



# REVISTA INGENIO

## Violencia en Ecuador: Análisis de Homicidios Mediante Series de Tiempo

### Violence in Ecuador: Analysis of Homicides Through Time Series

Atal Kumar Vivas Paspuel, [1](#) | [ID](#) Universidad de las Fuerzas Armadas ESPE, Santo Domingo (Ecuador)  
David Alfredo Vivas Paspuel, [2](#) | [ID](#) Universidad Central del Ecuador, Quito (Ecuador)

#### HISTORIA DEL ARTÍCULO

Recepción: 8/5/2023  
Recepción tras revisión:  
29/9/2023 Aprobación:  
30/10/2023 Publicación:  
15/01/2023

#### PALABRAS CLAVE

Pronósticos, series de tiempo,  
modelos, homicidios.

#### ARTICLE HISTORY

Received: 8/5/2023  
Received after revision:  
29/9/2023 Approved: 30/10/2023  
Accepted: 15/1/2024

#### KEY WORDS

Forecasts, time series, models,  
homicides.

#### RESUMEN

La violencia en Ecuador no tiene precedentes, los índices de homicidios, femicidios, robos, atentados y otros tipos de crímenes han aumentado de forma alarmante en este país. Todos los días se reportan nuevos eventos que son noticia y alarman a la comunidad. Las instituciones gubernamentales junto con la organización policial y las fuerzas militares realizan acciones para mitigar la ola de violencia sin alcanzar resultados eficientes. Este trabajo analiza la cantidad de homicidios a nivel nacional como una serie temporal con el fin de conocer el comportamiento de esta variable en los últimos años. Aplicando modelos de suavizado, así como el modelo ARIMA y Red Neuronal se busca el modelo más eficiente que minimice el error de predicción. Entre los modelos de suavizado se encontró al modelo de Holt como el más eficiente, sin embargo, pero al comparar todos los modelos aplicados, se encontró que el modelo de Red Neuronal es el más eficiente con el cual se pueden obtener buenos pronósticos.

#### ABSTRACT

Violence in Ecuador is unprecedented, the rates of homicides, femicides, robberies, attacks and other types of crimes have increased alarmingly in this country. Every day new events are reported that are news and alarm the community. Government institutions, together with the police organization and the military forces, carry out actions to mitigate the wave of violence without achieving efficient results. This paper analyzes the number of homicides nationwide as a time series to know the behavior of this variable in recent years. Applying smoothing models, as well as the ARIMA and Neural Network models, the most efficient model is sought. that minimizes the prediction error. Among the smoothing models, the Holt model was found to be the most efficient, however, but when comparing all the applied models, it was found that the Neural Network model is the most efficient with which good forecasts can be obtained

## 1. INTRODUCCIÓN

El año 2022 ha sido considerado uno de los más violentos de la historia de Ecuador. Según la policía nacional, se registraron al menos 4.539 muertes violentas que se dieron en diferentes circunstancias como sicariatos, homicidios, femicidios, robos con asesinato o actos criminales con explosivos. En términos de la tasa de muertes delincuenciales, este dato equivale a 25,5 muertes por cada 100.000 habitantes en 2022. Haciendo una comparación respecto al año anterior, se observa un crecimiento abrupto en esta tasa ya que para el 2021 se registraron 2.048 crímenes, lo que significan 13,7 muertes por cada 100.000 habitantes. Las autoridades de seguridad están de acuerdo en que es la tasa más alta de la historia desde que se tienen registros sobre muertes delincuenciales [1].

Las razones para la escalada de violencia en el país son de variado orden. Se conoce que el crimen organizado

transnacional crece, se perfecciona en su logística y comunicación y se despliega de forma acelerada. Se conoce la asociación que existe entre estas organizaciones y el estado desde hace varios años. La tecnificación y globalización del comercio a nivel internacional ha hecho que el crimen tenga más facilidades para los flujos ilícitos a través de las fronteras (Crimen organizado cadenas de valor). La disputa entre organizaciones criminales es otra razón para el incremento de crímenes. Las bandas se enfrentan por mantener el mando en las cárceles del Ecuador y por lo tanto, los principales centros de privación de libertad del país han sufrido a la par el aumento en la violencia interna, llevando a las autoridades a soportar una crisis de críticas y demandas [2]. Bajo estas circunstancias, se vuelve necesario conocer el problema a través de la información recabada en los eventos violentos. Los recuentos de estos eventos por mes pueden ser útiles para realizar predicciones por medio de

series de tiempo. Los pronósticos en series de tiempo por medio de un modelo adecuado proporcionan un estimado cuantitativo en un marco de probabilidad para eventos futuros. Es importante incorporar este tipo de pronósticos para el recuento de crímenes ya que las autoridades requieren información que les permita organizar hacia el futuro la logística que implica contener los hechos violentos [3]. Este trabajo realiza un análisis de la serie de tiempo construida con los recuentos de homicidios y femicidios desde enero 2014 hasta enero 2022. Esta serie de tiempo es analizada mediante varios modelos de pronósticos: modelo de medias móviles, modelo exponencial simple, modelo de Holt, modelo de Holt Winters, ARIMA y Red Neuronal. Estos modelos cuentan con su formulación y sus parámetros asociados. El paquete computacional Statgraphics se utiliza para los modelos de medias móviles, exponencial simple, modelo de Holt y modelo de Holt Winters (llamados también modelos de suavizado), mientras que los modelos ARIMA (Autorregresive Integrated Moving Average) y Red Neuronal se aplican mediante el software R. El error cuadrático medio (RMSE), el Error Absoluto Medio (MAE) y el Error Absoluto Porcentual Medio (MAPE) se usarán como estadísticos de comparación para rescatar el mejor modelo.

## 2. MÉTODO

Una serie de tiempo es una sucesión de datos:  $\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3, \dots$ , sobre una variable particular y que son tomados a través del tiempo. Es decir, es una secuencia ordenada de observaciones sobre alguna variable de interés. Las series más usuales son las univariantes, es decir, que miden tan solo una variable a través del tiempo, sin embargo, los análisis pueden extenderse a más variables. Los modelos utilizados para el manejo de las series son variados, en este trabajo se utilizan los métodos de suavizado, que permiten controlar el ruido o las fluctuaciones aleatorias que dificultan la interpretación de la serie o modelos como el ARIMA y el modelo de Red Neuronal.

Suponiendo que la serie de datos se puede descomponer en: tendencia, ciclo, estacionalidad e irregularidad, se afirma que la serie es el resultado de la suma de los componentes teóricos:

$$Y_t = T_t + S_t + C_t + I_t \quad (1)$$

La tendencia de una serie  $T_t$ , es aquella parte de la serie que describe los cambios de la variable a largo plazo, es decir, representa el crecimiento o caída de la serie a través de un período amplio en el tiempo. La parte estacional  $S_t$ , define un patrón de cambio que se encuentra dentro el periodo de un año y para su detección del patrón estacional, suelen usarse métodos multiplicativos o aditivos. La parte cíclica  $C_t$ , llamado también efecto cíclico, se determina como una

fluctuación que se relaciona con la tendencia y que tiende a repetirse durante periodos mayores a un año. Suele ser difícil establecer modelos cíclicos debido a la inestabilidad que estos presentan. La parte irregular de la serie de tiempo se determina como un factor residual, es el resto de la serie luego de sumar las tres primeras componentes, por lo tanto, puede definirse también como la parte aleatoria.

La media de la serie se define como el valor constante en el tiempo alrededor del cual evoluciona la serie. La varianza es el valor que mide la dispersión o variabilidad de la serie alrededor de su media. La autocorrelación se define como la medida de la relación existente entre dos observaciones consecutivas de la serie, es decir separadas por un periodo temporal que también se denomina retardo. Para el caso de los modelos ARIMA, suele suponerse que la serie cumple la hipótesis de estacionariedad. Esta suposición implica consideraciones de tipo estocástico sobre la media y varianza de la serie.

### 2.1 Modelo de medias móviles

Una de las formas de suavizar una serie es por medio del método de las medias móviles que se basa en el cálculo de una media para valores vecinos de la serie de forma consecutiva [4]. Por lo tanto, podemos tomar una cantidad de los datos de la serie y promediarlos y así construir una nueva serie suavizada correspondiente. En nuestro caso utilizamos una media móvil para 5 puntos, es decir, la primera media, es el promedio entre  $x_1, x_2, x_3, x_4$  y  $x_5$ , la segunda media será el promedio entre  $x_2, x_3, x_4, x_5$  y  $x_6$ , y así sucesivamente. Se puede ponderar la información aplicando pesos a cada observación, el promedio sería:

$$\begin{aligned} & \text{Promedio móvil ponderado} \\ & = \sum_{i=1}^n c_i x_i \end{aligned} \quad (2)$$

donde  $0 \leq c_i \leq 1$ , entonces  $c_i$  es la proporción asignada a  $x_i$ . Por lo tanto,  $\sum_{i=1}^n c_i = 1$ .

### 2.2 Modelo exponencial simple

Cuando se requiere predecir valores a futuro para una serie, podemos pensar en utilizar muchos valores rezagados o simplemente tomar en cuenta el ultimo o los últimos valores recabados. El método de suavizado es una solución intermedia entre estos extremos, es decir, realiza un pronóstico basado en una media ponderada de los valores actuales y de los pasados [5]. El cálculo de esta media dará más peso a la última observación, menos peso al valor inmediatamente anterior, y así sucesivamente hacia atrás. Representando esto en una ecuación tenemos:

$$\hat{x}_t = (1 - \alpha)x_t + \alpha(1 - \alpha)x_{t-1} + \alpha^2(1 - \alpha)x_{t-2} + \dots \quad (3)$$

En esta ecuación,  $\alpha$  es un valor entre 0 y 1.

### 2.3 Modelo de Holt

Este modelo se considera como un mejoramiento al modelo exponencial simple al agregar un parámetro al modelo, por lo que se lo puede definir como modelo exponencial doble. Por lo tanto, los dos parámetros ahora son  $\alpha$  y  $\beta$ . El modelo queda como sigue

$$x_{t+m} = \alpha z_t + (1 - \alpha)(S_{t-1} + b_{t-1}) + m[\beta(S_t - S_{t-1}) + (1 - \beta)b_{t-1}] \quad (4)$$

En donde,  $\alpha$  y  $\beta$  son parámetros que están entre 0 y 1. La constante  $\alpha$  es relativa al modelo de suavizado exponencial simple. La constante  $\beta$  es la constante de suavizado de la tendencia de la serie.

### 2.4 Modelo de Holt-Winters

Este modelo, a diferencia de los anteriores, añade una componente de estacionalidad que puedan presentar los datos de la serie. Por lo tanto, este modelo presentará y dependerá de 3 parámetros [5]:  $\alpha$ ,  $\beta$  y  $\gamma$  en sus ecuaciones. Siendo  $z_{t+m}$  la variable alisada al tiempo  $t + m$ , la podremos calcular mediante

$$\hat{z}_{t+m} = (s_t + mb_t)E_{t+m}, \text{ en donde}$$

$$s_t = \alpha \frac{z_t}{E_{t-s}} + (1 - \alpha)(s_{t-1} + b_{t-1}) \quad (5)$$

$$b_t = \beta(s_t - s_{t-1}) + (1 - \beta)b_{t-1} \quad (6)$$

$$E_t = \gamma \frac{z_t}{s_t} + (1 - \gamma)E_{t-s} \quad (7)$$

### 2.5 Modelos ARIMA

El modelo ARIMA se aplica a series de tipo estacionarias. Una serie estacionaria es aquella cuyos valores y propiedades no dependen del tiempo en el que se encuentra la serie. Por ejemplo, si una serie posee tendencias o estacionalidad, no es estacionaria, pero una serie de ruido blanco es estacionaria ya que en cualquier tiempo debería verse igual. Para obtener una serie estacionaria a partir de series no estacionarias, suele realizarse una diferenciación entre observaciones consecutivas [6]. Un modelo autorregresivo es aquel que usa observaciones pasadas combinadas linealmente para realizar predicciones a futuro. La autorregresión significa que el modelo se basa en la regresión de la variable con ella misma.

Al combinar un modelo autorregresivo con uno de medias móviles, se genera el modelo ARIMA. Es decir, si combinamos la diferenciación con la autorregresión y un modelo de media móvil, obtenemos un modelo ARIMA no estacional. ARIMA es un acrónimo de Media Móvil Integrada Autorregresiva. Se dice que tenemos un modelo ARIMA(p,d,q) donde:

p, es el orden autorregresivo del modelo.

d, grado de la diferenciación involucrada en el modelo.

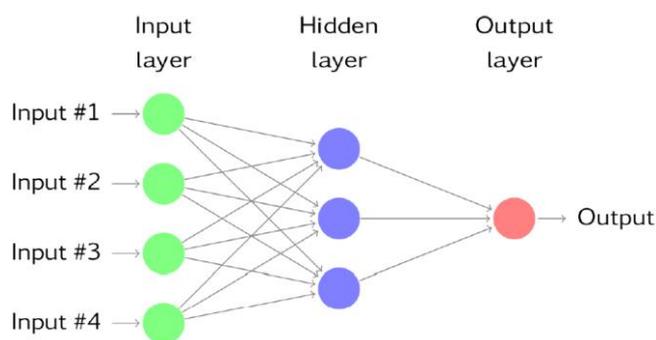
q, orden de la media móvil del modelo.

### 2.6 Modelo de Redes Neuronales

Estas redes constituyen métodos de pronóstico basadas en métodos matemáticos que copian la actividad del cerebro. Pueden modelar relaciones no lineales y relaciones complejas entre la variable de respuesta y sus predictores [5]. La red neuronal es una red de "neuronas" que se organizan mediante capas. Las entradas son los predictores y las salidas son los pronósticos. Todo esto está organizado mediante capas inferiores, superiores e intermedias [7].

Figura 1

Estructura básica de una red neuronal.



Para series de tiempo, los valores retrasados de la serie pueden servir como entradas para una red neuronal, a esto lo llamamos autorregresión de red neuronal o modelo NNAR (Neural Network Autoregression). Usamos la notación NNAR(p,k) para indicar que hay p entradas y k nodos retrasados en la capa oculta. Por ejemplo, un modelo NNAR(9,5) usa las últimas nueve observaciones utilizadas como entradas para pronosticar la salida y con cinco neuronas en la capa oculta. El paquete *Forecast* de R implementa el modelo de redes neuronales de alimentación hacia adelante que contiene una sola capa oculta y las entradas son los *lags* o retrasos de la serie. Estos insumos le permiten al modelo realizar pronósticos para las series temporales univariadas. En R, la red implementada tiene una sola capa oculta y la cantidad de entradas depende de la cantidad de rezagos que tienen los datos [8]. En R usamos la función *nnetar()* para aplicar el modelo.

El modelo matemático puede ser escrito como  $y_t = f(\mathbf{y}_{t-1}) + \varepsilon_t$ , donde  $\mathbf{y}_{t-1} = (y_{t-1}, y_{t-2}, y_{t-2}, \dots)$  es el vector que contiene los valores rezagados de la serie en análisis y  $f$  representa la red neuronal. Se asume que el error de la serie  $\{\varepsilon_t\}$  es homocedástico y normalmente distribuido. Se puede simular muestras futuras de este modelo de forma iterativa, generando aleatoriamente un valor para  $\varepsilon_t$ , por medio de la distribución normal o de una nueva muestra de los valores históricos. Entonces, si  $\varepsilon_{T+1}^*$  es una muestra de la distribución de los errores al

tiempo  $T + 1$ , entonces  $y_{T+1}^* = f(y_T) + \varepsilon_{T+1}^*$  es una posible muestra de la distribución de predicciones para  $y_{T+1}$ . Así que es posible simular iterativamente las predicciones requeridas. Al simular repetidamente muestras, se puede conocer la distribución de las predicciones en función de la red neuronal.

### 3. RESULTADOS Y DISCUSIÓN

Se muestra en primer lugar la serie de observaciones para la variable Homicidios Intencionales (Absolutos) tomados del Instituto Nacional de Estadísticas y Censos (INEC) desde enero 2014 hasta mayo 2022 con frecuencia mensual en Ecuador [9]. El número de observaciones es 101 y el periodo es mensual.

**Tabla 1**

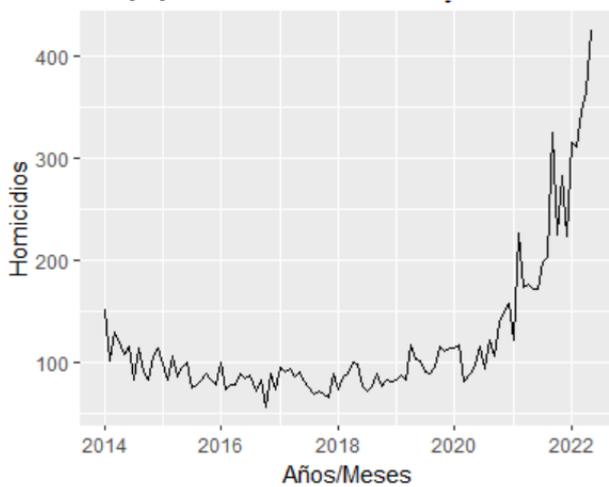
*Datos de homicidios absolutos a nivel nacional en Ecuador.*

Mes	2014	2015	2016	2017	2018	2019	2020	2021	2022
Enero	151	98	99	95	73	83	113	122	315
Febrero	101	82	73	90	86	87	116	226	311
Marzo	129	106	78	93	89	83	80	173	344
Abril	120	85	77	86	99	117	88	176	365
Mayo	107	95	89	90	98	102	96	172	424
Junio	115	100	84	80	76	101	115	171	
Julio	82	75	87	75	71	90	94	198	
Agosto	114	78	72	68	76	89	122	203	
Septiembre	90	82	82	71	89	95	105	325	
Octubre	82	89	56	69	76	115	138	225	
Noviembre	106	82	89	65	82	111	148	282	
Diciembre	113	78	73	88	80	114	157	223	

Una primera visualización de la serie se muestra en la Fig. 2, la cual evidencia el crecimiento de muertes que ha sufrido el país por causas del crimen. Podemos ver una leve caída desde el 2014 hasta el 2020 y desde este punto se dispara el número de casos hasta el 2022. Se espera, según la tendencia, que la variable siga creciendo en los siguientes periodos de tiempo.

**Figura 2**

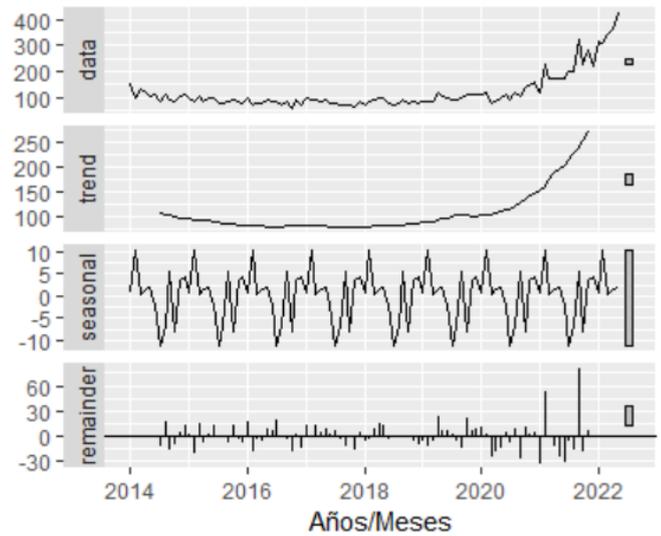
*Serie de tiempo para homicidios absolutos*



La descomposición de la serie en sus componentes de tendencia, estacional, cíclica e irregular la podemos ver como modelo aditivo en la Fig. 3. Podemos ver que no se trata de una serie estacionaria, al no tener varianza constante y tener una tendencia bien marcada.

**Figura 3**

*Descomposición aditiva para la serie de datos.*



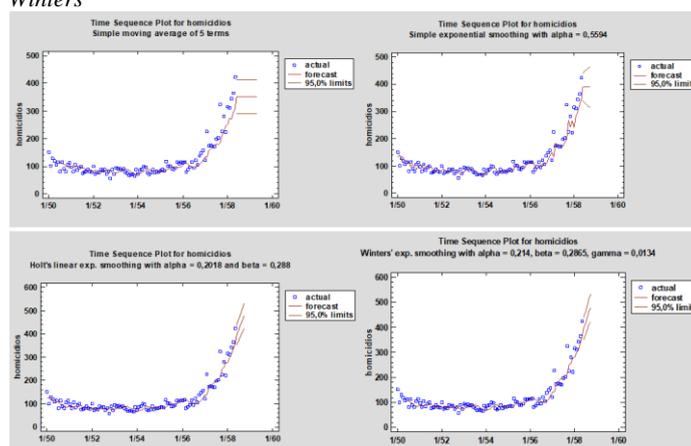
Para mostrar los resultados de los modelos de medias móviles, exponencial simple, Holt y Holt Winters, se utilizó el software Statgraphics, un software estadístico estándar, cuya virtud es mostrar los resultados de forma amigable incluso para investigadores que no tienen conocimientos estadísticos. Una ventaja es la omisión del uso de programación para la obtención de resultados personalizados dirigido a personas que no tengan grandes conocimientos de estadística, además de no utilizar programación y, por tanto, simplificar el trabajo.

Para esto, dispone del intérprete StatAdvisor que permite interpretar estadísticamente los resultados de los modelos

utilizados en los análisis, lo cual ayuda si no se tienen conocimientos suficientes de estadística.

Los resultados para los modelos de medias móviles, exponencial, Holt y Holt Winters pueden verse en la Fig. 4. Para cada modelo, la línea roja marca las predicciones calculadas, al final se realizan varias predicciones. Para los modelos de medias móviles y exponencial simple se puede observar que las predicciones a futuro se comportan como una recta horizontal constante, es decir, se tienen las mismas predicciones. Esto se debe al hecho de que estos dos modelos no toman en cuenta características como la tendencia de los datos. Los modelos de Holt y Holt Winters si toman en cuenta estas características de la serie, esto implica que su modelo depende de una mayor cantidad de parámetros y su ventaja es que las predicciones mejoran, reduciendo el error de predicción. Los parámetros  $\alpha$ ,  $\beta$  y  $\gamma$  para estos modelos son optimizados por el paquete Statgraphics.

**Figura 4**  
Pronósticos para los modelos de media móvil, exponencial, Holt y Holt Winters



La Tabla 2 muestra los errores de predicción para cada uno de los modelos de suavizado. Los errores considerados son: RMSE, MAE y MAPE. Podemos ver que, para todos los estadísticos de error, el modelo Holt obtiene los valores más bajos. por lo que puede ser considerado el más eficiente en este grupo. Los parámetros:  $\alpha$ ,  $\beta$  y  $\gamma$  fueron optimizados mediante Statgraphics, de modo que se minimicen los errores.

**Tabla 2**  
Comparación de errores para los modelos de suavizado

Modelo	RMSE	MAE	MAPE	Parámetros
Medias Móviles	28,7255	17,5535	13,2376	términos = 5
Exponencial	25,3336	15,9956	12,3626	alpha = 0,563
Holt	22,5778	15,0606	12,3494	alpha = 0,211, beta = 0,275
Holt Winters	22,9257	15,1591	12,4563	alpha = 0,214, beta = 0,286, gamma = 0,013

Para los modelos ARIMA y Redes Neuronales hemos realizado un análisis separado dado que sus técnicas son diferentes a los primeros modelos y relativamente son modelos más actuales. En la Tabla 3 podemos ver la comparación de errores para estos modelos, el modelo de Redes Neuronales presenta los valores más bajos con respecto al modelo ARIMA y al resto de modelos, por lo

que puede ser considerado el más eficiente. Para estos dos modelos hemos utilizado el software R. Para el caso de ARIMA, R optimiza los parámetros p, d y q. Para el caso de Red Neuronal, R trabaja internamente en el modelo. En nuestro caso,  $p=100$  y  $k=1$ , es decir que la red será alimentada mediante 100 rezagos y por defecto, R trabaja con una sola capa oculta.

**Tabla 3**  
Comparación de errores para los modelos ARIMA y Red Neuronal

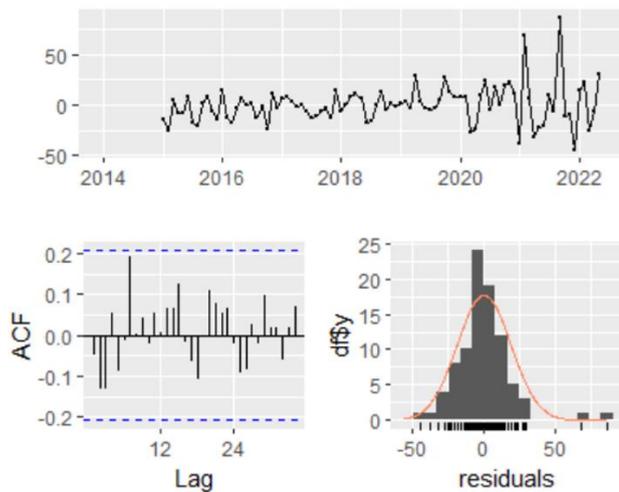
Modelo	RMSE	MAE	MAPE	Parámetros
ARIMA	20,529	13,569	11,383	$p = 2, d = 2, q = 3.$
Red Neuronal	18,668	12,935	11,090	$p=100, k=1$

El análisis de los residuos es importante para conocer el comportamiento de la serie de tiempo una vez que se aplica un modelo. La Fig. 5 muestra el comportamiento de los residuos para la serie de tiempo, sus autocorrelaciones y la distribución de estos.

Podemos ver que las autocorrelaciones se encuentran entre los límites permitidos y que la distribución parece tener media cero. Esto lo podremos corroborar en las pruebas de hipótesis correspondientes.

Figura 5

Residuales para el modelo de Redes Neuronales. Modelo NNAR(2,1,2).



La indicación NNAR(2,1,2) es una especificación de hiperparámetros para el modelo NNAR. Los números entre paréntesis representan los valores de los hiperparámetros del modelo: "2" se refiere al número de capas ocultas en la red neuronal, "1" se refiere al número de neuronas en la capa oculta. "2" se refiere al retraso máximo en el modelo autorregresivo.

### Ruido Blanco

Para probar la existencia de ruido blanco lo hacemos por medio de la prueba de Ljung-Box cuyas hipótesis dicen lo siguiente:

H<sub>0</sub>: Hipótesis Nula (existe ruido blanco)

H<sub>1</sub>: Hipótesis alternativa (no existe ruido blanco)

Por medio del software R se obtuvo un  $p\text{-value} < 2.2e-16$ , por lo tanto, podemos concluir que se rechaza H<sub>0</sub>, es decir que los residuos no se comportan como ruido blanco.

### Media nula.

Para verificar si los residuos tienen media nula, podemos realizar la prueba de hipótesis sobre la media:

Las hipótesis serían:

H<sub>0</sub>:  $\mu = 0$  (Media Nula)

H<sub>1</sub>:  $\mu \neq 0$  (Media no Nula)

Mediante el software R se obtiene un  $p\text{-value} = 0.9904$ , entonces, no se rechaza la hipótesis nula, por lo tanto, la media de los residuos es estadísticamente cero.

### Varianza constante

Para determinar si existe varianza constante hemos realizado la prueba de McLeod-Li que consiste en una prueba de heterocedasticidad condicional autorregresiva para una serie de tiempo. Las hipótesis son

H<sub>0</sub>: No existe heteroscedasticidad condicional autorregresiva (ARCH) entre los rezagos considerados.

H<sub>1</sub>: Existe heteroscedasticidad condicional autorregresiva (ARCH) entre los rezagos considerados.

Dado que se trata de una prueba múltiple, el resultado es una gráfica que muestra los  $p\text{-values}$  en una sola gráfica. Por tanto, habría que observar cuantos de estos valores están por debajo de la línea de color rojo y ver si estos son suficientes para rechazar la hipótesis nula. En la Fig.6 (Anexo Fig.6) podemos ver que la mayoría de las marcas están por encima de la línea de color rojo por lo que no podemos rechazar H<sub>0</sub>, es decir que existe heteroscedasticidad condicional autorregresiva (ARCH) entre los rezagos considerados.

### Los residuos siguen una distribución normal

Se realiza la prueba de Shapiro - Wilk a los residuos para conocer si se distribuyen normalmente, las hipótesis son:

H<sub>0</sub>: La variable presenta una distribución normal

H<sub>1</sub>: La variable presenta una distribución no normal  
Mediante el software R, se obtiene que  $p\text{-value} = 2.601e-05$ , con lo cual los residuos no siguen una distribución normal.

## 4. CONCLUSIONES

Se han aplicado los modelos de suavizado para el tratamiento de la serie de tiempo: medias móviles, exponencial simple, Holt y Holt Winters. Estos modelos permiten describir en forma general el comportamiento de la serie temporal pero no siempre las predicciones son las más eficientes. Para estos modelos, los errores más bajos fueron obtenidos por el modelo de Holt, RMSE = 22,5778, MAE = 15,0606 y MAPE = 12,3494. Estos modelos se aplican Cuando las series son muy irregulares, suele aplicarse modelos deterministas que suavizan la forma de la serie y nos permite realizar una mejor interpretación visual de la misma. Sin embargo, estos modelos no son tan eficientes al realizar pronósticos por lo que, dependiendo de las aplicaciones, podrían aplicarse modelos alternativos. Los modelos deterministas que se aplican son: Medias móviles con 5 elementos, Exponencial simple, Holt y Holt Winters.

Para analizar series de tiempo es importante analizar los residuos del modelo ya que nos permite conocer la eficiencia y en que magnitud se ha capturado las

características de los datos de la serie. Para que el ajuste del modelo sea eficiente, los residuos deberían: a) Presentar una baja autocorrelación o autocorrelación parcial ya que la presencia de correlación, indica que el modelo ha perdido alguna información de los datos. Hemos usado una prueba Ljung-Box para determinar si los residuos están realmente correlacionados y se encontró que nuestra serie efectivamente presenta autocorrelación. b) El promedio de los residuos debe ser nula, si esto no se cumple, estaremos ante un resultado sesgado de los pronósticos. Para nuestro caso, esto se cumplió satisfactoriamente. c) Los residuos deberían presentar varianza constante, en este trabajo se utilizó la prueba de McLeod-Li que consiste en una prueba de heterocedasticidad condicional autorregresiva para una serie de tiempo y se concluye que existe presencia de heterocedasticidad.

Realizar predicciones sobre series temporales no es una tarea fácil. La razón radica en que las observaciones de una serie temporal dependen casi solo de sus valores pasados y esta dependencia tiene un valor que es más alto cuando se trata de observaciones recientes y más bajo cuando se trata de observaciones lejanas en el tiempo.

Los modelos ARIMA se preocupan de hacer que una serie se vuelva estacionaria y para esto realizan diferentes técnicas como la diferenciación de la serie. Para medir el grado de estacionariedad, se preocupan de medir las autocorrelaciones de la serie, de modo que se obtenga una serie sin tendencia y varianza constante en la que se puedan realizar predicciones de mejor manera. También se realiza una diferencia estacional para eliminar justamente la estacionalidad de la serie. El paquete R permite realizar una optimización en este sentido al calcular el mejor modelo ARIMA.

Las redes neuronales son parte de las nuevas tendencias que tienen que ver con el aprendizaje de máquinas y la inteligencia artificial. En este sentido al utilizar una red neuronal como modelo para realizar predicciones en una serie de tiempo, la red utiliza los datos como entradas al modelo y el modelo calcula las correspondientes salidas que irán a nuevas entradas y con esto se construyen las capas de la red. Esto hace que la red aprenda de los datos que ingresan en las entradas y se obtenga una salida de aprendizaje que trate de minimizar los errores de predicción. En nuestro caso, hoy el modelo que obtuvo el valor más bajo de error RMSE es justamente el modelo de redes neuronales.

## REFERENCIAS

- [1] S. Ortiz (22, Dic 29) “Ecuador cierra el 2022 con la peor tasa de homicidios de la historia.” <https://www.expreso.ec/actualidad/ecuador-cierrano-tasa-homicidios-25-5-peor-historia-145484.html> (accessed May 07, 2023).
- [2] A. L. Santillán Molina *et al.*, “Drogas, tráfico y crimen organizado como detonante de actos violentos en las cárceles del Ecuador,” *Revista Universidad y Sociedad*, vol. 14, no. 3, pp. 478–486, 2022, Accessed: May 07, 2023. [Online]. Available: [http://scielo.sld.cu/scielo.php?script=sci\\_arttext&id=S2218-36202022000300478&lng=es&nrm=iso&tlng=en](http://scielo.sld.cu/scielo.php?script=sci_arttext&id=S2218-36202022000300478&lng=es&nrm=iso&tlng=en)
- [3] A. C. Juárez, C. A. Zuñiga, J. L. M. Flores, and D. S. Partida, “Análisis de series de tiempo en el pronóstico de la demanda de almacenamiento de productos perecederos,” *Estudios Gerenciales*, vol. 32, no. 141, pp. 387–396, doi: 10.1016/J.ESTGER.2016.11.002.
- [4] D. R. (David R. Anderson, D. J. Sweeney, and T. A. Williams, “Estadística para negocios y economía,” p. 1080, 2012.
- [5] R. J. Hyndman, “Forecasting: Forecasting: Principles & Practice,” no. September, p. 138, 2014, Accessed: May 07, 2023. [Online]. Available: [robjhyndman.com/uwa%5Chttp://robjhyndman.com/papers/forecasting-age-specific-breast-cancer-mortality-using-functional-data-models/](http://robjhyndman.com/uwa%5Chttp://robjhyndman.com/papers/forecasting-age-specific-breast-cancer-mortality-using-functional-data-models/)
- [6] S. Siami-Namini and A. S. Namin, “Forecasting Economics and Financial Time Series: ARIMA vs. LSTM,” Mar. 2018, Accessed: May 07, 2023. [Online]. Available: <http://arxiv.org/abs/1803.06386>
- [7] Z. Pala and R. Atici, “Forecasting Sunspot Time Series Using Deep Learning Methods,” *Sol Phys*, vol. 294, no. 5, pp. 1–14, May 2019, doi: 10.1007/S11207-019-1434-6/METRICS.
- [8] A. DE Técnicas Económicas Y and A. Ramón Chung Pinzás, “APLICACIÓN DE TÉCNICAS ECONÓMICAS Y MACHINE LEARNING PARA SERIES DE TIEMPO UNIVARIADAS EN UNA ESCUELA PROFESIONAL DE UNA UNIVERSIDAD PÚBLICA,” *Veritas*, vol. 23, no. 1, pp. 47–51, Jan. 2023, doi: 10.35286/VERITAS.V23I1.335.
- [9] INEC, “Justicia y crimen” <https://www.ecuadorencifras.gob.ec/justicia-y-crimen/> (accessed May 07, 2023).

**Anexo**

**Figura 6.**

*Los p-valores para la prueba de McLeod-Li.*

