

Análisis de series de tiempo del índice de empleo privado en Bolivia

Teddy Horacio Álvarez Zarate

teddyhoracioa@gmail.com

Instituto Técnico Superior Corporación Cibernética Americana
(0009-0004-5995-6207)

Resumen: Este documento de investigación contiene la evaluación de las técnicas de series de tiempo para la elaboración del pronóstico del Índice de Empleo privado en Bolivia.

El presente trabajo está basado en la construcción de un modelo autorregresivo integrado de medias móviles, denominado también, modelo ARIMA, para de esta forma conocer la evolución histórica de una variable a través del tiempo y poder realizar pronósticos hacia el futuro.

Se hará especial énfasis a nivel teórico para la aplicación de un caso real como lo es el Índice de Empleo Privado en Bolivia, identificando si la serie de tiempo observada presenta propiedades de estacionariedad a través de pruebas de hipótesis. Así mismo se usaron diferentes técnicas de validación del modelo como ser, gráficos de tendencia, identificación de procesos a través de la lectura de correlograma y la construcción de un modelo para hacer el pronóstico y por último evaluar la capacidad predictiva de modelo construido

La información que se empleó para la presente investigación ha sido obtenida de la página oficial de la UDAPE (Unidad de Análisis de Políticas Económicas) cuyos datos están ordenados trimestralmente a partir del año 1996 hasta el año 2022.

La idea de la técnica de la serie de tiempo es procurar elaborar un modelo econométrico que replique a la serie original para hacer una proyección hacia adelante. Así se concluye que la técnica de análisis de series de tiempo es adecuada para modelar el comportamiento cronológico de la serie observada.

Palabras-clave: Análisis econométrico; Índice de empleo privado; Modelos ARIMA; Series de tiempo.

Time series analysis of the private employment index in Bolivia

Abstract: This research paper evaluates time series analysis techniques for forecasting the Private Employment Index in Bolivia. The study is based on the construction of an Autoregressive Integrated Moving Average (ARIMA) model, which allows us to analyze the historical evolution of a variable over time and make future predictions. Special emphasis is placed on the theoretical aspects of applying this model to a real-world case, specifically the Private Employment Index in Bolivia. The analysis identifies whether the observed time series exhibits stationarity through hypothesis testing. Various model validation techniques were used, including trend graphs, autocorrelation function (ACF) analysis, and model building for forecasting. Finally, the predictive capacity of the constructed model was evaluated. The data used in this research were obtained from the official website of UDAPE (Economic Policy Analysis Unit), and cover quarterly data from 1996 to 2022. The objective of using time series analysis is to develop an econometric model that replicates the original data series, enabling future projections. The conclusion is that time series analysis is an appropriate technique for modeling the temporal behavior of the observed data.

Keywords: Econometric analysis; Private employment index; ARIMA models; Time series.

Solo para uso editorial

Cómo citar: Alvarez. (2025). ANALISIS DE SERIES DE TIEMPO DEL INDICE DE EMPLEO PRIVADO EN BOLIVIA. *PERSPECTIVA Revista Científica de Economía*, 2(01), pp. 26-44.

Recibido: 15/07/00 **Revisado:** 10/08/25 **Aprobado:** 23/10/25 **Publicado:** 28/10/25

1. Introducción

Dentro de lo que es el análisis económico, el empleo es uno de los pilares fundamentales en el desarrollo de un país ya que el mismo refleja la dinámica productiva que a su vez deriva en el crecimiento económico de los países.

En el contexto nacional, el empleo y sus connotaciones sociales son sin duda un aspecto a analizar dado que este sector es el principal articulador de la economía y su desarrollo y potenciamiento es clave para generar riqueza y lograr la distribución de los ingresos nacionales a las familias.

En los últimos años el empleo, y sobre todo el del sector privado ha cobrado mayor relevancia, dado su aporte al crecimiento de la economía del país, donde los emprendimientos privados vienen a cubrir las falencias creadas en el sector público como ser la alta politización de los cargos públicos que en muchos casos no toman en cuenta la calidad de formación laboral de los trabajadores, relegándoles al sector informal donde no gozan de los beneficios de contar con un empleo que respete proteja sus derechos laborales.

Es así que es importante en estos tiempos dar énfasis al empleo en el sector privado que, junto al sector público, promuevan la creación de nuevas fuentes de empleo de calidad y sea, sobre todo el empleo del sector privado, sea protagonista de la creación de riqueza y por ende del crecimiento económico del país, por lo que conocer su evolución y proyección a través del tiempo, podrá coadyuvar a la generación de políticas para la inserción de trabajadores del sector informal al sector formal en el corto y mediano plazo. En las secciones que siguen se describen los formatos que se deben usar en los títulos, subtítulos y en el texto final de los documentos, así como los formatos para las leyendas de las tablas, figuras y normas de las referencias bibliográficas.

2. Marco teórico

2.1. Series de tiempo

Stock-Watson (2012) indican que los datos de series temporales – datos registrados para una única entidad individual para varios momentos del tiempo- pueden utilizarse para responder a preguntas cuantitativas para las que los datos de sección cruzada resultan inadecuados.

Los componentes de una serie de tiempo de acuerdo a Levin-Rubin (2010) utilizamos el termino de serie de tiempo para referirnos a cualquier grupo de información estadística que se acumula a intervalos regulares. Con respecto a una

PERSPECTIVA

Revista científica de Economía

UMRPSFXCH

FCEE

variable de interés, existen cuatro tipos de cambio o variación implicados en el análisis de series de tiempo, estos son:

a) Tendencia secular o variación secular. - Con este tipo de variación, la tendencia secular, el valor de la variable tiende a aumentar o disminuir en un periodo muy largo

b) Fluctuación cíclica o variación cíclica. - El segundo tipo de variación observado en una serie de tiempo es la fluctuación cíclica. El ejemplo más común de fluctuación cíclica es el ciclo económico.

c) Variación estacional. - El tercer tipo de cambio en los datos de una serie de tiempo es la variación estacional. Como cabe esperar este tipo de variación implica patrones de cambio en el lapso de un año que tienden a repetirse anualmente

d) Variación irregular. - La variación irregular es el cuarto tipo de cambio que ocurre en el análisis de las series de tiempo. En muchas situaciones, el valor de la variable puede ser completamente impredecible cambiando de manera aleatoria.

2.2. Procesos estocásticos estacionarios

Para Gujarati (2010) un proceso estocástico o aleatorio, es una colección de variables aleatorias ordenadas en el tiempo. Una serie temporal Y_t , es estacionaria si su distribución de probabilidad no varía en el tiempo, es decir, si la distribución conjunta de $(Y_{s+1}, Y_{s+2}, \dots, Y_{s+T})$ no depende de s sea cual sea el valor de T ; de lo contrario se dice que la serie Y_t no es estacionaria (Stock-Watson 2012)

En términos generales se dice que un proceso estocástico es estacionario si su media y su varianza son constantes en el tiempo y si el valor de la covarianza entre dos periodos depende solo de distancia o rezago entre estos dos periodos y no del tiempo en el cual se calculó la covarianza (Gujarati, 2009)

2.3. Modelos autorregresivos

Autorregresión es un modelo de regresión que relaciona una variable de series temporales con sus valores pasados (Stock-Watson 2012).

2.4. Pruebas para evaluar la estacionariedad del modelo**a) Phillips-Perron (PP)**

Esta prueba estima una regresión haciendo una corrección sobre la matriz de varianzas y covarianzas de los residuos. La corrección es mediante un método no paramétrico. En esta se estima la siguiente regresión:

$$\Delta x_t = \Delta\beta + \rho x_{t-1} + w_t$$

A diferencia de la prueba ADF, no existen términos de diferencias retardados. La hipótesis nula H_0 del test de Phillips-Perron es la trayectoria de raíz unitaria con tendencia y la alternativa la estacionariedad con tendencia, si el valor t asociado al coeficiente de x_{t-1} es mayor en valor absoluto al estadístico de MacKinnon, se rechaza la hipótesis nula de existencia de raíz unitaria. (Instituto Científico del Pacífico, 2025)

b) Dickey-Fuller (DF)

Es el modelo más simple para evaluar la presencia de raíz unitaria, este modelo viene dado por: $\Delta x_t = \alpha + \delta x_{t-1} + w_t$ El contraste será el siguiente: • $H_0: \delta = 0 \rightarrow$ Existe raíz unitaria, x_t no es estacionaria. • $H_1: \delta \neq 0 \rightarrow$ No existe raíz unitaria, x_t es estacionaria. Si: • τ -calculado en valor absoluto $>$ τ -crítico en valor absoluto: Se rechaza H_0 . • τ -calculado en valor absoluto $<$ τ -crítico en valor absoluto: Se acepta H_0 . (Instituto Científico del Pacífico, 2025)

c) Kwiatkowski-Phillips-Smichdt-Shin (KPSS)

En esta prueba se propone contrastar como hipótesis nula la estacionariedad de las tendencias, esta es la principal diferencia con las pruebas de raíz unitaria. El contraste es el siguiente:

H_0 : La serie es estacionaria.

H_1 : La serie no es estacionaria.

Si:

- Valor calculado $>$ Valor crítico: Se rechaza la H_0 .
- Valor calculado $<$ Valor crítico: Se acepta la H_0 . (Instituto Científico del Pacífico, 2025)

2.5. Modelos ARIMA

La publicación de G.P.E Box y G. M. Jenkins Time series Analysis: Forecasting and Control, op, cit., marco el comienzo de una nueva generación de herramientas de pronóstico. Popularmente conocida como la metodología Box-Jenkins, pero técnicamente conocida como la metodología ARIMA, el interés de estos métodos de pronósticos no está en la construcción de modelos uniecuacionales o de ecuaciones simultaneas, sino en el análisis de las propiedades probabilísticas, o estocásticas, de las series de tiempo económicas por si mismas según la filosofía de que los datos hablen por si mismos. A diferencia de los métodos de regresión, en los cuales Y_t se explica por los regresores $X_1, X_2, X_3, \dots, X_k$, en los modelos de series de tiempo del tipo BJ, Y_t se explica por valores pasados o rezagados de si misma y por los términos de error estocásticos. Por esta razón los modelos ARIMA reciben algunas veces el nombre de modelos ateóricos – porque no se derivan de teoría económica alguna -, y las teorías económicas a menudo son la base de los modelos de ecuaciones simultaneas. (Guajarati 2010).

2.6. Correlogramas

Las herramientas principales en la identificación son la función de autocorrelación (FAC), la función de autocorrelación parcial (FACP) y los correlogramas resultantes que son simplemente los gráficos de FAC y de FACP respecto de la longitud del rezago. (Guajarati 2009).

2.7. AIC

El Criterio de Información de Akaike (AIC) se utiliza para seleccionar modelos estadísticos penalizando la complejidad. Su fórmula es:

$$AIC_{(p)} = \ln \left[\frac{SR_{(p)}}{T} \right] + (p + 1) \frac{2}{T}$$

- **SR(p)**: suma de residuos del modelo con pp retardos.
- **T**: número de observaciones.
- **(p + 1)**: número total de parámetros estimados (incluye el término de error).

El AIC penaliza menos que el BIC porque usa el número **2** en lugar de **ln(T)**, lo que lo hace más flexible para aceptar modelos con más parámetros si la mejora en el ajuste lo justifica. Sin embargo, esto puede llevar a sobreestimar el número de

retardos en muestras grandes. Stock – Watson. (2012). *Introducción a la econometría* (3ª ed.). Pearson

Una serie de tiempo es un conjunto de valores observados, tales como datos de producción o ventas, para series ordenadas secuencialmente de periodos de tiempo.

3. Metodología

La presente investigación se basa en un análisis cuantitativo de serie de tiempo del Índice de Empleo privado en Bolivia. Los datos obtenidos para la misma corresponden a la UDAPE (Unidad de Análisis de Políticas Económicas) correspondientes a los periodos comprendidos entre 1996 a 2022.

En primera instancia se realiza un análisis grafico de la serie observada para identificar tendencias, ciclos y posibles patrones estacionales, para luego dar paso a pruebas de hipótesis con el objetivo de detectar estacionariedad en la serie. Posterior a la detección de estacionariedad, se realizan pruebas para determinar el orden de integración de la serie de tiempo.

Luego se emplea la metodología Box-Jenkins con el objetivo de construir modelos autorregresivos integrados de medias móviles (ARIMA) mediante la lectura de correlogramas de autocorrelación y autocorrelación parcial. Los pasos de la metodología Box-Jenkins son los siguientes:

- Identificación del modelo
- Estimación de parámetros
- Diagnóstico del modelo
- Proyección y validación

Finalmente se elige el modelo que más se ajuste mediante el criterio AIC, el cual se utiliza para hacer la proyección del índice de empleo privado. El procesamiento, análisis y modelado se realiza usando el software R.

4. Resultados

Centramos la investigación en la metodología Box-Jenkins que es la metodología para la construcción y diseño de modelos de series de tiempo para pronósticos, que es un conjunto de pasos que nombran a continuación:

4.1. Identificación del modelo

4.1.1. Revisión grafica de la serie

En el siguiente grafico se muestra el índice de empleo del sector privado desde el año 1996 hasta el año 2022:




Figura 2 – Índice de empleo privado en Bolivia

4.1.2. Evaluación de la estacionariedad de la serie en cuestión

Una serie de tiempo es estacionaria si su media, varianza y autocovarianza no cambian con el tiempo. Aunque es suficiente con que la estacionariedad sea en sentido débil, esto es, que la media al igual que la varianza de la serie de tiempo sean iguales o constantes a través del tiempo. La estacionariedad es importante porque simplifica el análisis de series de tiempo y permite obtener predicciones fiables de modelos.

Para evaluar la estacionariedad de la serie de tiempo usamos las siguientes pruebas formales:

- Prueba de Dickey - Fuller
- Prueba de Phillip – Perron
- Prueba de Kwiatkowski-Phillips-Smichdt-Shin (KPSS)

PERSPECTIVA

Revista científica de Economía

UMRPSFXCH

FCEE

Las hipótesis tanto nula como alternativa que se plantean para todas pruebas de estacionariedad, excepto la prueba Kwiatkowski-Phillips-Smichdt-Shin (KPSS), son las siguientes:

H₀: La serie de tiempo tiene raíz unitaria (no es estacionaria)

H₁: La serie de tiempo no tiene raíz unitaria (es estacionaria)

Que la serie de tiempo en estudio tenga raíz unitaria significa que esta serie no permite obtener predicciones fiables, ósea que hace que la serie sea impredecible.

El criterio de decisión respecto a rechazar o aceptar la hipótesis nula se describe en el cuadro siguiente:

Tabla 1 - Criterios de decisión para las pruebas de Dickey – Fuller y Phillip – Perron

Criterio de decisión	Hipótesis
Si: p-valor < valores críticos	H ₀ : Hipótesis nula (Se rechaza) H ₁ : Hipótesis alternativa
Si: p-valor > valores críticos	H ₀ : Hipótesis nula (Se acepta) H ₁ : Hipótesis alternativa

Para la prueba Kwiatkowski-Phillips-Smichdt-Shin (KPSS), las hipótesis tanto nula como alternativa se plantea de la siguiente forma:

H₀: La serie de tiempo no tiene raíz unitaria (es estacionaria)

H₁: La serie de tiempo tiene raíz unitaria (no es estacionaria)

El criterio de decisión respecto a rechazar o aceptar la hipótesis nula se describe en el cuadro siguiente:

Tabla 2 - Criterios de decisión para la prueba de Kwiatkowski-Phillips-Smichdt-Shin

Criterio de decisión	Hipótesis
Si: p-valor < valores críticos	H ₀ : Hipótesis nula (Se acepta) H ₁ : Hipótesis alternativa
Si: p-valor > valores críticos	H ₀ : Hipótesis nula (Se rechaza) H ₁ : Hipótesis alternativa

a) Prueba de Dickey – Fuller

La prueba de Dickey-Fuller es una prueba estadística que se usa para determinar si una serie de tiempo es estacionaria, es decir, si sus propiedades estadísticas se

PERSPECTIVA

Revista científica de Economía

UMRPSFXCH

FCEE

mantienen constantes a lo largo del tiempo, evaluando la presencia de una raíz unitaria.

Haciendo uso del software R para la prueba Dickey – Fuller, obtenemos los siguientes resultados:

```
## Value of test-statistic is: -2.0576
## Critical values for test statistics:
## 1pct 5pct 10pct
## tau3 -3.99 -3.43 -3.13
```

Podemos ver que en términos absolutos el valor calculado del test o el p-valor es de 2.0576, que es mayor a los valores críticos al 1%, 5% y 10% son 3.99, 3.43 y 3.13 respectivamente, por lo que no se rechaza la hipótesis nula y se concluye que la serie de tiempo en estudio es unitaria, o lo mismo que, no existe estacionariedad en la serie de tiempo.

b) Prueba de Phillip – Perrón

La prueba de Phillip – Perrón es una prueba de raíz unitaria que se utiliza en el análisis de series de tiempo para determinar si una serie es no estacionaria. A diferencia de otras pruebas como la de Dickey-Fuller aumentada, la prueba de Phillips - Perrón es robusta frente a la autocorrelación y la heterocedasticidad en los errores del modelo, lo que significa que puede identificar la presencia de una raíz unitaria incluso cuando las propiedades estadísticas de la serie cambian con el tiempo.

Los resultados obtenidos son los siguientes:

```
## Value of test-statistic, type: Z-tau is: -2.0165
## Critical values for Z statistics:
##          1pct      5pct      10pct
## critical values -4.046009 -3.451905 -3.15116
```

En esta prueba, en términos absolutos, el valor calculado de la prueba es 2.0165 que es menor a los valores críticos al 1%, 5% y 10% son 4.04, 3.45 y 3.15 respectivamente por lo que no se rechaza la hipótesis nula y se concluye que la serie de tiempo en estudio es unitaria, o lo mismo que, no existe estacionariedad en la serie de tiempo.

c) Prueba de Kwiatkowski-Phillips-Schmidt-Shin (KPSS)

La prueba de Kwiatkowski-Phillips-Schmidt-Shin (KPSS) es una prueba estadística para determinar si una serie temporal es estacionaria en torno a una tendencia determinista o si, por el contrario, es no estacionaria debido a una raíz unitaria. A diferencia de pruebas como la ADF, la hipótesis nula de la prueba KPSS es que la serie es estacionaria, y se rechaza si el valor p es menor que el nivel de significancia, lo que indica la presencia de no estacionariedad.

Los resultados obtenidos son los siguientes:

```
## Value of test-statistic is: 0.4038
## Critical value for a significance level of:
##          10pct 5pct 2.5pct 1pct
## critical values 0.119 0.146 0.176 0.216
```

Se obtiene un p-valor de 0.4038 que es mayor para cualquiera de los valores críticos al 10%, 5% y 2.5% y 1% son 0.119, 0.146, 0.176 y 0.216 respectivamente por lo que se rechaza la hipótesis nula y se concluye que la serie de tiempo en estudio es unitaria, o lo mismo que, no existe estacionariedad en la serie de tiempo.

4.1.3. Diferenciación de la serie

Ya que se sabe que la serie debe ser diferenciada, se trabajó con la función “ndiffs” del software R para saber cuántas veces debemos diferenciar la serie en estudio, para lo cual se cuenta con tres opciones dentro de la función “ndiffs” para saber las veces que se deben diferenciar la serie, estas son:

- Prueba Kpss
- Prueba Dickey – Fuller aumentada (ADF)
- Prueba Phillip - Perron

Los resultados obtenidos se muestran a continuación

```
ndiffs(desemp_ts, test = c("kpss"))
```

```
## [1] 1
```

```
ndiffs(desemp_ts, test = c("adf"))
```

```
## [1] 1
```

```
ndiffs(desemp_ts, test = c("pp"))
```

```
## [1] 1
```

De acuerdo a las tres pruebas usadas, las veces que se debe diferenciar la serie en estudio es de una sola vez.

4.1.4. Identificación de procesos a través de la lectura del correlograma

¿Cuántos rezagos tengo que incorporar en el modelo de serie de tiempo para que explique a la variable dependiente, de tal manera que al incorporar estos rezagos mi modelo replique de mejor forma a la serie original y por tanto sirva para hacer una proyección a futuro?. Esta pregunta se responde con dos funciones, la función de autocorrelación simple (ACF) y la función de autocorrelación parcial (PACF). Estas funciones también nos dicen cuántas medias móviles (MA) y cuantos autorregresivos (AR), respectivamente, se deben incorporar al modelo.

Los correlogramas obtenidos en el software R para la serie en estudio se muestran a continuación:




Figura 2 – Correlogramas para la funcion de autocorrelacion simple (ACF) y autocorrelacion parcial) para determinar los regresores AR y MA

a) Correlograma izquierdo (ACF)

En el rezago 1 hay una barra negativa que sobresale de las bandas de confianza (líneas segmentadas azules). Luego, los demás rezagos caen dentro de las bandas

PERSPECTIVA

Revista científica de Economía

UMRPSFXCH

FCEE

(no significativos), esto es característico de un MA(1), porque la ACF se corta en el primer rezago.

b) Correlograma derecho (PACF)

En el rezago 1 también sobresale una barra significativa, negativa. En los rezagos 2, 3, 4, etc., las barras son pequeñas y no tan claramente significativas, esto es compatible con un AR(1), porque la PACF se corta en el primer rezago.

Por lo tanto, de acuerdo a los correlogramas obtenidos podemos decir lo siguiente:

- ACF sugiere MA(1)
- PACF sugiere AR(1)

Esto nos dice que debemos incorporar una media móvil y un autorregresivo dentro del modelo.

Resumiendo, las veces que hay que diferenciar el modelo en cuestión y el número de medias móviles y autorregresivos que debe incorporar el modelo, se concluye que tenemos un modelo ARIMA (p, d, q), donde:

p= PACF (autocorrelación parcial, AR)

d= número de veces que se debe diferenciar la serie

q= ACF (autocorrelación simple, MA)

Es así que, de acuerdo a los resultados obtenidos, el modelo de serie de tiempo que se obtuvo es un modelo ARIMA de orden (1,1,1)

4.2. Estimación de parámetros

De acuerdo al modelo determinado ARIMA (1,1,1) a continuación se muestran los coeficientes estimados del modelo:

```
##      ar1      ma1
##    -0.0079 -0.008
## s.e.   NaN    NaN
```

De acuerdo a los resultados obtenidos sobre la estimación de los coeficientes del modelo, estos coeficientes, tanto autorregresivo (AR) y de media móvil (MA) resultaron ser prácticamente nulos (−0.0079 y −0.008, respectivamente), lo que indica que no aportan estructura significativa al modelo, además y tal como se

PERSPECTIVA

Revista científica de Economía

UMRPSFXCH

FCEE

puede en los resultados correspondientes a los errores estándar asociados a estos coeficientes no pudieron ser calculados (NaN), lo que sugiere problemas de identificación y una matriz de varianzas-covarianzas mal condicionada.

Ante esta situación identificada, se considera más pertinente adoptar un modelo ARIMA (0,1,0), que representa lo que se llama de camino aleatoria simple. Este modelo captura adecuadamente la dinámica de la serie diferenciada sin introducir parámetros innecesarios, en línea con el principio de parsimonia. La simplificación mejora la estabilidad numérica, evita el sobreajuste y facilita la interpretación del proceso subyacente.

Por lo tanto, se muestra en resumen, los argumentos del cambio a un modelo ARIMA (0,1,0):

- La insignificancia estadística de los coeficientes AR y MA.
- La imposibilidad de estimar errores estándar confiables.
- La mejora en la estabilidad y simplicidad del modelo.
- La coherencia con el comportamiento observado de la serie, que no presenta evidencia clara de autocorrelación estructural.

A continuación, se presenta los coeficientes estimados del modelo ARIMA (0,1,0)

```
## Call:  
## arima(x = desemp_ts, order = c(0, 1, 0))  
## sigma^2 estimated as 106: log likelihood = -401.33, aic = 804.66
```

El modelo ARIMA (0,1,0) representa una caminata aleatoria simple, cuya estructura se define únicamente por la diferenciación de primer orden y un término de error aleatorio.

En este modelo:

- No se incluyen términos autorregresivos (AR), por lo que no hay coeficientes que se relacionen con valores pasados más allá de la diferenciación.
- No se incluyen términos de media móvil (MA), por lo que no hay coeficientes que se relacionen con errores pasados.

Por esta razón, el modelo no estima coeficientes AR ni MA, y el único parámetro reportado es la varianza del error (σ^2), que en este caso fue estimada como 106. Esta ausencia de coeficientes no representa una limitación, sino que refleja la simplicidad estructural del modelo, que es adecuada cuando la serie no presenta patrones de autocorrelación significativos tras la diferenciación.

4.2.1. Evaluando la capacidad predictiva del modelo

Siendo que tenemos dos modelos, el primero ARIMA (1,1,1) y ARIMA (0,1,0), y aunque se ha dicho que el primer modelo cuyos coeficientes tanto autorregresivos (AR) y de media móvil (MA) resultaron ser prácticamente nulos, se hará una verificación de cuál de los dos modelos es el más adecuado mediante el criterio de información AIC (Akaike)

El AIC mide la calidad relativa de un modelo estadístico, penalizando la complejidad. Cuanto menor sea el AIC, mejor es el modelo (en términos de ajuste y parsimonia).

A continuación, se pueden ver los resultados obtenidos:

```
mod_arima1
```

```
## Call:
```

```
## arima(x = desemp_ts, order = c(1, 1, 1))
```

```
## Coefficients:
```

```
##      ar1    ma1
```

```
##    -0.0087 -0.0087
```

```
## s.e.   NaN    NaN
```

```
## sigma^2 estimated as 106: log likelihood = -401.31, aic = 808.62
```

```
mod_arima2
```

```
## Call:
```

```
## arima(x = desemp_ts, order = c(0, 1, 0))
```

```
## sigma^2 estimated as 106: log likelihood = -401.33, aic = 804.66
```

Los resultados corresponden a los dos modelos construidos siendo que dentro del software R, se nombra al modelo ARIMA (1,1,1) con el nombre “mod_arima1” y el modelo ARIMA (0,1,0) con el nombre “mod_arima2” se tiene el siguiente cuadro comparativo:

Tabla 3 – Comparación de los valores AIC para los modelos ARIMA (1,1,1) y ARIMA (0,1,0)

Modelo	AIC
ARIMA (1,1,1)	AIC= 808.62
ARIMA (0,1,0)	AIC= 804.66

Con lo que se puede constatar que el modelo que mejor se ajusta es el modelo ARIMA de orden (0,1,0)

4.3. Diagnóstico del modelo

4.3.1. Evaluando los residuos del modelo

Lo que sigue es evaluar los residuos para verificar si los mismos son “ruido blanco”, ósea, que son generados de manera aleatoria

Un proceso de ruido blanco tiene estas características:

- **Media cero:** Los residuos no tienen sesgo sistemático.
- **Varianza constante:** No hay heterocedasticidad.
- **No autocorrelación:** No hay patrones temporales; los errores no están correlacionados entre sí.
- **Distribución aleatoria:** Los residuos parecen ruido puro, sin estructura.

Si los residuos no son ruido blanco, significa que:

- El modelo no capturó toda la estructura de la serie.
- Hay información no explicada que podría usarse para mejorar el modelo.
- Podrías tener autocorrelación o heterocedasticidad, lo que invalida inferencias estadísticas.

El gráfico de residuales se muestra a continuación:




Figura 3 – Comportamiento de los residuales del modelo ARIMA

De acuerdo al gráfico obtenido se puede ver que los residuos no tienen un patrón sistemático, ósea, no hay tendencia en los residuos no forman una “u” o “n”, ósea se comporta de forma aleatoria "ruido blanco"

Si bien una gráfica puede dar información subjetiva, por lo que es indispensable hacer contrastes para evaluar si el modelo es ruido blanco, para lo cual se usó el contraste “Box.test” donde las hipótesis planteadas son las siguientes:

H₀: Los residuos son independientes

H₁: Los residuos no son independientes

El resultado obtenido de este contraste se muestra a continuación:

```
## Box-Ljung test
## data: modelo2$residuals
## X-squared = 0.092254, df = 1, p-value = 0.7613
```

El p-valor que arroja esta prueba es de 0.7613 que es mayor a 0.05 por lo que no se rechaza la hipótesis nula y se concluye que los residuos son independientes, lo que implica que el modelo es bueno para hacer proyecciones.

PERSPECTIVA

Revista científica de Economía

UMRPSFXCH

FCEE

4.4. Proyección y validación con el modelo ARIMA (0,1,0)

La proyección del modelo está orientada para 3 años hacia adelante, ósea que la proyección se hará para los 4 trimestres de los años 2023, 2024 y 2025, teniendo en cuenta que los datos que sirvieron para el armado del modelo ARIMA (0,1,0) teniendo de fuente a la UDAPE, solo nos proporciona datos sobre el índice de empleo trimestral del sector privado solo hasta el año 2022, en tal sentido tenemos las siguientes proyecciones:

##	Point Forecast	Lo 95	Hi 95
## 2023 Q1	217.2775	197.0971	237.4579
## 2023 Q2	217.2775	188.7381	245.8169
## 2023 Q3	217.2775	182.3240	252.2310
## 2023 Q4	217.2775	176.9166	257.6383
## 2024 Q1	217.2775	172.1527	262.4023
## 2024 Q2	217.2775	167.8458	266.7092
## 2024 Q3	217.2775	163.8851	270.6699
## 2024 Q4	217.2775	160.1986	274.3563
## 2025 Q1	217.2775	156.7362	277.8187
## 2025 Q2	217.2775	153.4614	281.0936
## 2025 Q3	217.2775	150.3466	284.2084
## 2025 Q4	217.2775	147.3705	287.1845

Los resultados anteriores muestran la proyección del índice de empleo trimestral del sector privado hasta el año 2025 así también los intervalos de confianza (Lo, Hi) al 95%.

Así también se muestra el grafico en el cual se proyecta hasta el 4to trimestre del año 2025, el índice de empleo trimestral del sector privado




Figura 3 – Proyección de la Tasa de Empleo del Sector Privado hasta el año 2025

PERSPECTIVA

Revista científica de Economía

UMRPSFXCH

FCEE

En el gráfico anterior, la línea azul corresponde a la proyección del índice de empleo del sector privado hasta el año 2025.

5. Conclusiones

El índice de empleo privado se muestra constante en los siguientes trimestres proyectados para los años 2023, 2024 y 2025, esto sucede porque en un modelo ARIMA(0,1,0) (random walk) el mejor pronóstico de todos los horizontes futuros es simplemente el último valor observado, aunque, como se puede ver en el gráfico de proyección y los resultados obtenidos, hay una creciente brecha en los intervalos de confianza al 95%, lo cual muestra bastante incertidumbre dado que el empleo podría subir a niveles de 280 en los próximos años o caer a 150.

Entre las limitaciones del modelo, se podría decir que el modelo no captura ciclos económicos, estacionalidad ni tendencia, ya que como se ve en las proyecciones para los años 2023, 2024 y 2025 el modelo predice estabilidad en el índice de empleo privado alrededor de 217.

5. Bibliografía

Stock - Watson. (2010). *Introducción a la econometría*. Editorial Pearson.

Gujarati. (2010). *Econometria*. Editorial Mc Graw - Hill.

Jeffery M. Wooldridge. (2008). *Introducción a la econometría*. Editorial Paraninfo.

Levin – Rubin. (2010). *Estadística para Administración y Economía*. Editorial Prentice Hall

Instituto Científico del Pacífico. (2025). *Econometría aplicada con R: Nivel avanzado, Módulo 6 – Modelos multivariados I*. Curso en línea.