






## Modelación matemática de frecuencias óptimas de inspecciones de mantenimiento para tornos paralelos en función del contexto operacional

*Mathematical modeling of optimal maintenance inspection frequencies for parallel lathes as a function of operational context*

- <sup>1</sup> Luis Stalin López Telenchana  <https://orcid.org/0000-0001-7548-0406>  
Maestrante en la Universidad Nacional de Chimborazo, Facultad de Ingeniería, Carrera de Ingeniería Industrial, Universidad Nacional de Chimborazo, Riobamba, Ecuador.  
[luis.lopez@unach.edu.ec](mailto:luis.lopez@unach.edu.ec)
- <sup>2</sup> Cristina Estefanía Ramos Araujo  <https://orcid.org/0000-0002-8644-5814>  
Facultad de Ciencias, Carrera de Estadística, Escuela Superior Politécnica de Chimborazo, Riobamba, Ecuador.  
[cristina.ramos@epoch.edu.ec](mailto:cristina.ramos@epoch.edu.ec)
- <sup>3</sup> Natalia Alexandra Pérez Londo  <https://orcid.org/0000-0001-9068-879>  
Facultad de Ciencias, Carrera de Estadística, Escuela Superior Politécnica de Chimborazo, Riobamba, Ecuador.  
[nperez@epoch.edu.ec](mailto:nperez@epoch.edu.ec)
- <sup>4</sup> Carmen del Rocio Moyón Moyón  <https://orcid.org/0000-0001-8798-7060>  
Investigador Independiente, Riobamba, Ecuador.  
[carmy\\_111@hotmail.com](mailto:carmy_111@hotmail.com)



### Artículo de Investigación Científica y Tecnológica

Enviado: 14/06/2023

Revisado: 22/07/2023

Aceptado: 09/08/2023

Publicado: 22/08/2023

DOI: <https://doi.org/10.33262/concienciadigital.v6i3.2.2667>

### Cítese:

López Telenchana, L. S., Ramos Araujo, C. E., Pérez Londo, N. A., & Moyón Moyón, C. del R. (2023). Modelación matemática de frecuencias óptimas de inspecciones de mantenimiento para tornos paralelos en función del contexto operacional. *ConcienciaDigital*, 6(3.2), 77-96.  
<https://doi.org/10.33262/concienciadigital.v6i3.2.2667>



**CONCIENCIA DIGITAL**, es una revista multidisciplinar, **trimestral**, que se publicará en soporte electrónico tiene como **misión** contribuir a la formación de profesionales competentes con visión humanística y crítica que sean capaces de exponer sus resultados investigativos y científicos en la misma medida que se promueva mediante su intervención cambios positivos en la sociedad. <https://concienciadigital.org>

La revista es editada por la Editorial Ciencia Digital (Editorial de prestigio registrada en la Cámara Ecuatoriana de Libro con No de Afiliación 663) [www.celibro.org.ec](http://www.celibro.org.ec)

Esta revista está protegida bajo una licencia Creative Commons Attribution Non Commercial No Derivatives 4.0 International. Copia de la licencia: <http://creativecommons.org/licenses/by-nc-nd/4.0/>

**Palabras claves:**

Optimización, frecuencias, mantenimiento, bitácora, modelo, autoregresivo, pronóstico.

**Keywords:**

Optimization, frequencies, maintenance, logbook, model, autoregressive, forecasting.

**Resumen**

La optimización de frecuencias de mantenimiento utilizando el pronóstico de ocurrencia de fallas resultado de modelación matemática y en particular a través del empleo de Modelos Autorregresivos Integrado de Promedio Móvil (ARIMA) es un tema que ha venido siendo investigado y desarrollado en los últimos años, debido a que los resultados obtenidos reflejan el aumento de los distintos índices de productividad de las máquinas y equipos intervenidos, es decir se ha comprobado la eficacia, la eficiencia y la efectividad que tiene dichos modelos en la estimación de dichas frecuencias. Se ha aplicado una metodología que parte de la generación de una serie temporal en función de los Tiempos de Buen Funcionamiento (TTF) que se encuentran registrados en las bitácoras de mantenimiento del torno paralelo TR - 01, esta serie es modelada matemáticamente con el objetivo de generar un pronóstico adecuado de la aparición de nuevas fallas, esto permitió reducir indicadores clave de desempeño a nivel industrial como el Tiempo Medio de Reparación y los Costos de Mantenimiento hasta en un 35%, además la repetibilidad y la reproducibilidad de metodología planteada hace que el estudio se pueda implementar en cualquier activo físico.

**Abstract**

The optimization of maintenance frequencies using the prediction of failure occurrence resulting from mathematical modeling and in particular through the use of Autoregressive Integrated Moving Average Models (ARIMA) is a topic that has been investigated and developed in recent years, because the results obtained reflect the increase of the different productivity indexes of the intervened machines and equipment, that is, the efficiency and effectiveness of these models in the estimation of these frequencies has been proven. It has been applied a methodology that starts from the generation of a time series based on the Times of Good Operation (TTF) that are recorded in the maintenance logs of the parallel lathe TR - 01, this series is mathematically modeled with the objective of generating an adequate forecast of the appearance of new failures, this allowed to reduce key performance indicators at industrial level as the Average Time of Repair and Maintenance Costs up to 35%, also the repeatability and

---

reproducibility of the proposed methodology makes that the study can be implemented in any physical asset.

---

## Introducción

En esta última década se ha venido generando investigaciones que muestran que la modelación matemática es una herramienta viable para la optimización de las frecuencias de inspección de mantenimiento. Para la modelación matemática se emplean los distintos contextos operacionales y las frecuencias de reparación, estas dos variables han sido utilizadas exitosamente en el pronóstico de fallas, que es la base de la optimización de las frecuencias de mantenimiento (Zdenek & Rudolf, 2003). Además, múltiples investigaciones publicadas reflejan el interés por parte de la academia de indagar estos casos y la demanda en la práctica por parte de las empresas de los resultados de la optimización del mantenimiento (Vanderschueren et al., 2023).

La optimización de las frecuencias de inspección de mantenimiento es una metodología que se ha desarrollado en los últimos años, convirtiéndose en una herramienta que permite disminuir los costos de intervención de mantenimiento y anticiparse a la ocurrencia de fallas. Investigaciones previas indican que el mantenimiento industrial a nivel de producción es complejo, debido a que debe ser capaz de minimizar fallas imprevistas y evitar revisiones con altos costos para la empresa (Pinciroli et al., 2023).

Por otra parte, la eficacia y la eficiencia de la gestión de mantenimiento está ligada a la adquisición, utilización y rotación adecuada de repuestos y elementos fungibles, descartando de esta manera la política de mantenimiento correctivo. Es por ello, que un modelo matemático que utiliza datos históricos de las intervenciones de mantenimiento, el contexto operacional de producción y la rotación de repuesto, es considerado preciso para la optimización de las frecuencias de inspección de mantenimiento, en comparación con otras metodologías reactivas (Zahedi-Hosseini, 2018).

La importancia de utilizar el contexto operacional de un activo físico en la modelación matemática radica en la influencia que tiene esta condición para que las máquinas no estén disponibles todo el tiempo, esto se debe a fallos inesperados o programaciones de tareas establecida, cabe recalcar, que las máquinas en producción real tienen distintos lapsos de tiempos en donde están paralizadas debido a fallos no programados o intervenciones de inspecciones de mantenimiento preventivo que buscan anticiparse a la ocurrencia de fallas y evitar que el activo llegue a un estado de avería (Zhang et al., 2021).

En la actualidad el desarrollo de planes de mantenimiento industrial tiene fundamentación en la utilización de herramientas y técnicas propias de ingeniería, que van desde la

creación de algorítmicos mediante modelación matemática hasta el pronóstico de posibles escenarios, en estos modelos es indispensable incluir las restricciones de la organización, esto permite que el plan de mantenimiento potencialice tanto la realización y programación de las distintas tareas (Parreño et al., 2021). En este sentido la modelación matemática permite pronosticar la ocurrencia de fallas, optimizando las frecuencias de inspección de mantenimiento, con esto se puede diseñar e implementar planes adecuados de mantenimiento, sin que signifique un aumento del uso de recursos de la organización (Rodas & Castrillón, 2019).

Varios estudios han determinado que el pronóstico de las frecuencias de mantenimiento preventivo es relevante en la planificación a nivel de gestión, las predicciones ayudan a la toma adecuada de decisiones a partir de los datos históricos (Melo & Santana, 2016). La modelación matemática de un procedimiento industrial involucra varias estrategias que permiten optimizar el mantenimiento mediante el pronóstico de fallas, con el objetivo de anticiparse a la ocurrencia de estas (Abdullah et al., 2017).

En la literatura científica se ha encontrado que los modelos lineales ARIMA (p, d, q) de Box-Jenkins son aplicados en el pronóstico de series temporales no estacionarias, es decir que la media y la varianza cambia a través del tiempo. (Ho et al., 2002). En máquinas de herramientas como los tornos paralelos, las frecuencias de inspección de mantenimiento establecen reemplazos innecesarios, tanto de repuestos como de material fungible, aumentando así los costos de mantenimiento. Por esta razón, una metodología que combine el pronóstico de la aparición de fallas mediante promedio móvil autorregresivo (ARIMA) y las condiciones habituales de uso de las máquinas generan una optimización correcta, logrando disminuir de forma considerable los costos de mantenimiento (Baptista et al., 2018).

Se ha considerado que mediante modelos autorregresivos se puede describir el comportamiento de series temporales y proyectar valores futuros. Los modelos ARIMA han permitido capturar de forma natural las distintas propiedades empíricas de los datos interrelacionados temporalmente como una herramienta confiable (Mazón & Buñay, 2022). La toma de decisiones en función de las inspecciones de mantenimiento está dividida en dos etapas, la primera el diagnóstico y la segunda el pronóstico (Jimenez-Cortadi et al., 2019).

### Metodología

La presente investigación tiene un enfoque cuantitativo, que tiene un conjunto de procesos secuenciales: recolectar, organizar, analizar y pronosticar la variable en estudio. El diseño de la investigación es de tipo no experimental, se trabaja con datos históricos provenientes de bitácoras de mantenimiento (Hernández-Sampieri, 2018).

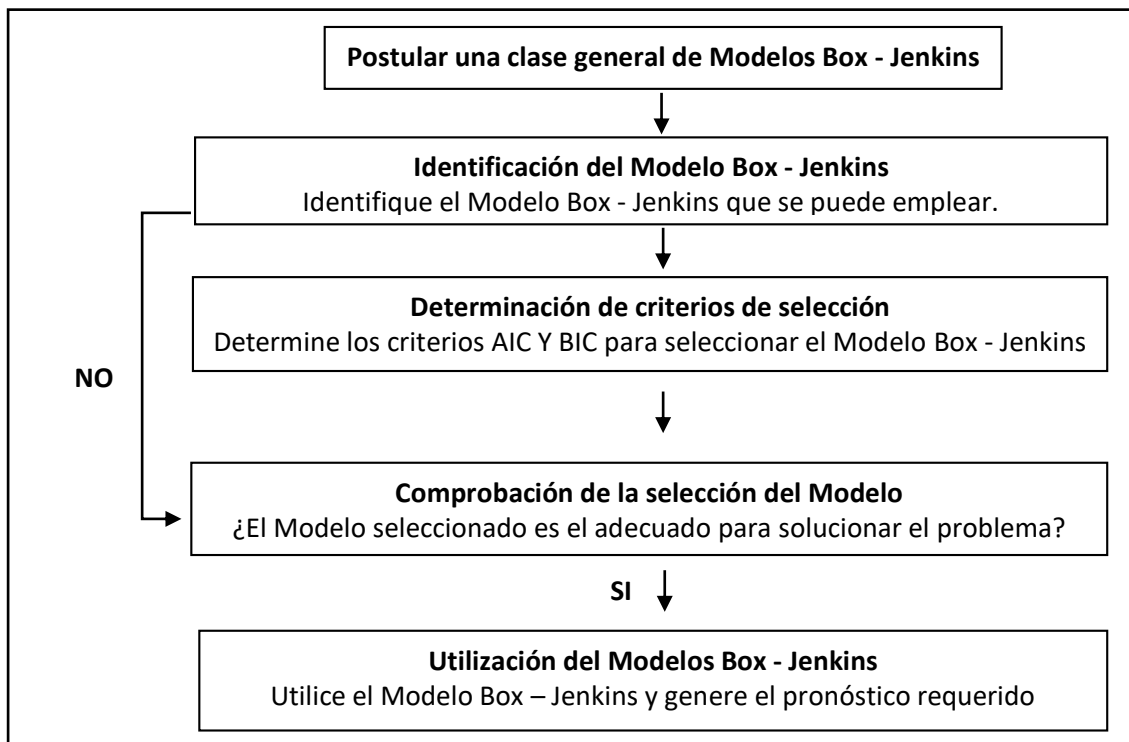
Se ha utilizado 15 bitácoras de mantenimiento de torno paralelo TR-01 que van desde Enero del 2013 hasta Febrero del 2020, en donde se encuentran 86 registros de fallas, de los cuales 47 corresponden a fallas inherentes a las bandas que transmiten la potencia desde el motor principal y que es el elemento con mayor criticidad del torno paralelo intervenido, y los 39 registros restantes son cambios programados, que fueron recolectados en las bitácora de mantenimiento del Laboratorio de Máquinas Herramientas de la Universidad Nacional de Chimborazo.

La metodología utilizada en la presente investigación consiste en un proceso conformado por una secuencia de procedimientos: recolección de los datos, análisis de datos e implementación del modelo Box-Jenkins más adecuado para la serie temporal. El modelado de cualquier serie de tiempo tiene como finalidad el poder predecir el patrón de la evolución temporal (Taneja et al., 2016). El modelo más utilizado para conseguir un pronóstico adecuado es el modelo autorregresivo integrado de media móvil ARIMA (Box et al., 1994).

La implementación del modelo Box-Jenkins puede ser desarrollado mediante cuatro etapas, como se muestra en la Figura 1:

Figura 1

Fases de implementación del modelo Box-Jenkins



Nota: Proceso para la implementación de distintos Modelos Box - Jenkins

Fuente: Adhikari & Agrawal (2013)

El proceso parte de identificar el modelo apropiado, continúa con la estimación de los parámetros, después realiza una comprobación del diagnóstico en la serie temporal y finalmente genera el pronóstico requerido (Adhikari & Agrawal, 2013). Para identificar el modelo ARIMA apropiado se verifica la estacionariedad de la serie temporal, esto debido a que no tienen un proceso estocástico específico (Pindyck & Rubinfeld, 1998).

Se aplica el método de diferenciación a la serie temporal con el objetivo de desaparecer la estacionalidad, luego se comprueba la estacionariedad mediante la prueba de raíz unitaria. Se ha utilizado el contraste de Dickey-Fuller que detecta estadísticamente la presencia de conducta tendencial estocástica en las series temporales mediante un contraste de hipótesis (Dickey & Fuller, 1981). Cuando existe tendencia en una serie temporal en un modelo AR (1), el primer regresor tenderá a ser igual o próximo a 1. Esto se debe a la propiedad de reversión a la media de un proceso estocástico estacionario. Esto implica que cuanto más cerca esté el primer coeficiente de un modelo AR (1), más tardarán las observaciones a volver al valor medio. Esto es sinónimo de no estacionariedad, si el proceso estocástico fuera estable, este coeficiente sería menor a 1 o muy próximo a 0.

Se puede diferenciar entre tendencia o no tendencia estocástica en las observaciones en función del número que se le asigne al primer regresor de la autoregresión, esquemáticamente lo acotado se define como (Rodó, 2019):

$H_0: \varphi = 1 \rightarrow$  Tendencia estocástica en las series temporales.

$H_1: \varphi < 1 \rightarrow$  No tendencia estocástica en las series temporales.

Mientras que matemáticamente, se parte de un modelo AR (1):

$$Y_t = a + \varphi Y_{t-1} + \varepsilon$$

Después se resta la variable independiente  $Y_{t-1}$  de ambos lados, tal que:

$$Y_t - Y_{t-1} = a - Y_{t-1} + \varphi Y_{t-1} - Y_{t-1} + \varepsilon - Y_{t-1}$$

Se factoriza y se cambia el parámetro para indicar que es una modificación del original:

$$\varphi Y_{t-1} - Y_{t-1} = Y_{t-1}(\varphi - 1) = Y_{t-1}(\delta - 1)$$

Posteriormente se define el incremento:

$$Y_t - Y_{t-1} = \Delta Y$$

Determinando el nuevo modelo AR (1) como:

$$\Delta Y_t = a + \varphi Y_{t-1} + \varepsilon$$



Estableciendo un nuevo contraste de hipótesis:

$H_0: \delta = 0 \rightarrow$  Tendencia estocástica en las series temporales.

$H_1: \delta < 1 \rightarrow$  No tendencia estocástica en las series temporales.

Cabe resaltar que en los modelos ARIMA  $(p, d, q)$ ,  $p$  es el grado del modelo autorregresivo (AR) y  $q$  es grado del modelo de promedio móvil (MA), finalmente  $d$  es el grado de resta. Después se establecen los términos AR y MA de los datos con la serie de tiempo estacionaria, dichos términos son establecidos mediante las gráficas de función de autocorrelación (ACF), se descompone la serie temporal con el método de Descomposición estacional y de Tendencias con Loess (STL) que es más robusto (Cleveland et al., 1994).

Posteriormente a la identificación de los modelos tentativos, se debe estimar los parámetros del modelo, para ello se diagnostica la idoneidad de los modelos preestablecidos, para seleccionar el mejor modelo, se considera el Criterio de Información de Akaike (AIC), que es una medida de la bondad de ajuste de un modelo estadístico, describe la relación entre el sesgo y varianza en la construcción del modelo, es decir, describe la exactitud y complejidad del modelo (Çankaya & Korbel, 2018), y el Criterio de Información Bayesiano (BIC) o criterio Schwarz (SIC), que también es una medida de bondad de ajuste de un modelo estadístico, se utiliza como un criterio para para la selección de modelos entre un conjunto finito de modelos y está estrechamente relacionado con el (AIC) (Schwarz, 1978).

La aplicación del criterio AIC, se denota como:

$$AIC = 2k - 2\ln(\hat{L}) \quad (1)$$

Donde:

" $k$ " es el número de parámetros de estimación, " $L$ " es el valor máximo de la función de verosimilitud para el modelo ARIMA correspondiente.

La aplicación del criterio BIC o criterio Schwarz (SIC), se denota como:

$$BIC = -2\ln(\hat{L}) + k\ln(n) \quad (1)$$

En donde:

" $n$ " es el tamaño de la muestra; " $k$ " es el número de parámetros de estimación, " $\ln(\hat{L})$ " es la función de log-verosimilitud para el modelo estadístico.

Finalmente, con el modelo seleccionado, se ha generado el pronóstico de la serie temporal con el paquete "forecast" del Software libre RStudio, que ha proporcionado métodos y

herramientas para mostrar y analizar pronósticos de series temporales univariadas, incluyendo el suavizado exponencial a través de modelos de espacio de estado ARIMA (Athanasopoulos et al., 2017), dicho pronóstico sirve como herramienta fundamental tanto para la toma de decisiones como para optimización de las frecuencias de mantenimiento en cualquier activo físico.

### Resultados

Se ha realizado la recopilación de los Tiempos de Buen Funcionamiento (TTF) del torno paralelo TR – 01, logrando obtener los 86 registros mensuales existentes en las 15 bitácoras semestrales de mantenimiento del Laboratorio de Máquinas Herramientas de la Universidad Nacional de Chimborazo, dichos como se muestran en la tabla 1.

**Tabla 1**

*Bitácoras semestrales de mantenimiento 2013*


Bitácora torno paralelo TR-01 (2003 primer semestre)			
TTF (h)	Año y Mes	Año	Mes
107	Octubre 2012 - Marzo 2013	2013	Enero
106	Octubre 2012 - Marzo 2013	2013	Febrero
104	Octubre 2012 - Marzo 2013	2013	Marzo
103	Abril - Agosto 2013	2013	Abril
101	Abril - Agosto 2013	2013	Mayo
101	Abril - Agosto 2013	2013	Junio
Bitácora torno paralelo TR-01 (2003 segundo semestre)			
TTF (h)	Año y Mes	Año	Mes
103	Abril - Agosto 2013	2013	Julio.
103	Abril - Agosto 2013	2013	Agosto
104	Abril - Agosto 2013	2013	Septiembre
106	Octubre 2013 - Marzo 2014	2013	Octubre
106	Octubre 2013 - Marzo 2014	2013	Noviembre
107	Octubre 2013 - Marzo 2014	2013	Diciembre

Se ha graficado los datos de los Tiempos de Buen Funcionamiento (TTF (h)) de las bitácoras de mantenimiento, como se indica en la figura 2.



**Figura 2**


*Transformación de los datos iniciales de TTF (h) en una serie temporal*



Se ha utilizado la función de autocorrelación (ACF), como resultado se establece que la serie es no estacionaria debido a que el valor de autocorrelación no decae de manera exponencial en función del aumento de rezagos en el tiempo, tal como muestra la figura 3.

**Figura 3**


*Gráfica de la Función de Autocorrelación (ACF)*



Se ha realizado la descomposición de la serie temporal mediante el modelo STL, para determinar si existe una componente estacional, como se muestra en la figura 4.

**Figura 4**

*Descomposición de la serie de tiempo medinst a el modelo STL*




Se ha considerado que es necesario eliminar la tendencia y la estacionalidad implícita en la serie tratada. Se ha calculado el número de diferencias requeridas para que la serie de tiempo sea estacionaria, corroborando los resultados mediante una prueba de raíz unitaria (29), que indica necesario realizar otra diferencia con la finalidad de transformar a la serie de tiempo en estacionaria.

Con los resultados se ha establecido que la serie de tiempo formada con los TTF del torno paralelo TR – 01 necesita una diferenciación regular y otra diferenciación estacionaria.

A continuación se aplica a la serie temporal la diferenciación retrasada, misma que devuelve las diferencias adecuadamente rezagadas e iteradas, con la finalidad de eliminar la componente de tendencia, como se muestra en la figura 5.

**Figura 5**

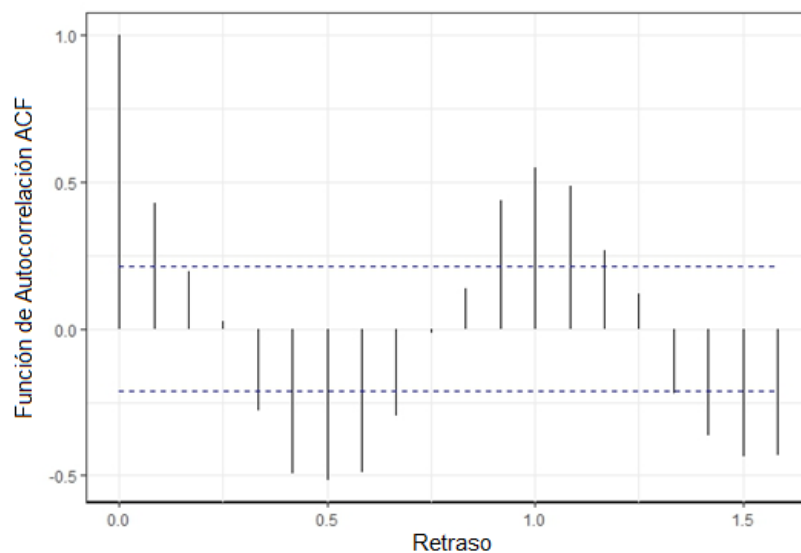
*Serie de tiempo sin tendencia*



Una vez eliminada la tendencia, se vuelve a representar la función de autocorrelación (ACF) como se observa en la figura 6, para analizar si la serie temporal es estacionaria.

**Figura 6**

*Gráfica de la función de autocorrelación (ACF) eliminada la tendencia*



Se ha establecido que la serie de tiempo sigue siendo no estacionaria, esto debido a que la autocorrelación decrece rápidamente en los desfases regulares y de forma lenta en los retardos. Se ha verificado mediante la Prueba de Dickey-Fuller aumentada, donde se establece las hipótesis (Fuller, 1996):

$H_0$  = La serie es no estacionaria, pues tiene raíz unitaria.

$H_1$  = La serie es estacionaria, pues no tiene raíz unitaria.

Mediante la prueba Dickey-Fuller se obtuvo un valor p de 0,01 que es menor al 5% de significancia, se rechaza la hipótesis nula y se concluye que la serie es estacionaria.

Se ha utilizado una variación del algoritmo Hyndman-Khandakar, para determinar los términos (p, d, q) (P, D, Q) del modelo ARIMA, debido a que esta función combina pruebas de raíces unitarias, minimización el criterio de información de Akaike (AIC) y el criterio de información bayesiano (BIC), para obtener un modelo ARIMA apropiado (Hyndman & Khandakar, 2008), donde se ha obtenido los siguientes resultados:

ARIMA (1,1,1) (0,1,1) [12]

AIC=211.55

AICc=212.14

BIC=220.71

Las series con tendencia secular y variaciones cíclicas pueden representarse mediante los modelos ARIMA (p, d, q)(P, D, Q). El primer paréntesis (p, d, q) se refiere a la tendencia secular o parte regular de la serie y el segundo paréntesis (P, D, Q) se refiere a las variaciones estacionales, o parte cíclica de la serie temporal. El hecho de que el modelo identificado sea adecuado no debe descartar la posibilidad de que otro modelo algo más complejo pueda ajustarse mejor a la serie observada (Burnham & Anderson, 2002).

Para comprobar si algún otro modelo ARIMA se ajusta a conveniencia los términos del modelo ARIMA, como se muestra a continuación:

ARIMA 2. (1,1,2) (0,1,1) [12]

ARIMA 3. (1,1,2) (0,2,1) [12]

ARIMA 4. (2,1,1) (0,0,1) [12]

ARIMA 5. (2,1,1) (1,0,1) [12]

Se ha seleccionado el modelo con mejor ajuste, tomando en cuenta el criterio AIC, y el criterio BIC como se muestra en la tabla 2.

**Tabla 2**

*Comparativo de los criterios AIC Y BIC de los modelos ARIMA propuestos*


Modelos propuestos	Criterio AIC	Criterio BIC
ARIMA 1. (1,1,1) (0,1,1) [12]	211,5529	220,7147
ARIMA 2. (1,1,2) (0,1,1) [12]	212,7154	224,1677
ARIMA 3. (1,1,2) (0,2,1) [12]	231,6694	242,2238
ARIMA 4. (2,1,1) (0,0,1) [12]	280,4044	292,6176
ARIMA 5. (2,1,1) (1,0,1) [12]	253,8389	268,4948

Según los criterios AIC y BIC el mejor modelo es ARIMA 1. (1,1,1) (0,1,1) [12], por lo que este modelo es utilizado para generar el pronóstico de los Tiempos de Buen Funcionamiento del torneo paralelo TR-01.

Por último, se generó el pronóstico del comportamiento de la serie temporal, como se muestra en la figura 7.

**Figura 7**

*Pronóstico con el ñ.modelo ARIMA (1,1,1) (0,1,1) [12]*



Los valores obtenidos del pronóstico se muestran en la tabla 3, tanto para el semestre

Abril – Septiembre 2023 y en la Tabla 4 para el semestre Octubre 2023 – Abril 2024.

**Tabla 3**

*Pronóstico de TTF (h) para el semestre Abril – Septiembre 2023*

Mes	Pronóstico (h)	Alto	Bajo
Abril 2023	120	116	125
Mayo 2023	119	114	123
Junio 2023	118	113	122
Julio 2023	118	113	123
Agosto 2023	119	114	124
Septiembre 2023	120	115	125

**Tabla 4**

*Pronóstico de TTF (h) para el semestre Octubre 2023 – Marzo 2024.*

Mes	Pronóstico (h)	Alto	Bajo
<i>Octubre 2023</i>	122	117	126
<i>Noviembre 2023</i>	123	118	128
<i>Diciembre 2023</i>	124	119	129
<i>Enero 2024</i>	125	120	130
<i>Febrero 2024</i>	124	119	129
<i>Marzo 2024</i>	123	118	128

### Discusión

Existen múltiples investigaciones como las desarrolladas por Walls & Bendell (1987) y Ho & Xie (1998), que han empleado modelos ARIMA en series temporales para el análisis y el pronóstico de fallo, con base en nuestro estudio se ha evidenciado que la generación de previsiones ha obtenido un rendimiento predictivo satisfactorio en comparación con otros modelos como el Duane, por otro lado, el proceso de construcción de los modelos ARIMA es iterativos, por lo tanto, la aplicación de estos modelos en series



temporales se ha realizado en software estadístico libre. Los modelos ARIMA han permitido optimizar frecuencias de mantenimiento mediante un adecuado pronóstico de fallos, que también se podría aplicar en cualquier activo físico.

En estudios como los publicados por Ayeleru et al. (2021) y Laurente & Laurente (2019), han aplicado modelos ARIMA para pronosticar la producción, contaminación y gestión industrial, además emplean datos anuales y para la selección del modelo se basan tanto (AIC) y (BIC), de esta manera se ha garantizado la selección del modelo con mayor capacidad de capturar el comportamiento y la proyección tanto de la producción como de la contaminación y la gestión industrial, los resultados de estas investigaciones ayudaron a planificar las actividades de producción. En base a previos resultados, en el presente estudio se ha seleccionado el modelo ARIMA (1,1,1) (0,1,1) [12] que obtuvo el menor valor en la evaluación de los criterios (AIC) y (BIC), dicho modelo ha permitido pronosticar el comportamiento de la serie temporal de los tiempos de buen funcionamiento de las bitácoras del torno paralelo 01, este pronóstico permite planificar de manera adecuada las distintas actividades a nivel industrial que están en función al activo intervenido.

En comparación con el estudio publicado por Montero et al. (2020), la optimización de las frecuencias de mantenimiento se ha reducido los costos de mantenimiento entre un 25 % y un 35 %, se ha eliminado los fallos imprevistos entre un 70 % y un 75 %, ha decrecido el Tiempo Medio de Reparación (MTTR) entre un 35 % y un 45 % y finalmente la producción ha crecido entre un 25 % y un 35 %. En el caso de estudio, de la presente investigación en el semestre Abril – Agosto 2023 los costos de mantenimiento se han reducido en un 35%, se ha eliminado los fallos imprevistos en un 70%, de la misma manera, el MTTR ha decrecido en un 35%, y ha aumentado en 35% la producción proporcional, debe destacarse que el activo físico intervenido ha aumentado su productividad.

### Conclusiones

- Se concluye que mediante modelos ARIMA se ha pronosticado de forma aproximada la aparición de fallas, esto convierte a dichos modelos en una herramienta útil para optimizar las frecuencias de inspección de mantenimiento, logrando de esta manera anticipar la acción preventiva de mantenimiento para evitar paros imprevistos en los tornos paralelos.
- Se determina que utilizando el pronóstico de la modelación matemática se redujeron indicadores de desempeño como el MTTR, el número de fallos imprevistos y los costos de mantenimiento, logrando aumentar los índices de producción hasta un 35%, considerando esta herramienta relevante para la productividad en función del contexto operacional de cualquier activo físico.

- La presente investigación muestra la utilidad de los datos históricos para los analistas de producción y de mantenimiento en su búsqueda por diseñar planes de mantenimiento preventivo, partiendo del estado técnico de un activo y el contexto operacional de las máquinas o equipos.

### Conflicto de intereses

Los autores declaramos que no existe conflicto de intereses en relación con el artículo presentado.

### Referencias Bibliográficas

- Abdullah, A., Ashutosh, T., & Mark S. (2017), Simulation - based optimisation of maintenance systems: Industrial case studies, *Journal of Manufacturing Systems*, 44, Part 1, 191-206. <https://doi.org/10.1016/j.jmsy.2017.05.008>
- Adhikari, R., & Agrawal, R. (2013). Hybridization of artificial neural network and Particle Swarm Optimization methods for time series forecasting. *International Journal of Applied Evolutionary Computation (IJAEC)*, 4(3), 75-90. <https://www.igi-global.com/article/hybridization-of-artificial-neural-network-and-particle-swarm-optimization-methods-for-time-series-forecasting/95960>
- Athanasopoulos, G., Hyndman, R., Kourentzes, N., & Petropoulos, F. (2017). Forecasting with temporal hierarchies, *European Journal of Operational Research*, Volume 262, Issue 1, 2017, Pages 60-74, ISSN 0377-2217, <https://doi.org/10.1016/j.ejor.2017.02.046>.
- Ayeleru, O.O., Fajimi, L.I., Oboirien, B.O., & Olubambi, P.A., (2021). Forecasting municipal solid waste quantity using artificial neural network and supported vector machine techniques: a case study of Johannesburg, South Africa. *J. Clean. Prod.* 289, 125671. <https://doi.org/10.1016/j.jclepro.2020.125671>
- Baptista, M., Sankararaman, S., de Medeiros, I. P., Nascimento, C., Prendinger, H., & Henriques, E. M. P. (2018). Forecasting fault events for predictive maintenance using data-driven techniques and ARMA modeling. *Computers & Industrial Engineering*, 115, 41–53. <https://doi:10.1016/j.cie.2017.10.033>
- Box, G.E.P., Jenkins, G.M., & Reinsel, G.C., 1994. *Time Series Analysis -Forecasting and Control*, third ed. Prentice-Hall, Englewood Cliffs, NJ.
- Burnham, K., & Anderson, D. (2002). *Selección de modelos e inferencia multimodelo: un enfoque práctico de la teoría de la información*. 2ª ed. Nueva York, Springer-

Verlag.

Çankaya, M. N., & Korbel, J. (2018). Least informative distributions in maximum q-log-likelihood estimation. *Physica A: Statistical Mechanics and Its Applications*, 509, 140–150. doi: 10.1016/j.physa.2018.06.004

Cleveland, R., Cleveland, W., McRae, J., & Terpenning, I (1990). “STL: A Seasonal-Trend Decomposition.” *Journal of Official Statistics* 6 (1): 3–73.  
<https://www.wessa.net/download/stl.pdf>

Dickey, D. A., & Fuller, W. A. (1981). Likelihood ratio statistics for autoregressive time series with a unit root. *Econometrica: journal of the Econometric Society*, 1057-1072. <https://www.jstor.org/stable/1912517>

Fuller, W. A. (1996). *Introduction to Statistical Time Series*, second ed., New York: John Wiley and Sons.

Hernández-Sampieri, Roberto. (2018). *Metodología de la investigación: Las rutas cuantitativa y cualitativa y mixta*. México: Mc Graw Hill- Educación.

Ho, S., & Xie, M., (1998). The use of ARIMA models for reliability forecasting and analysis, *Computers & Industrial Engineering*, 35(1–2), 213-216, ISSN 0360-8352, [https://doi.org/10.1016/S0360-8352\(98\)00066-7](https://doi.org/10.1016/S0360-8352(98)00066-7).  
(<https://www.sciencedirect.com/science/article/pii/S0360835298000667>)

Ho, S., Xie, M., & Goh, T., (2002) A comparative study of neural network and Box-Jenkins ARIMA modeling in time series prediction, *Computers & Industrial Engineering*, 42 (2–4), 371-375, ISSN 0360-8352,  
[https://doi.org/10.1016/S0360-8352\(02\)00036-0](https://doi.org/10.1016/S0360-8352(02)00036-0).  
[http://www.scielo.org.bo/scielo.php?script=sci\\_arttext&pid=S2409-16182019000100006&lng=es&tlng=es](http://www.scielo.org.bo/scielo.php?script=sci_arttext&pid=S2409-16182019000100006&lng=es&tlng=es).

Hyndman, R., & Khandakar, Y. (2008). Automatic Time Series Forecasting: The forecast Package for R. *Journal of Statistical Software*, 27(3), 1–22.  
<https://doi.org/10.18637/jss.v027.i03>

Jimenez-Cortadi, A., Irigoien, I., Boto, F., Sierra, B., & Rodríguez, G. (2019). Predictive Maintenance on the Machining Process and Machine Tool. *Applied Sciences*, 10(1), 224. <http://doi:10.3390/app10010224>

Laurente, L., & Laurente, F. (2019). Aplicación del modelo ARIMA para la producción de la papa en la región de Puno-Perú. *Revista de Investigación e Innovación Agropecuaria y de Recursos Naturales*, 6(1), 30-40.

- Mazón Fierro, G. J., & Buñay Guisñan, P. A. (2022). Análisis exploratorio entre modelos matemáticos predictivos, aplicados a la producción de energía mediante series temporales. *ConcienciaDigital*, 5(3.1),57-78.  
<https://doi.org/10.33262/concienciadigital.v5i3.1.2223>.
- Melo, J., & Santana, G. (2016). Minado de series de tiempo utilizando la metodología ARIMA. *Revista de Investigación y Desarrollo*, 2-5: 21-31. ISSN-2444-4987.  
[https://www.ecorfan.org/spain/researchjournals/Investigacion\\_y\\_Desarrollo/vol2\\_num5/Revista\\_de\\_Investigaci%C3%B3n\\_y\\_Desarrollo\\_V2\\_N5\\_3.pdf](https://www.ecorfan.org/spain/researchjournals/Investigacion_y_Desarrollo/vol2_num5/Revista_de_Investigaci%C3%B3n_y_Desarrollo_V2_N5_3.pdf)
- Montero, J., Schwartz, S., Vingerhoeds, R., Grabot, B., & Salaün, M. (2020). Towards multi-model approaches to predictive maintenance: A systematic literature survey on diagnostics and prognostics. *Journal of Manufacturing Systems*, 56, 539–557. <https://doi:10.1016/j.jmsy.2020.07.008>.
- Parreño, F., Parreño C., & Alvarez P. (2023). A matheuristic algorithm for the maintenance planning problem at an electricity transmission system operator, *Expert Systems with Applications*, 230, ISSN 0957-4174,  
<https://doi.org/10.1016/j.eswa.2023.120583>.
- Pinciroli, L., Baraldi, P., & Zio, E. (2023) Maintenance optimization in industry 4.0, *Reliability Engineering & System Safety*, 234, ISSN 0951-  
<https://doi.org/10.1016/j.ress.2023.109204>.
- Pindyck, R. S., & Rubinfeld, D. L. (1998). Econometric models and economic forecasts. (No Title). <https://cir.nii.ac.jp/crid/1130000795059255552>
- Rodas, L., & Castrillón, O. (2019). Predicción de Fallos Mecánicos en Equipos de Envoltura. *Información tecnológica*, 30(6), 111-122.  
<https://dx.doi.org/10.4067/S0718-07642019000600111>
- Rodó, P. (2019, julio 30). Contraste de Dickey-Fuller. *Economipedia.com*
- Schwarz, G. (1978). Estimating the dimension of a model. *The annals of statistics*, 461-464. <https://www.jstor.org/stable/2958889>
- Taneja, K., Ahmad, S., Ahmad, K., & Attri, S. (2016). Time series analysis of aerosol optical depth over New Delhi using Box–Jenkins ARIMA modeling approach, *Atmospheric Pollution Research*, 7(4), 585-596, ISSN 1309-1042,  
<https://doi.org/10.1016/j.apr.2016.02.004>.
- Vanderschueren, T., Boute, R., Verdonck, T., Baesens, B., & Verbeke, W. (2023). Optimizing the preventive maintenance frequency with causal machine learning, *International Journal of Production Economics*, 258, ISSN 0925-5273,

<https://doi.org/10.1016/j.ijpe.2023.108798>.

Walls, L., & Bendell, A., (1987). Time series methods in reliability, *Reliability Engineering*, Volume 18, Issue 4, 1987, Pages 239-265, ISSN 0143-8174, [https://doi.org/10.1016/0143-8174\(87\)90030-8](https://doi.org/10.1016/0143-8174(87)90030-8).

Zahedi-Hosseini, F. (2018). Modeling and simulation for the joint maintenance-inventory optimization of production systems. *Winter Simulation Conference (WSC)*. 3264-3274. <https://doi:10.1109/wsc.2018.8632283>.

Zdenek, V. & Rudolf, H. (2003). Preventive maintenance optimization on the basis of operating data analysis. *Annual Reliability and Maintainability Symposium*, 400-406. <https://doi:10.1109/rams.2003.1182022>.

Zhang, Z., Tang, Q., & Chica, M. (2021). Maintenance costs and makespan minimization for assembly permutation flow shop scheduling by considering preventive and corrective maintenance. *Journal of Manufacturing Systems*, 59, 549 -564. <https://doi:10.1016/j.jmsy.2021.03.020>

El artículo que se publica es de exclusiva responsabilidad de los autores y no necesariamente reflejan el pensamiento de la **Revista Conciencia Digital**.



El artículo queda en propiedad de la revista y, por tanto, su publicación parcial y/o total en otro medio tiene que ser autorizado por el director de la **Revista Conciencia Digital**.



#### Indexaciones

