

Un modelo de predicción con series cronológicas para el Sars Cov2 en la zona 1 del Ecuador

A prediction model with time series for Sars Cov2 in zone 1 of Ecuador

DOI: 10.46932/sfjdv5n4-008

Received on: Mar 15th, 2024

Accepted on: Apr 02nd, 2024

Cristian Emilio Oñate Chilibingua

Maestría en Estadística Aplicada

Institución: Universidad Politécnica Estatal del Carchi

Dirección: Antisana y Av. Universitaria, Tulcán, Ecuador

E-mail: cristian.onate@upec.edu.ec

RESUMEN

El año 2020 estuvo marcado por la intensa pandemia llamada COVID-19, causada por un nuevo coronavirus denominado SARS-Cov2, misma que alarmó y puso a prueba los sistemas de salud y a la investigación científica a nivel mundial. En Ecuador, el primer caso se detectó el 20 de febrero del 2020, y hasta la actualidad se siguen reportando contagios por el virus. En este estudio fue posible diseñar un modelo autorregresivo de medias móviles (ARIMA) con la finalidad de estimar el número de contagios de 12 meses a partir del primero de abril del 2020, para la Zona 1 del Ecuador, el modelo pronosticó 25 contagios para abril de 2022, y un promedio estable de 30 contagios por mes hasta marzo del 2023. Estos resultados permiten anticipar la evolución de la pandemia y respaldar la toma de decisiones en materia de salud pública en la Zona 1 del Ecuador.

Palabras clave: Pandemia, Modelos Autorregresivos, Modelos de Medias Móviles.

ABSTRACT

The year 2020 was marked by the intense pandemic called COVID-19, which was caused by a new coronavirus called SARS-Cov2. It alarmed and tested health systems and scientific research worldwide. In Ecuador, the first case was detected on February 20th, 2020, and infections due to the virus continue to be reported up to now. An autoregressive mobile media model (ARIMA) was designed in this research to estimate the number of infections for 12 months, starting on April 1st, 2020, for Zone 1 of Ecuador, this model predicted 25 infections for April 2023, and a stable average of 30 infections per month until March 2023. These results allow us to anticipate the evolution of the pandemic and support public health decision-making in Zone 1 of Ecuador.

Keywords: Pandemic, Autoregressive Models, Moving Average Models.

1 INTRODUCCIÓN

El 31 de diciembre de 2019, el gobierno de la República Popular de China informó a la Organización Mundial de la Salud (OMS) que, en la ciudad de Wuhan, provincia de Hubei aparecieron casos de neumonía de etiología desconocida. Desde esa fecha hasta el 3 de enero de 2020, se reportaron

44 casos de este tipo a la OMS, la mayoría de ellos presuntamente provenientes de un mercado de mariscos en Wuhan. El Gobierno de China, por medio de sus autoridades, el 7 de enero identificaron al virus causante y lo denominaron “nuevo coronavirus Covid-19. De acuerdo con (Bravo, 2020, p. 3) Desde esa fecha hasta el 31 de marzo del mismo año, se reportaron 750 890 casos confirmados de COVID-19 en 180 países, con 36 405 muertes asociadas, lo que se traduce que el nuevo virus detectado tiene una letalidad del 4.8%.

Mientras tanto en el Ecuador el *Sistema* Nacional de Gestión de *Riesgos* y Emergencias (SINGRE), desde que se identificó el primer caso el 20 de febrero del 2020 al 31 de marzo del mismo año, reportó 2032 casos confirmados y 79 personas fallecidas (Inca, 2020, p. 6).

La comunidad científica desde la aparición del virus SARS-CoV-2, se ha preocupado por conocer el comportamiento del virus para poder predecir las formas de contagio, así como las afectaciones en la salud y la velocidad con la que se propaga el virus, Khan y Gupta, (2020), implementaron un modelo ARIMA, en la India a partir de un conjunto de datos disponibles al 4 de abril del 2020, relacionados con los casos diarios confirmados, los resultados establecieron que el número de contagios diarios por COVID-19 en la salida del modelo fue de 1500. Alabdulrazzaq *et al.* (2021), utilizaron la técnica ARIMA para predecir los casos confirmados y recuperados las predicciones del modelo fueron precisas, su exactitud fue validada durante un período de tiempo relativamente largo utilizando Kuwait como caso de estudio, la precisión de la predicción proporcionada por el modelo fue apropiada y satisfactoria. Sokoco y Sidhu (2021), estimaron el número total de infectados por COVID-19 en la India, utilizando un modelo autorregresivo de medias móviles ARIMA, el modelo fue programado con fecha de inicio el 16 de septiembre del 2020, el periodo de duración para la predicción del modelo fue de 230 días, el modelo fue capaz de predecir un total de 25 669 294 millones de infectados, en Colombia Buitriago y Másmela (2021), realizaron un pronóstico de la pandemia de COVID-19 usando RNN (Recurrent Neural Network) simple, RNN con celdas LSTM (Long Short Term Memory) y RNN con celdas GRU (Gated Recurrent Unit), el modelo relacionado con la Simple RNN, indicó que para el 2022 – 05 – 04, el número de casos acumulados será de 6 114 741, mientras que el modelo de LSTM con 6 430 160 y por último el modelo GRU con 6 236 141.

Para la zona 1 del Ecuador no se han encontrado publicaciones que permitan conocer con precisión la evolución de los contagios por coronavirus, por lo que no existen datos que faciliten aplicar Políticas Gubernamentales oportunas y efectivas para controlar la curva de contagios y atenuar los impactos que causa la pandemia, por tal razón en este trabajo de investigación se ha propuesto la formulación de un modelo ARIMA (Promedio móvil integrado autorregresivo), también conocido como método Box-Jenkins, para predecir el comportamiento futuro del SARS COV2 en la zona 1 del Ecuador.

2 MATERIALES Y MÉTODOS

Aplicando una investigación de tipo cuantitativa, se ha diseñado un modelo ARIMA, con el objetivo de realizar inferencias del número de contagios por COVID-19 en la población de la ZONA 1 del Ecuador, los datos que alimentaron el modelo tuvieron naturaleza secundaria tomados del MSP del Ecuador en la dirección: <https://almacenamiento.msp.gob.ec/index.php/s/tEBUgdkzuv7reEH#pdfviewer>.

El modelo ARIMA, generalmente conocido como metodología Box-Jenkins, se utiliza para pronóstico y análisis en el enfoque de series de tiempo, el acrónimo ARIMA(p,d,q), consta de tres secciones, los modelos autorregresivos, AR que expresan el valor presente como una función lineal en los valores rezagados de la variable, la Integración, I que indica el grado en que la variable es estacionaria y el modelo de Medias Móviles, MA que expresa el valor actual de la variable, como una función lineal en el valor presente de el término de error aleatorio y varios de sus valores de rezago Shoko y Njuho (2023).

2.1 MODELOS AUTORREGRESIVOS

Según De Arce y Mahía (2003), un modelo es autorregresivo si la variable endógena de un período t es explicada por las observaciones de ella misma correspondientes a períodos anteriores añadiéndose, como en los modelos estructurales, un término de error, Los modelos autorregresivos se abrevian con la palabra AR tras la que se indica el orden del modelo: AR (1), AR(2), etc. El orden del modelo expresa el número de observaciones retrasadas de la serie temporal analizada que intervienen en la ecuación. Así, por ejemplo, un modelo AR (1) tendría la siguiente expresión de la ecuación 1:

$$Y_t = \phi_0 + \phi_1 Y_{t-1} + a_t \quad (1)$$

El término de error de los modelos de este tipo se denomina generalmente ruido blanco cuando cumple las tres hipótesis básicas (De Arce, 2003, p. 5):

1. media nula;
2. varianza constante;
3. covarianza nula entre errores correspondientes a observaciones diferentes.

2.2 MODELOS DE MEDIAS MÓVILES

El modelo de media móvil es una agrupación lineal de términos de errores presentes y rezagados, su modelo matemático está representado en la ecuación 2

$$Y_t = \mu + a_t + \beta_1 a_{t-1} \quad (2)$$

Donde:

μ es una constante y a_t , es el término de error estocástico de ruido blanco. Aquí, Y en el periodo t es igual a una constante más un promedio móvil de los términos de error presente y pasado. Así, en este caso decimos que sigue un proceso de promedios móviles de primer orden, o MA (1) (Gujarati, 2010, p. 766).

2.3 PROCESOS ESTOCÁSTICOS INTEGRADOS

Es conocido que muchas series de tiempo no son estacionarias, porque pueden ir cambiando de nivel en el tiempo o sencillamente la varianza no es constante en el tiempo, a este tipo de proceso se les considera procesos integrados, por consiguiente, se debe diferenciar una serie de tiempo d veces para hacerla estacionaria y luego aplicarla a esta serie diferenciada un modelo, ARMA(p,q), en este caso se dice que la serie original es ARIMA(p,d,q), es decir, una serie de tiempo autoregresiva integrada de media móvil (Villavicencio, 2010, p. 19).

2.4 FASES PARA DESARROLLAR UN MODELO ARIMA

El modelo ARIMA es una herramienta estadística eficaz que permite describir un valor de una serie temporal como una función lineal de sus datos anteriores, errores aleatorios, así como también componentes cíclicos o estacionales. Por consiguiente, el modelo ARIMA se construye para capturar todos los elementos necesarios que caracterizan el comportamiento del fenómeno en estudio. Los estadísticos Box y Jenkins, creadores de este modelo, recomiendan trabajar con al menos 50 observaciones en la serie temporal para garantizar resultados confiables. Además, propusieron una metodología sistemática de cuatro fases (Fernández, 2016, p. 1).

Según (Khan, 2020, p. 13) para desarrollar un modelo ARIMA se pueden seguir la secuencia de las siguientes fases o etapas:

La primera etapa consiste en identificar el posible modelo ARIMA (p,d,q) que sigue la serie. Esto implica dos pasos clave:

1. aplicar las transformaciones necesarias para convertir la serie observada en una serie estacionaria; y
2. determinar los órdenes p y q que definen la estructura autorregresiva (AR) y de medias móviles (MA) del modelo ARMA para la serie estacionaria.

Tras identificar un modelo ARIMA provisional para la serie estacionaria, se procede a la fase de estimación. En ella, se calculan por máxima verosimilitud los parámetros AR y MA del modelo, así como los errores estándar de las estimaciones. Además, se obtienen los residuos resultantes del modelo ajustado para su posterior diagnóstico.

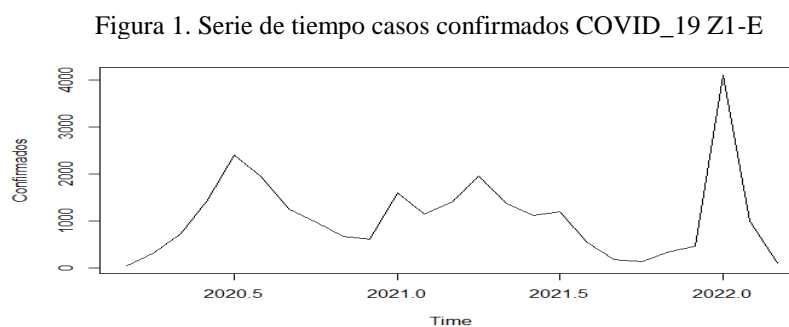
La tercera fase es el diagnóstico de residuos. Se verifica que no presenten estructura de dependencia y sigan un proceso de ruido blanco. De encontrarse inconsistencias, el modelo se reformula para capturar dicha estructura. Las fases de identificación y estimación se repiten hasta obtener residuos que cumplan los supuestos de ruido blanco.

Una vez validado el modelo ARIMA, se procede a la cuarta fase de predicción. En esta etapa final, el modelo se emplea para generar pronósticos de valores futuros de la serie temporal. Esta metodología que consiste en la identificación, estimación, diagnóstico y aplicación, construye modelos ARIMA adecuados y estadísticamente válidos.

2.5 DISEÑO DEL MODELO

2.5.1 Identificación del modelo Arima (p,d,q)

Para identificar el modelo ARIMA(p,d,q), se utilizó el software de código abierto R, los datos de entrada del modelo fueron ordenados cronológicamente, desde el 9 marzo del 2020 hasta el 2 abril del 2022, con frecuencia mensual, la serie temporal de los datos se puede apreciar en la figura 1.



Fuente: Elaboración propia


Se puede observar en la figura 1 que la serie de tiempo para los casos confirmados por COVID-19 en la zona 1 del Ecuador, no es estacionaria, para corroborar esta hipótesis se utilizó como prueba la de Dickey-Fuller aumentada (DFA) con la ayuda del software libre R, obteniendo un valor para el estadístico Dickey-Fuller igual a -3.4985, con un p-valor de 0.0641, mayor al nivel de significancia del 0.05, por lo que se toma la decisión de conservar la hipótesis nula y concluir que la serie no es estacionaria.

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 sólo de la distancia o rezago entre estos dos periodos, y no del tiempo en el cual se calculó la covarianza (Gujarati, 2010, p. 740).

Para lograr la transformación de una serie no estacionaria en estacionaria, está se puede estabilizar con una transformación logarítmica natural o de raíz cuadrada, en este caso se va implementó los dos tipos de transformación (IBM, 2023)

Para la transformación logarítmica, la prueba de DFA asumió un valor -3.4712 , con un p-valor de 0.06789 , que sigue siendo mayor que el nivel de significancia establecido en el 5% , por lo que no fue posible una transformación estacionaria, la transformación por raíz cuadrada fueron significativos con un p-valor de 0.04972 para un DFA igual a -3.6039 , la figura 2, muestra la serie transformada.

Figura 2. Serie de tiempo transformada con extracción de raíz cuadrada de casos confirmados COVID_19 Z1-E



Fuente: Elaboración propia


2.5.2 Estimación de los parámetros (p,q)

Seleccionar valores apropiados para los parámetros p y q requiere pruebas y optimización. Para elegir los valores, se deben inspeccionar observaciones visuales de los datos para determinar la tendencia y/o estacionalidad. Las visualizaciones en forma de gráficos de función de autocorrelación (ACF) y función de autocorrelación parcial (PACF) han demostrado ser útiles para determinar los valores de estos parámetros (Alabdulrazzaq *et al.*, 2021, p. 3).

Se pueden seguir algunas reglas para determinar los valores de p y q de gráficos ACF y PACF. Por ejemplo, si un gráfico ACF muestra que la autocorrelación que ha disminuido drásticamente en el retraso k mientras que el gráfico PACF muestra una disminución más sinusoidal más allá del retraso k , entonces p debe ser cero y q debe establecerse en k (el valor de retraso más grande). Esto se conoce como

MA(q), o modelo de orden de media móvil q . Por otro lado, si un gráfico PACF muestra que la autocorrelación parcial ha disminuido drásticamente en el retraso k mientras que el gráfico ACF muestra una disminución más sinusoidal, entonces q debería ser cero y p debería establecerse en k . Esto se conoce como AR(p), o modelo de orden de regresión automática (Alabdulrazzaq *et al.*, 2021, p. 3).

Figura 3. ACF y PACF serie transformada



Fuente: Elaboración propia

En la figura 3 se puede observar dos picos significativos, para ACF y PACF, por lo que se puede adoptar un modelo ARIMA(0,0,1), para definir el siguiente modelo matemático,

$$Y_t = 29.7070 + a_t + 0.533a_{t-1} \quad (3)$$

2.5.3 Validación del modelo

Con los resultados proporcionados por el software R, por un lado, se calcularon los coeficientes del modelo, MA(1) igual a 0.533, el intercepto 29.7, además los coeficientes del modelo son significativos con p-valores menores al nivel de significancia 0.05.

2.6 ANÁLISIS DE RESIDUOS DE RUIDO BLANCO


El análisis de residuos implica realizar pruebas de diagnóstico para verificar si los residuos del modelo cumplen con las propiedades de un proceso de ruido blanco. Esto requiere comprobar tres supuestos fundamentales: media igual a cero, varianza constante y ausencia de autocorrelación significativa. Únicamente cuando los residuos cumplen estas condiciones se puede concluir que el modelo ARIMA captura adecuadamente el comportamiento estocástico de la serie temporal analizada.

2.6.1 Supuesto media cero

Para verificar que la media de los residuos es cero, se realiza un análisis gráfico representando los residuos en el tiempo. Si los valores oscilan aleatoriamente alrededor de cero, sin tendencias sistemáticas, se puede asumir que se cumple con el supuesto de media cero.

En la figura 4, se puede verificar el supuesto de media cero para los residuos al observar que estos oscilan alrededor del cero

Figura 4. Análisis gráfico supuesto media cero




Fuente: Elaboración propia

2.6.2 Supuesto varianza constante

La evaluación de la homocedasticidad, es decir, el supuesto de variación constante de los residuos es un supuesto fundamental en al análisis de residuos de ruido blanco se evalúa mediante un gráfico de dispersión. Si los residuos se distribuyen de forma homogénea sin patrones sistemáticos, se puede asumir que la varianza de estos permanece constante, la figura 5, exhibe una dispersión aproximadamente constante de los residuos, sin patrones sistemáticos evidentes, este comportamiento aleatorio indica que la varianza de los residuos es homogénea, cumpliendo con el supuesto de varianza constante. Por lo tanto, se puede concluir que la varianza de los residuos permanece constante durante la predicción.

Figura 5. Análisis gráfico supuesto varianza constante



Fuente: Elaboración propia

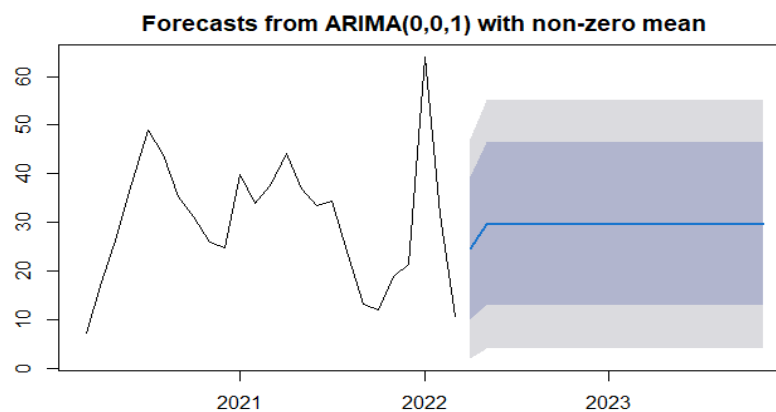
2.6.3 Supuesto de ausencia de correlación serial

Para verificar si los residuos tienen un comportamiento de ruido blanco, se examinan las funciones de autocorrelación (FAC) y autocorrelación parcial (FACP). En un proceso de ruido blanco, estos coeficientes deben ser estadísticamente no significativos. Adicional a esto, según (González, 2009, p. 78) también se comprueba mediante contrastes de significancia conjunta de los coeficientes de autocorrelación, donde la hipótesis nula es que estos son nulos. El no rechazo de esta hipótesis nula validaría la suposición de ruido blanco en los residuos. El test más utilizada para contrastar esta hipótesis es el propuesto por Ljung-Box (1978), este contraste de hipótesis fue analizado, utilizando el software R, se comprobó el supuesto ausencia de correlación serial con un p-valor de 0.8832 mayor del nivel de significancia del 0.05.

3 RESULTADOS Y DISCUSIÓN

Con un nivel de confianza del 95% y después de buscar el modelo que mejor se ajusta a los datos se implementó un modelo ARIMA(0,0,1) con la finalidad de predecir el número de infectados por SARS-CoV-2 en la Zona 1 de Ecuador. El modelo fue alimentado con datos secundarios de casos registrados por el Ministerio de Salud Pública desde abril de 2020 hasta marzo de 2022. La selección del modelo se basó en el análisis de las funciones de autocorrelación (ACF) y autocorrelación parcial (PACF) (Shoko, 2023). Si bien, la muestra de 25 registros fue limitada, el modelo cumplió los supuestos de estacionalidad, independencia de residuos y distribución de ruido blanco, validando su idoneidad. Este enfoque permitió realizar pronósticos confiables de la evolución de la pandemia en la región estudiada, los resultados de la predicción se muestran en la figura 6.

Figura 6. Predicción del número de infectados por covid 19 12 meses



Fuente: Elaboración propia

La figura 7, registra el detalle de la predicción, para un periodo de 12 meses, a partir de abril del 2022, se observa que el número de infectados esperados hasta marzo del 2023 fue de 30 infectados.

Figura 7. Predicción modelo ARIMA (0,0,1)

	Point Forecast <dbl>	Lo 80 <dbl>	Hi 80 <dbl>	Lo 95 <dbl>	Hi 95 <dbl>
Apr 2022	24.63815	9.924758	39.35154	2.135959	47.14034
May 2022	29.70697	13.033973	46.37998	4.207819	55.20613
Jun 2022	29.70697	13.033973	46.37998	4.207819	55.20613
Jul 2022	29.70697	13.033973	46.37998	4.207819	55.20613
Aug 2022	29.70697	13.033973	46.37998	4.207819	55.20613
Sep 2022	29.70697	13.033973	46.37998	4.207819	55.20613
Oct 2022	29.70697	13.033973	46.37998	4.207819	55.20613
Nov 2022	29.70697	13.033973	46.37998	4.207819	55.20613
Dec 2022	29.70697	13.033973	46.37998	4.207819	55.20613
Jan 2023	29.70697	13.033973	46.37998	4.207819	55.20613

1-10 of 36 rows

PREVIOUS 1 2 3 4 NEXT

Elaboración: Propia.

Alabdulrazzaq *et al.* (2021), pusieron a prueba la precisión de un modelo ARIMA en la predicción de casos confirmados y recuperados, utilizando a Kuwait como caso de estudio, los modelos seleccionados fueron examinados en términos de medidas de precisión, utilizando los gráficos ACF y PACF, la precisión de dicho modelo resultó apropiada y satisfactoria, lo cual puede corroborar la precisión del modelo de este estudio utilizando la metodología Box-Jenkins. Por otro lado Shoko y Njuho (2023), utilizaron un modelo ARIMA, también como predictor de la propagación de COVID-19 en la región de la SADC al Sur de Sudáfrica ellos diseñaron los modelos candidatos, observando los picos los picos de los gráficos de función autocorrelación (ACF) y función de autocorrelación parcial (PACF). El ajuste de varios modelos ARIMA dio como resultado un modelo de predicción cuya precisión en el rendimiento se evaluó mediante el error de la raíz cuadrada media (RMSE), el modelo del presente estudio fue validado tomando como medida el nivel de dispersión de los valores residuales, lo cual es un buen indicador de su precisión.

4 CONCLUSIONES

El presente trabajo de investigación fue capaz de desarrollar un modelo ARIMA, con el propósito de predecir, el número de infectados por COVID-19, en la Zona 1, en un periodo de 12 meses, el modelo se validó correctamente y pudo predecir el número de infectados en dicho periodo.

Los modelos ARIMA, no son sencillos de diseñar, se ha utilizado el software R, para obtener el modelo que mejor se ajusta a los datos, en este caso el modelo equivale a un modelo de medias móviles MA (1), sin violar ninguno de los supuestos en su desarrollo.

REFERENCIAS

- Alabdulrazzaq, H., Alenezi, M. N., Rawajfih, Y., Alghannam, B. A., Al-Hassan, A. A., & Al-Anzi, F. S. (2021). On the accuracy of ARIMA based prediction of COVID-19 spread. *Elsevier*, 27, 1-17. doi: <https://doi.org/10.1016/j.rinp.2021.104509>
- Bravo-García, E., & Magis-Rodríguez, C. (2020). La respuesta mundial a la epidemia del COVID-19: los primeros tres meses. *Boletín sobre COVID-19 Salud Pública y Epidemiología*, 3-8. Obtenido de <https://dsp.facmed.unam.mx/wp-content/uploads/2022/03/COVID-19-No.1-03-La-respuesta-mundial-a-la-epidemia-del-COVID-19-los-primeros-tres-meses.pdf>
- De Arce, R. (2003). *Modelos ARIMA*. Programa CITUS: Técnicas de Variables Financieras.
- Fernández, S. D. (2016). *Series Temporales, Modelo ARIMA Metodología de BOX-JENKINS*. Madrid: Universidad Autónoma de Madrid. Obtenido de <https://www.estadistica.net/ECONOMETRIA/SERIES-TEMPORALES/modelo-arima.pdf>
- González, C. M. (2009). *Análisis de series temporales: Modelos ARIMA*.
- Gujarati, D. N. (2010). *Econometría*. Mexico: Mc Graw Hill.
- IBM. (06 de 12 de 2023). *IBM*. Obtenido de <https://www.ibm.com/docs/es/spss-modeler/saas?topic=data-series-transformations>
- Khan, F. M., & Gupta, R. (2020). ARIMA and NAR based prediction model for time series analysis of COVID-19 cases in India. *Journal of Safety Science and Resilience*, 12-18. doi: <https://doi.org/10.1016/j.jnlssr.2020.06.007>
- Ledo, M. V., Rodríguez, W. B., García, F. D., & Bermejo, P. M. (2020). Número Básico de Reproducción (R0). *Educación Médica Superior*, 1-12. Obtenido de <http://scielo.sld.cu/pdf/ems/v34n4/1561-2902-ems-34-04-e2596.pdf>
- López, Y. A. (2022). Pronóstico del COVID-19 en Colombia utilizando Redes Neuronales Recurrentes con celdas de gran memoria de corto plazo y unidades recurrentes cerradas. *Comunicaciones en Estadística*, 16-38. Obtenido de <file:///C:/Users/user/Desktop/Dialnet-PronosticoDelCOVID19EnColombiaUtilizandoRedesNeuro-8710231.pdf>
- Ruiz, G. I., & León, A. C. (2020). Evolución de la enfermedad por coronavirus (Covid-19) en Ecuador. *La Ciencia al Servicio de la Salud y la Nutrición*, 11(1), 5-15. Obtenido de <http://revistas.esPOCH.edu.ec/index.php/cssn/article/view/441/422>
- SHOKO Claris, N. P. (2023). Arima model in predicting of Covid-19 epidemic for the Southern Africa region. *Journal of Infectious Diseases*, 1-9. doi:<https://doi.org/10.21010/Ajidv17i1.1>
- Sidhu, R. K. (2021). An Application of ARIMA Model to Forecast the Dynamics of COVID-19 Epidemic in India. *Global Business Review*. doi:10.1177/0972150920988653journals.sagepub.com/home/gbr
- Villavicencio, J. (2010). *Introducción a series de tiempo*. Puerto Rico.