargo, esto puede ser un sobreajuste al modelo, o errores de entrenamiento de los demás modelos, por tal motivo, para tener una predicción mas certera, se verificará el accuracy en la muestra de validación.

Tabla 4: Resultados muestra de validación

Modelo	Accuracy
Decision tree	0.43
Random forest	0.64
Gradient boosting	0.35
Logistic regression	0.66

Para mejorar el Accuracy se realizó una validación cruzada y variación de los hiperparámetros de cada uno de los modelos, para tal fin, se divide el conjunto de datos en $k = 5$ pliegues, en el cual en la primera iteración prueba el primer pliegue y los demás para entrenar el modelo, luego usa el segundo pliegue y los otros apoyan el proceso de entrenamiento, y este proceso se repite hasta que el conjunto de pruebas utiliza los 5 pliegues, arrojando los siguientes resultados:

Tabla 5: Resultados muestra de entrenamiento con validación cruzada y variación de hiperparámetros

Modelo	Accuracy
Random forest	0.68
Logistic regression	0.66

Tomando el modelo Random forest, se realizó la imputación de los datos faltantes en los datos de fallas de las aeronaves y obtenemos nuestra base de datos completa para dar inicio al análisis de la informacion de los sistemas que mas fallan.

4.2. Análisis de la información

Una vez se obtuvieron las fallas con su sistema asociado, se presenta el diagrama de pareto de los sistemas, con el fin de identificar cuales son los que mas fallan:

Donde podemos evidenciar que el 80 % de las fallas se distribuye en los sistemas:




Figura 12: Pareto sistemas helicópteros HUEY II.

Tabla 6: Sistemas donde se concentra el 80 % de las fallas

N.º JASC	Nombre del capítulo de la JASC	N.º JASC	Nombre del capítulo de la JASC
JASC 23	COMUNICACIONES	JASC 62	ROTOR PRINCIPAL
JASC 24	SISTEMA ELÉCTRICO	JASC 67	CONTROL EN VUELO DE LOS ROTORES
JASC 28	COMBUSTIBLE	JASC 72	MOTORES DE TURBINAS/TURBOPROPULSORES
JASC 31	SISTEMAS DE INDICACIÓN Y REGISTRO	JASC 77	INDICACIONES DEL MOTOR
JASC 33	LUCES	JASC 79	ACEITE DEL MOTOR
JASC 34	NAVEGACIÓN	JASC 95	EQUIPOS ESPECIALES
JASC 53	FUSELAJE		

Para identificar el tiempo de falla y la confiabilidad de cada uno de los sistemas, la probabilidad de que un evento ocurra está dada por la función de distribución acumulada de probabilidad $F(T) = Q(T)$:

$$F(t) = \int_0^t f(s)ds$$

Entonces la Confiabilidad $R(t)$ está dada por:

$$R(t) = 1 - Q(t)$$

Se desarrolló la función de confiabilidad $R(t)$ mediante la función de densidad de probabilidad de la distribución exponencial, dado que se cuenta con las horas voladas en sucesos consecutivos, que en este caso son las horas de vuelo x entre cada una de las fallas presentadas

$$f(s) = \lambda e^{-\lambda s}$$

Para tal fin, se realizaron pruebas de Kolmogorov-Smirnov para determinar la bondad de ajuste a la distribución exponencial, y se planteó la **Hipótesis nula** e **Hipótesis alternativa**.

$$H_0 : X \sim Exp(\lambda)$$

$$H_1 : X \not\sim Exp(\lambda)$$

Tabla 7: P valores prueba Kolmogorov-Smirnov

CÓDIGO	P VALOR
JASC34	0.2717960
JASC24	0.8549843
JASC23	0.6707628
JASC72	0.6254178
JASC53	0.9112597
JASC33	0.7923237
JASC31	0.8330085
JASC62	0.3504870
JASC28	0.4574187
JASC63	0.6322435
JASC77	0.9925596
JASC67	0.7721330
JASC95	0.2014346
JASC79	0.7315073

Donde se evidencia en la Tabla (7) que para todos los sistemas no se rechazó la hipótesis nula $H_0 : X \sim \text{Exp}(\lambda)$.

La probabilidad de que este componente funcione bajo las condiciones de diseño para el cual fue desarrollado durante un tiempo t está dada por.

$$\begin{aligned}
 R(t) &= 1 - \int_0^t \lambda e^{-\lambda s} ds \\
 &= 1 - [1 - e^{-\lambda t}] \\
 &= e^{-\lambda t}
 \end{aligned} \tag{17}$$

De acuerdo a lo anterior, el desempeño de los sistemas es medido con la ecuación (13), donde λ es la tasa de ocurrencia del evento por unidad de tiempo.

El análisis de las fallas por sistema corresponde al individuo **Sistema JASC**, el cual es evaluado en cada una de las aeronaves, esto considera las correlaciones entre este mismo sujeto en sus tiempos de falla de cada helicóptero y puede analizarse desde un enfoque promedio para determinar el tiempo de falla de cada uno de los sistemas a través de la estimación del λ y con este dato poder calcular la Confiabilidad Aeronáutica de cada sistema.

Como la variable respuesta **Tiempo a la falla** presenta una distribución exponencial y cuenta con el efecto aleatorio de la variable cualitativa del identificador de cada aeronave, podemos considerar esta variable como un efecto aleatorio, por tal motivo se implementó un Modelo Lineal Generalizado Mixto (GLMM) [Mangeaud and Videla, 2005], el cual está dado por:

$$\eta_i = \mu + \alpha_i + \delta_j + \varepsilon_{ij} \tag{18}$$

donde:

η_i es la variable respuesta, los tiempos entre cada falla, μ es la media poblacional, intercepto, α_i es el efecto de la i -ésima covariable, no se cuenta con covariables y δ_j representa el efecto aleatorio, el identificador de cada aeronave.

Con el software estadístico RStudio, se calculó el intercepto 4.14681, entonces el MTBF del sistema 34 es el siguiente:

$$\begin{aligned}
 MTBF(34) &= e^{4.14681} \\
 &= 63.23hrs
 \end{aligned}
 \tag{19}$$

Es decir, en promedio para toda la flota de helicópteros se presenta una falla en el sistema de navegación cada 63.23 horas de vuelo, y el tiempo medio entre fallas del sistema de navegación (34) para cada aeronave, así:

Tabla 8: MTBF por aeronave sistema de navegación

	Aeronave	MTBF(horas de vuelo)		Aeronave	MTBF(horas de vuelo)
1	Helicóptero 1	58.55	15	Helicóptero 15	66.33
2	Helicóptero 2	56.62	16	Helicóptero 16	51.04
3	Helicóptero 3	55.14	17	Helicóptero 17	58.56
4	Helicóptero 4	57.05	18	Helicóptero 18	77.41
5	Helicóptero 5	62.24	19	Helicóptero 19	58.18
6	Helicóptero 6	67.95	20	Helicóptero 20	67.45
7	Helicóptero 7	55.08	21	Helicóptero 21	54.80
8	Helicóptero 8	69.82	22	Helicóptero 22	74.48
9	Helicóptero 9	76.98	23	Helicóptero 23	66.38
10	Helicóptero 10	62.23	24	Helicóptero 24	65.76
11	Helicóptero 11	62.89	25	Helicóptero 25	66.57
12	Helicóptero 12	64.54	26	Helicóptero 26	64.84
13	Helicóptero 13	58.38	27	Helicóptero 27	64.98
14	Helicóptero 14	69.74	28	Helicóptero 28	67.38

Donde la aeronave con mejor desempeño en el sistema de navegación es el Helicóptero 18 con un tiempo de falla promedio de 77.41 horas de vuelo, y la aeronave con peor desempeño es el helicóptero 16 con 51.04 horas de vuelo.

Ahora, de acuerdo a la ecuación 13, se calculó la confiabilidad del sistema de navegación para la flota de helicópteros.

$$\begin{aligned}
 R_{34}(t = 2.3) &= e^{-\frac{1}{63.23} * 2.3} \\
 &= 0.9642
 \end{aligned}
 \tag{20}$$

donde t es la autonomía de vuelo es decir, el tiempo que una aeronave puede estar en vuelo con los tanques de combustibles al 100 %.

Lo cual nos indica que la probabilidad de que una aeronave salga a vuelo y no tenga fallas en el sistema de navegación es del 96.42 %.

A continuación se presentan en la tabla 9, los valores de confiabilidad de todos los sistemas, donde se puede observar, que seguido del sistema de navegación, el sistema eléctrico tiene una confiabilidad del 98,12 %.

Tabla 9: Confiabilidad por sistema

SISTEMA	JASC	FALLAS	Confiabilidad	MTBF
NAVEGACION	34	1216	96,43 %	63,23
SISTEMA ELÉCTRICO	24	617	98,12 %	121,17
COMUNICACIONES	23	559	98,30 %	133,75
MOTORES	72	507	98,45 %	147,46
FUSELAJE	53	371	98,87 %	201,52
SISTEMAS DE INDICACIÓN	31	348	98,94 %	214,84
LUCES	33	329	98,99 %	227,25
ROTOR PRINCIPAL	62	292	99,11 %	256,04
COMBUSTIBLE	28	281	99,14 %	266,07
EMPUJE ROTOR PRINCIPAL	63	278	99,15 %	268,94
INDICACIONES MOTOR	77	245	99,25 %	305,16
CONTROLES DE VUELO	67	231	99,29 %	323,66
ACEITE DEL MOTOR	79	218	99,33 %	342,96
EQUIPOS ESPECIALES	95	212	99,35 %	352,66

4.3. Identificación de los modelos

Una vez identificados los sistemas que mas fallas, se toma la serie y_t correspondiente a la demanda de repuestos semestral de cada uno de los repuestos asociados a los sistemas que mas fallan, es decir, cada repuesto es una serie de tiempo independiente, a la cual se le aplicaron los siguientes modelos:

1. Modelo simple de suavización exponencial.
2. Modelo Croston.
3. Modelo Syntetos and Boylan.
4. Método Bootstrap aplicado a una serie de la familia de suavización exponencial.
5. Modelo lineal dinámico generalizado Poisson.

4.3.1. Criterios de evaluación del modelo

Para la evaluación de los modelos se plantearon las medidas, error cuadrático medio (RMSE) y error absoluto medio (MAE) arrojando los siguientes resultados:




Figura 13: Serie de 01 repuesto del sistema de navegación y sus modelos

Tabla 10: Resultados RMSE

Modelo	Exponencial	Croston	SBA	BOOT	MLD
Exponencial	0	45	45	68	69
Croston	21	0	14	63	68
SBA	21	16	0	63	68
BOOT	2	6	6	0	57
MLD	1	1	1	5	0

Donde se puede observar que para una muestra de la rotación de 70 repuestos, el mejor modelo es el modelo lineal dinámico el cual con la metrica del error cuadrático medio es mejor en 69 repuestos que el modelo clásico de suavización exponencial, comparado con el modelo Croston es mejor en 68 repuestos, con el modelo SBA es mejor en 68 repuestos, y con el modelo Bootstrap en 57 repuestos.

Tabla 11: Resultados MAE

Modelo	Exponencial	Croston	SBA	BOOT	MLD
Exponencial	0	41	41	48	53
Croston	23	0	12	45	56
SBA	23	13	0	43	56
BOOT	20	23	23	0	52
MLD	13	12	12	15	0

Y con la métrica error absoluto medio (MAE), el modelo lineal dinámico, en comparación con el exponencial es mejor en 53 repuestos, con Croston y SBA en 56 repuestos y con el modelo Bootstrap en 52 repuestos.

5. DISCUSIÓN DE RESULTADOS

Con el desarrollo del presente trabajo, se logró establecer metodologías para el pronóstico de la demanda de repuestos aeronáuticos y se identificó que los modelos lineales dinámicos en comparación con los métodos clásicos de pronóstico de inventarios en términos del RMSE y MAE, presentan menor error de predicción, lo cual permite a una compañía de aviación disminuir los tiempos de parada de las aeronaves al contar con los repuestos asociados, así como, reducir costos de almacenamiento, riesgo de deterioro y/o obsolescencia, aumento del control de stock estacional, así como una disminución al costo del inventario, este desarrollo, contribuye a una mejora en la administración de inventarios, de igual forma el presente trabajo no solo aplica para rotación de repuestos aeronáuticos, sino también a otro tipo de industria, se recomienda para futuros estudios, no solo modelar el pronóstico mediante el modelo polinomial de primer orden, sino plantear un modelo de tendencia lineal o modelo polinomial de segundo orden en el cual $F_t = \begin{pmatrix} 1 \\ 0 \end{pmatrix}$ y $G_t = \begin{pmatrix} 1 & 1 \\ 0 & 1 \end{pmatrix}$.

El modelo de suavización exponencial, es un método sencillo y probablemente el más usado para manejo de inventarios por su simpleza y que no requiere gran volumen de datos históricos, sin embargo, como método de pronóstico puede generar sobrestock de elementos, ya que la rotación de repuestos aeronáuticos presenta características de demanda errática cuando hay periodos con demanda cero, este error de pronóstico, obedece a su baja respuesta a la tendencia, aun cuando el valor de la variable α de suavización logra responder frente a cambios en los datos, cambios sistemáticos harán más grande el error de pronóstico, se pudo evidenciar que el error disminuye cuando se aplican los métodos Croston y Syntetos and Boylan, ya que, reduce el sesgo cuando se presentan demandas intermitentes.

A través del uso de modelos Bootstrap de bloques generadas a partir de un modelo de la familia de suavización exponencial, se observa una mejora considerable en términos del RMSE y MAE en comparación con los modelos clásicos de pronóstico.

La identificación de los sistemas que más fallan y su probabilidad de ocurrencia calculada a través de modelos lineales generalizados mixtos, permite al área de operaciones y mantenimiento aeronáutico generar alertas tempranas de posibles fallas en componentes que puedan comprometer la aeronavegabilidad de los productos CLASE I y II. Se recomienda para futuros estudios, realizar un pronóstico de fallas mediante modelos lineales dinámicos y de esta manera incluirlo en el desarrollo de un programa de confiabilidad.

Para la clasificación de las fallas que no asociaban sistema aeronáutico, se aplicaron modelos de machine learning como lo son: (Árbol de decisión, Random forest, Gradient boosting y regresión logística), en el cual, el modelo Random Forest tuvo el mejor desempeño en términos de accuracy, se recomienda para trabajos futuros, profundizar en temas de machine learning para el procesamiento del lenguaje natural (NLP), ya que en el presente trabajo se realizó una aplicación muy sencilla y de poco requerimiento de máquina, sin embargo, se observa que existe gran marco teórico referencial para un trabajo de investigación de minería de datos.

6. BIBLIOGRAFÍA

Referencias

- [Aeronáutica Civil Colombiana, 2010] Aeronáutica Civil Colombiana (2010). Circular informativa (CI) (No CI-5103-082-17). <http://www.aerocivil.gov.co/autoridad-de-la-aviacion-civil/biblioteca-tecnica/Circulares>
- [Aeronáutica Civil Colombiana, 2017] Aeronáutica Civil Colombiana (2017). Circular informativa (CI) (No CI 5103-082-012 V3). <http://www.aerocivil.gov.co/autoridad-de-la-aviacion-civil/biblioteca-tecnica/Circulares>
- [Aeronáutica Civil Colombiana, 2019] Aeronáutica Civil Colombiana (2019). Reglamento Aeronáutico Colombiano (RAC). <http://www.aerocivil.gov.co/autoridad-de-la-aviacion-civil/reglamentacion/rac>.
- [Bergmeir et al., 2016] Bergmeir, C., Hyndman, R. J., and Benítez, J. M. (2016). Bagging exponential smoothing methods using stl decomposition and box cox transformation. *International Journal of Forecasting*, 32(2):303–312.
- [Billah et al., 2006] Billah, B., King, M., Snyder, R., and Koehler, A. (2006). Exponential smoothing model selection for forecasting. *International Journal of Forecasting*, 22:239–247.
- [Biryukov, 2019] Biryukov, V. (2019). Methodical foundations of forecasting the reliability of products of aviation and rocket and space technology. *INCAS BULLETIN*, 11:41–51.
- [Breiman, 1996] Breiman, L. (1996). Bagging predictors. *Machine Learning*, 24(2):123–140.
- [Bugaj, 2012] Bugaj, M. (2012). Failure analysis basic step of applying reliability centered maintenance in general aviation. *Transport Problems : an International Scientific Journal*, 7:77–86.
- [Cancillería de Colombia, 2022] Cancillería de Colombia (28 de Abril de 2022). <https://www.cancilleria.gov.co/mapa-general>.
- [Cleveland et al., 1990] Cleveland, R. B., Cleveland, W. S., McRae, J. E., and Terpenning, I. (1990). Stl: A seasonal-trend decomposition procedure based on loess (with discussion). *Journal of Official Statistics*, 6:3–73.
- [Croston, 1972] Croston, J. (1972). Forecasting and stock control for intermittent demands. *Journal of The Operational Research Society - J OPER RES SOC*, 23:289–303.
- [Cruz R. and Correa, 2017] Cruz R., R. S. and Correa, C. (2017). Previsión de demanda intermitente con métodos de series de tiempo y redes neuronales artificiales: Estudio de caso. *DYNA*, 84:9 – 16.
- [FEDERAL AVIATION ADMINISTRATION, 2008] FEDERAL AVIATION ADMINISTRATION (27 de Octubre de 2008). https://av-info.faa.gov/sdrx/documents/JASC_Code.pdf.
- [Fuerza Aérea Colombiana, 2020] Fuerza Aérea Colombiana (2020). Estrategia para el desarrollo aereo y espacial fuerza aerea colombiana 2042. <https://www.fac.mil.co/edaesfac2042>.
- [Harrison and Stevens, 1976] Harrison, P. J. and Stevens, C. F. (1976). Bayesian forecasting. *Journal of the Royal Statistical Society. Series B (Methodological)*, 38(3):205–247.
- [Hasni et al., 2019] Hasni, M., Aguir, M., Babai, M., and Jemai, Z. (2019). Spare parts demand forecasting: a review on bootstrapping methods. *International Journal of Production Research*, 57(15-16):4791–4804.

- [Hua et al., 2007] Hua, Z., Zhang, B., Yang, J., and Tan, D. (2007). A new approach of forecasting intermittent demand for spare parts inventories in the process industries. *Journal of The Operational Research Society - J OPER RES SOC*, 58:52–61.
- [Hyndman et al., 2002] Hyndman, R. J., Koehler, A. B., Snyder, R. D., and Grose, S. (2002). A state space framework for automatic forecasting using exponential smoothing methods. *International Journal of Forecasting*, 18(3):439–454.
- [Lahiri, 1993] Lahiri, S. (1993). On the moving block bootstrap under long range dependence. *Statistics & Probability Letters*, 18(5):405–413.
- [Lahiri and Lahiri, 2003] Lahiri, S. and Lahiri, S. (2003). *Resampling methods for dependent data*. Springer Science & Business Media.
- [Liu and Tang, 1996] Liu, R. Y. and Tang, J. (1996). Control charts for dependent and independent measurements based on bootstrap methods. *Journal of the American Statistical Association*, 91(436):1694–1700.
- [Mangeaud and Videla, 2005] Mangeaud, A. and Videla, M. (2005). En busca de la independencia perdida: la utilización de modelos lineales generalizados mixtos en pruebas de preferencia.
- [Ostertagova and Ostertag, 2011] Ostertagova, E. and Ostertag, O. (2011). The simple exponential smoothing model.
- [Quinteiro et al., 2011] Quinteiro, J., Martel-Jordán, E., Morera, P., Fleitas, J., and Rodríguez, A. (2011). Clasificación de textos en lenguaje natural usando la wikipedia. *Revista Ibérica de Sistemas y Tecnologías de la Información*, 8:39–52.
- [Salton and Buckley, 1988] Salton, G. and Buckley, C. (1988). Term-weighting approaches in automatic text retrieval. *Information Processing & Management*, 24(5):513–523.
- [Salton et al., 1975] Salton, G., Wong, A., and Yang, C.-S. (1975). A vector space model for automatic indexing. *Commun. ACM*, 18:613–620.
- [Snyder, 2002] Snyder, R. (2002). Forecasting sales of slow and fast moving inventories. *European Journal of Operational Research*, 140(3):684–699.
- [Syntetos and Boylan, 2005] Syntetos, A. and Boylan, J. (2005). The accuracy of intermittent demand estimates. *International Journal of Forecasting*, 21:303–314.
- [Terán, 2013] Terán, A. M. (2013). Modelos dinámicos lineales aplicados a series de tiempo.
- [Valencia Cárdenas et al., 2015] Valencia Cárdenas, M., Correa, J., and Díaz, J. (2015). Inventory model using bayesian dynamic linear model for demand forecasting (modelo de inventarios que utiliza el modelo lineal dinámico bayesiano para el pronóstico de demanda). *Ingeniería, Investigación y Desarrollo ISSN 2422-4324*, 15:39–47.
- [Varghese and Rossetti, 2008] Varghese, V. and Rossetti, M. (2008). A parametric bootstrapping approach to forecast intermittent demand. *IIE Annual Conference and Expo 2008*.
- [Wang et al., 2020] Wang, Y., Gao, X., Cai, Y., Mingshun, Y., Li, S., and Li, Y. (2020). Reliability evaluation for aviation electric power system in consideration of uncertainty. *Energies*, 13:1175.
- [West et al., 1985] West, M., Harrison, P. J., and Migon, H. S. (1985). Dynamic generalized linear models and bayesian forecasting. *Journal of the American Statistical Association*, 80(389):73–83.
- [Willemain et al., 2004] Willemain, T., Smart, C., and Schwarz, H. (2004). A new approach to forecasting intermittent demand for service parts inventories. *International Journal of Forecasting*, 20:375–387.

7. ANEXOS

7.1. Programas

```
#####
##                                ##
##                                ##
##                                ##
##                                ##
#####

df_rmse <- data.frame(Material=character(),
                      Metrica=character(),
                      Exponencial=double(),
                      Croston=double(),
                      SBA=double(),
                      stringsAsFactors=FALSE)

df_mae <- data.frame(Material=character(),
                     Metrica=character(),
                     Exponencial=double(),
                     Croston=double(),
                     SBA=double(),
                     stringsAsFactors=FALSE)

i <- 1

for(i in 1:dim(rotaciones_totales)[1]){

  repuesto <- rotaciones_totales[i,-c(1, 2, 26, 27)]

  exponential <- ses(as.ts(t(repuesto)), initial = "simple")

  croston <- crost(as.ts(repuesto),type='croston', h=2, outplot=FALSE)
  synt_boylan <- crost(as.ts(repuesto),type='sba',h=2,outplot=FALSE)

  y_true_34 <- t(as.ts(repuesto))

  y_34 <- as.data.frame(y_true_34[3:23])
  colnames(y_34) <- c("y_true")
  y_34$ypred_expon <- exponential$fitted[3:23]
  y_34$ypred_crost <- croston$frc.in[3:23]
  y_34$ypred_sba <- synt_boylan$frc.in[3:23]
  y_34[is.na(y_34)] <- 0
}
```

```

metricas_exponential <- c(rmse(y_34$y_true, y_34$ypred_expon),
                           mae(y_34$y_true, y_34$ypred_expon))
metricas_croston <- c(rmse(y_34$y_true, y_34$ypred_croston),
                      mae(y_34$y_true, y_34$ypred_croston))
metricas_sba <- c(rmse(y_34$y_true, y_34$ypred_sba),
                  mae(y_34$y_true, y_34$ypred_sba))

Material <- c(rotaciones_totales[i,c(1)])

df_rmse[i,] <- c(Material,c("RMSE"), metricas_exponential[1],
                  metricas_croston[1], metricas_sba[1])
df_mae[i,] <- c(Material,c("MAE"), metricas_exponential[2],
                  metricas_croston[2], metricas_sba[2])

}

#####
##                                BOOTSTRAP                                ##
#####

df_rmse_boot <- data.frame(Material=character(),
                           Metrica=character(),
                           BOOTSTRAPPING=double(),
                           stringsAsFactors=FALSE)

df_mae_boot <- data.frame(Material=character(),
                           Metrica=character(),
                           BOOTSTRAPPING=double(),
                           stringsAsFactors=FALSE)

fr <- function(data){
  i <- as.ts(data)
  prueba_boot_11 <- ets(i)
}

j <- 1
for(j in 1:dim(rotaciones_totales)[1]){

  prueba_boot <- rotaciones_totales[j,-c(1,2, 26, 27)]

  prueba_boot_1 <- as.ts(t(prueba_boot))
  a <- c(prueba_boot_1)

  data_boot_mbb <- bld.mbb.bootstrap(ts(fr(a), freq = 23), 1000)

  z <- unlist(data_boot_mbb)

  datos_boot <- apply(matrix(z[-c(1:23)], ncol = 23, byrow = TRUE),
                      2, mean)

```

```

Material <- c(rotaciones_totales[j,c(1)])

rmse(unlist(prueba_boot), datos_boot)
mae(unlist(prueba_boot), datos_boot)

metricas_boot <- c(rmse(unlist(prueba_boot), datos_boot),
  mae(unlist(prueba_boot), datos_boot))

df_rmse_boot[j,] <- c(Material,c("RMSE"), metricas_boot[1])
df_mae_boot[j,] <- c(Material,c("MAE"), metricas_boot[2])
}
df_rmse <- cbind(df_rmse,df_rmse_boot[,3])
df_mae <- cbind(df_mae,df_mae_boot[,3])

#####
##                                MODELO LINEAL DINAMICO                                ##
#####
~

library(rjags)
library(R2jags)
library(coda)

df_rmse_dina <- data.frame(Material=character(),
  Metrica=character(),
  MLD=double(),
  stringsAsFactors=FALSE)

df_mae_dina <- data.frame(Material=character(),
  Metrica=character(),
  MLD=double(),
  stringsAsFactors=FALSE)

j <- 1
i <- 1
for(j in 1:dim(rotaciones_totales)[1]){

#MODELO LINEAL GENERALIZADO DINAMICO
prueba_boot <- rotaciones_totales[j,-c(1,2, 2, 26, 27)]

prueba_boot_din <- unlist(prueba_boot)

modelo <- function(){
  for (i in 2:n) {
    prueba_boot_din[i] ~ dpois(lambda[i])
    log(lambda[i]) <- m[i]
    m[i] ~ dnorm(m[i-1], h)
  }
}

```

```

    }
    h ~ dgamma(0.0001, 0.0001)
    m[1] ~ dnorm(0, 0.0001)
  }

  n <- length(prueba_boot_din)

  data_in <- list("prueba_boot_din", "n")
  data_out <- c("lambda")

  resultados <- jags(data = data_in, parameters.to.save = data_out,
                    model.file = modelo)

  #View(resultados$BUGSoutput$summary)

  out_jags <- resultados$BUGSoutput$mean$lambda

  Material <- c(rotaciones_totales[j, c(1)])

  metricas_dina <- c(rmse(prueba_boot_din[-1], out_jags),
                    mae(prueba_boot_din[-1], out_jags))

  df_rmse_dina[j,] <- c(Material, c("RMSE"), metricas_dina[1])
  df_mae_dina[j,] <- c(Material, c("MAE"), metricas_dina[2])
}
df_rmse <- cbind(df_rmse, df_rmse_dina[, 3])
df_mae <- cbind(df_mae, df_mae_dina[, 3])

```

7.2. Codificación JAGS

Tabla 12: Codificación JAGS

N.º JASC	Nombre del capítulo de la JASC	N.º JASC	Nombre del capítulo de la JASC
JASC 00	GENERAL	JASC 46	SISTEMAS DE INFORMACIÓN
JASC 01	POLÍTICA DE MANTENIMIENTO	JASC 47	SISTEMA DE GENERACIÓN DE NITRÓGENO
JASC 02	OPERACIONES	JASC 48	DISPENSACIÓN DE COMBUSTIBLE EN VUELO
JASC 03	APOYO	JASC 49	UNIDAD DE POTENCIA AUXILIAR
JASC 04	LIMITACIONES DE AERONAVEGABILIDAD	JASC 50	COMPARTIMENTOS DE CARGA Y ACCESORIOS
JASC 05	LÍMITES DE TIEMPO/CONTROLES DE MANTENIMIENTO	JASC 51	ESTÁNDARES PRÁCTICOS Y ESTRUCTURAS – GENERAL
JASC 06	DIMENSIONES Y SUPERFICIES	JASC 52	PUERTAS
JASC 07	LEVANTAMIENTO, APUNTALAMIENTO Y SOPORTE	JASC 53	FUSELAJE
JASC 08	NIVELACIÓN Y PESAJE	JASC 54	GÓNDOLAS / PILONES
JASC 09	REMOLQUE Y RODAJE	JASC 55	ESTABILIZADORES
JASC 10	APARCAMIENTO, AMARRE, ALMACENAMIENTO Y VUELTA AL SERVICIO	JASC 56	VENTANAS
JASC 11	LETREROS Y SEÑALES	JASC 57	ALAS
JASC 12	SERVICIO – MANTENIMIENTO RUTINARIO	JASC 60	ESTÁNDARES PRÁCTICOS – HÉLICE/ROTOR
JASC 13	HARDWARE Y HERRAMIENTAS GENERALES	JASC 61	PROPULSORES
JASC 18	ANÁLISIS DE VIBRACIÓN Y RUIDO (SÓLO HELICÓPTEROS)	JASC 62	ROTOR(ES) PRINCIPAL(ES)
JASC 20	ESTÁNDARES PRÁCTICOS – FUSELAJE	JASC 63	EMPUJE DEL ROTOR PRINCIPAL
JASC 21	AIRE ACONDICIONADO Y PRESURIZACIÓN	JASC 64	ROTOR DE COLA
JASC 22	PILOTO AUTOMÁTICO	JASC 65	EMPUJE DEL ROTOR DE COLA
JASC 23	COMUNICACIONES	JASC 66	PALAS/PILONES
JASC 24	SISTEMA ELÉCTRICO	JASC 67	CONTROL EN VUELO DE LOS ROTORES
JASC 25	EQUIPO Y ACCESORIOS	JASC 70	ESTÁNDARES PRÁCTICOS DEL MOTOR
JASC 26	PROTECCIÓN CONTRA EL FUEGO	JASC 71	PLANTA MOTORA
JASC 27	CONTROLES DE VUELO	JASC 72	MOTORES DE TURBINAS/TURBOPROPULSORES
JASC 28	COMBUSTIBLE	JASC 73	CONTROL Y GESTIÓN DEL COMBUSTIBLE DEL MOTOR
JASC 29	POTENCIA HIDRÁULICA	JASC 74	IGNICIÓN DEL MOTOR
JASC 30	PROTECCIÓN CONTRA HIELO Y LLUVIA	JASC 75	AIRE DEL MOTOR
JASC 31	SISTEMAS DE INDICACIÓN Y REGISTRO	JASC 76	CONTROL DEL MOTOR
JASC 32	TREN DE ATERRIZAJE	JASC 77	INDICACIONES DEL MOTOR
JASC 33	LUCES	JASC 78	SISTEMA DE ESCAPE DEL MOTOR
JASC 34	NAVEGACIÓN	JASC 79	ACEITE DEL MOTOR
JASC 35	OXÍGENO	JASC 80	ARRANQUE DEL MOTOR
JASC 36	SISTEMA NEUMÁTICO	JASC 81	TURBOCARGA
JASC 37	VACÍO	JASC 81	TURBOCARGA
JASC 38	AGUA / DESECHOS	JASC 82	INYECCIÓN DE AGUA
JASC 39	PANELES ELÉCTRICO-ELECTRÓNICOS Y COMPONENTES MULTIUSO	JASC 83	ACCESORIOS DE LA CAJA DE CAMBIOS
JASC 40	MULTISISTEMA	JASC 84	INCREMENTO DE LA PROPULSIÓN
JASC 41	AGUA / LASTRE	JASC 85	SISTEMAS DE CELDAS DE COMBUSTIBLE
JASC 42	AVIÓNICA MODULAR INTEGRADA	JASC 91	GRÁFICAS
JASC 44	SISTEMAS DE CABINA	JASC 92	INSTALACIÓN DEL SISTEMA ELÉCTRICO
JASC 45	SISTEMA DE DIAGNÓSTICO Y MANTENIMIENTO		