

Análisis de contagios SARS COV-2 por medio de herramientas de series de tiempo

Time series analysis for SARS COV-2 infections

DOI: 10.18041/2619-4244/dl.34: Enero-Junio.11649

Resumen:

El presente artículo propone analizar y desarrollar herramientas de series de tiempo con las cuales se pueda estimar la curva de contagios de SARS-COV2 en países de Latinoamérica. Para llevar a cabo este estudio se toma una muestra de contagios diarios de casos positivos en 10 países. Para su desarrollo se utilizaron los modelos econométricos, ARIMA, ARFIMA y NNAR, a los que se le realizaron diferentes estimaciones con el fin de determinar el que mejor se ajustara a la serie a partir de la medición de los criterios de bondad de ajuste. El resultado de este estudio demuestra que por medio de los modelos de NNAR se puede pronosticar de forma más acertada y precisa la curva de contagios de COVID-19 en LATAM.

Palabras clave: ARIMA, ARFIMA, Redes neuronales, SARS-COV2, COVID-19, series de tiempo.

Abstract:

The paper proposes developing time series tools to estimate the SARS-COV2 infection in Latin American countries using a daily infections dataset in ten countries. We use the ARIMA, ARFIMA and NNAR models for methodological development. We made different estimations to determine the best fit for the series based on the measurement of the goodness-of-fit criteria, showing that NNAR models can be used to predict the COVID-19 infection curve in LATAM more accurately and precisely.

Keywords: ARIMA, ARFIMA, Neural Networks, SARS-COV2, COVID-19, time series.

David Santiago Álzate Vélez

Ingeniero financiero
Instituto Tecnológico Metropolitano de Medellín
davidalzate220456@correo.itm.edu.co

Luisa Fernanda Rojas Metaute

Ingeniero financiero
Instituto Tecnológico Metropolitano de Medellín
luisarojas213893@correo.itm.edu.co

William Fernando Correa Serna


Ingeniero financiero
Instituto Tecnológico Metropolitano de Medellín
williamcorrea199727@correo.itm.edu.co

David Esteban Rodríguez Guevara

Magister en Administración financiera
Instituto Tecnológico Metropolitano de Medellín
davidrodriguez@itm.edu.co

Cómo citar: Álzate Vélez, D. S. ., Rojas Metaute , L. F. ., Correa Serna , W. F. ., & Rodríguez Guevara , D. E. . (2024). Análisis de contagios SARS COV-2 por medio de herramientas de series de tiempo . Dictamen Libre, (34: Enero-Junio).
<https://doi.org/10.18041/2619-4244/dl.34: Enero-Junio.11649>

Licencia Creative Commons
Atribución-CompartirIgual 4.0
Internacional



Recibido: 30 de noviembre de 2023 - Aceptado: 11 de abril de 2024



Introducción

El 16 de marzo de 2020 la (OMS, 2020a) decreto que” ...la pandemia de la COVID-19 es una emergencia sanitaria y social mundial.” Hasta el 10 de septiembre de 2021, un total de 43 millones de casos de COVID-19 han sido registrados en América Latina y el Caribe. Brasil es el país más afectado por esta pandemia en la región, con alrededor de 20.9 millones de casos confirmados, Argentina se ubica en segundo lugar con aproximadamente 5.2 millones de infectados, México, por su parte, ha registrado un total de 3.479.999 casos (Statista Research Department, 2021). El 1 de septiembre de 2021, la (OPS, 2021b) advirtió que el 75% de la población de América Latina y el Caribe aún no está totalmente vacunada contra la COVID-19 e informó que la OPS está acelerando sus esfuerzos para ampliar el acceso a las vacunas en toda la región. (OPS, 2021a) (Abigail Orús, 2021).

La aplicación de modelos estadísticos para obtener una predicción del número de infectados por esta enfermedad en una nación se ha vuelto de gran interés. (Kartikasari et al., 2020) estimaron los casos futuros positivos y muertes por COVID-19 en Indonesia mostrando la eficiencia de estimación de dichos modelos. (Pinzón, 2021) por su parte da a conocer un modelo ARIMA para pronosticar el tiempo de inmunidad de rebaño que demuestra que para el 19 de enero de 2022 se logrará obtener la inmunidad de rebaño. (Hamadneh et al., 2021) presenta un artículo donde utilizan redes neuronales artificiales (ANN) para predecir el número de casos de COVID-19 en Brasil y México en ciertos días, el estudio muestra el número esperado de infecciones, recuperaciones y muertes que Brasil y México alcanzarán diariamente a principios de 2021.

Desde el momento en que se detectó por primera vez el COVID-19, hasta principios de mayo de 2020, se había propagado a 216 países y había infectado a más de 4 millones de personas en todo el mundo, con más de 300.000 muertes registradas (Alabdulrazzaq et al., 2021) (Ala'raj et al., 2021); esto genera la necesidad de hacer un estudio y análisis de los comportamientos del virus que puede llegar a ser medible. Una predicción acertada del número de contagios ayudaría a los responsables políticos de una región concreta a evaluar su infraestructura sanitaria actual y a decidir qué medidas deben adoptarse para detener y controlar la difusión del COVID-19 (Alabdulrazzaq et al., 2021).

Respecto a estudios previos, se encuentra a (Dehesh et al., 2020) en el que predicen casos confirmados con modelos ARIMA con datos de casos confirmados, con el fin de tener una mayor preparación en los sistemas de salud. El estudio de (Ilie et al., 2020) muestra que los modelos de series de tiempo ARIMA fueron aplicado con éxito para estimar la prevalencia general de COVID-19 en nueve países. (Kartikasari et al., 2020) demuestran que el ARFIMA (1,0.431,0) es el mejor modelo para predecir los datos sobre la adición de nuevos casos de pacientes que mueren por COVID-19. (Adesina et al., 2020). Se utilizó el modelo de Media Móvil Integrada (ARFIMA) para predecir la tendencia de los casos confirmados en Argelia obteniendo resultados eficientes de predicción.

Este artículo se desarrolla con modelos ARIMA, ARFIMA y NNAR; principalmente se realizarán varias estimaciones de los modelos para obtener el que mejor se ajuste a la serie, el cual este será determinado por medición de los criterios de bondad de ajuste. Se toma del sitio web <https://ourworldindata.org/coronavirus> los casos positivos confirmados por COVID-19 en LATAM entre el 23 de febrero de 2020 hasta el 15 de septiembre de 2021. Este estudio tendrá como objetivo principal determinar el comportamiento del COVID-19 en LATAM.



Teniendo en cuenta los anteriores estudios, hace necesario investigar y utilizar tres tipos de modelos basados en modelos paramétricos univariados (ARIMA y ARFIMA) y otro un sistema de predicción genética como lo es una red neuronal autorregresiva (ANN) (Niazkar & Niazkar, 2020) buscando responder a ¿Qué modelo puede predecir con mayor precisión la curva de contagios de COVID-19 (SARS-COV2) en Latinoamérica?

Materiales y métodos

A continuación, se mostrarán los modelos que se implementarán para medir la evolución diaria del COVID.(Velásquez & Franco, 2012)

Modelo ARIMA

De la Fuente Fernández (2016) indica que el modelo ARIMA permite describir un valor como una función lineal de datos anteriores y errores debidos al azar, además puede incluir un componente cíclico o estacional, debe contener todos los elementos necesarios para describir el fenómeno. Los pasos para realizar un modelo ARIMA son: 1) Transformar la serie observada en una serie estacionaria o determinar un modelo ARMA para la serie estacionaria. 2. Se estiman los parámetros AR y MA y se obtiene los errores del modelo. 3. Realizar el diagnostico, donde se comprueba que los residuos no tienen estructura de dependencia y siguen un proceso de ruido blanco. 4. Una vez que se ha obtenido un modelo adecuado se realizan predicciones con el mismo. Se define ARIMA como en la ecuación [1]. donde $\Delta^d Y_t = (1 - B)^d Y_t$ es un proceso estacionario, d es un número entero positivo, B es el operador de retardo, $\{a_t\}$ es un proceso de ruido blanco con distribución $\mathcal{N}(0, \sigma^2)$ y los términos $\phi(B) = 1 - \phi_1 B - \phi_2 B^2$ corresponde a la parte autorregresiva y media móvil, respectivamente.

$$\phi(B)\Delta^d Y_t = \phi(B)(1 - B)^d Y_t = \theta(B)a_t \quad [1]$$

Modelo ARFIMA

Brockwell & Davis (2002) manifiestan que un proceso estocástico Z_t es un proceso ARFIMA (p, d, q) si es una solución a la ecuación [2]. donde $\phi(B) = 1 - \phi_1 B - \dots - \phi_p B^p$ y $\theta(B) = 1 - \theta_1 B - \dots - \theta_q B^q$ son respectivamente, los polinomios autorregresivos y de medias móviles de orden p y q de un proceso ARMA, cuyos ceros están fuera del círculo unidad y no tienen raíces comunes; d y θ_0 son números reales, d es llamado el parámetro de diferenciación fraccional, a_t son variables aleatorias no observables independientes e idénticamente distribuidas con media cero y varianza finita σ_a^2 . Castaño (2016) Mostró que si $d > -0,5$ y todas las raíces de $\theta(B) = 0$ caen fuera del círculo unidad, Z_t Es un proceso invertible; si $d < -0,5$ y todas las raíces de $\phi(B) = 0$ caen fuera del círculo unidad, Z_t Es un proceso estacionario. Por tanto, el proceso ARFIMA (p, d, q) es estacionario e invertibles si todas las raíces de $\theta(B) = 0$ y de $\phi(B) = 0$ caen fuera del círculo unidad y $-0,5 < d < 0,5$.



$$\phi(B)(1 - B)^d Z_t = \theta_0 + \theta(B)\alpha_t. t = 1. \dots T. \quad [2]$$

Redes Neuronales

Las redes neuronales son modelos computacionales que imitan las redes de neuronas del cerebro con el fin de emular el comportamiento inteligente (Velásquez & Franco. 2012) y (Velasquez-H.. 2011). Según (Florez Raquel, 2008) para desarrollar un modelo de red neuronal autorregresivo los rezagos definidos pueden ser utilizados como variables de entrada, de la misma manera que se utilizan en los modelos de predicción de auto regresión lineal. (Martín & Píneros. 2020). La aplicación de estos modelos ha sido definida en cinco etapas. (1) búsqueda de las variables. (2) preparación del conjunto de datos. (3) creación de la red. (4) entrenamiento. (5) validación. (Floréz López & Fernández Fernández, 2008). Como se muestra en [3] Donde β * es el peso de la conexión de la neurona adaptativa a la neurona de salida, βh es el peso asociado a la conexión entre cada neurona h de la capa oculta y la neurona de salida, ωh respresenta el peso de las conexión que van de la neurona adaptativa hasta cada neurona h de la oculta, $\alpha i, h$ pesos entre cada entrada i y la neurona h en la capa oculta, H representa el número de neuronas en la capa oculta, p es el número de rezagos considerados y g es la función de activación de las neuronas de procesamiento en la capa oculta.

$$y_t = \beta * \sum_{h=1}^H \beta h g (\omega h + \sum_{i=1}^p \alpha i, h \times y_{t-i}) \quad [3]$$

Criterios de bondad de ajuste

Castaño (2016) muestra que para ver la adecuación que existe entre la serie real y la estimada se puede utilizar el coeficiente de determinación o el coeficiente de determinación corregido, también el criterio de Schwartz y el criterio de Hannan Quinn. (Bielsa. 2016), el criterio de Información de Akaike (AIC, Criterio de información corregido (AICc), ME (mean error), MAE (mean absolute error), MPE (mean percentage error), MAPE (mean absolute porcentage error), MASE (mean absolute porcentage error), RMSE (root mean squared error).

Resultados

La información que se va a analizar e interpretar con el modelo, son los datos de números de contagios nuevos en los países de Latinoamérica tomados del sitio web oficial <https://ourworldindata.org/coronavirus>. La serie inicia el 23 de febrero de 2020 y va hasta 15 de septiembre de 2021, con una frecuencia diaria. Después de la construcción de la base de trabajo se realizan cálculos de algunas estadísticas descriptivas mostradas en la Tabla 1. para poder identificar variaciones y comportamientos de cada una de las variables que nuestro estudio son los países de Latinoamérica.



Tabla 1. Estadística Descriptiva de países con contagios diarios de SARS-COV-2.

País	Maximum	Mean	Median	Stand Des	Skewness	Kurtosis	coef var	JB P-value
Argentina	41080	9310.25	7682	8213.85	1.19	1.29	0.88	0.00
Bolivia	7072	895.36	681	903.3	1.98	7.11	1.01	0.00
Brasil	115228	37032.76	33775	25324.99	0.44	-0.58	0.68	0.00
Chile	13990	2881.32	2037	2315.96	1.05	0.96	0.8	0.00
Colombia	33594	8827.49	7523	7519.38	1.08	0.78	0.85	0.00
Ecuador	11536	935.7	814	943.46	4.10	34.40	1.01	0.00
Paraguay	3481	824.76	662	837.01	1.1	0.39	1.01	0.00
Perú	21358	3869.97	2935	4029.77	1.46	2.22	1.04	0.00
Uruguay	7289	701.45	118	1141.2	2.01	3.88	1.63	0.00
México	32244	6258.28	5083	5527.15	1.63	2.84	0.88	0.00

Nota: El valor Mínimo para todos los países es cero contagios.

De acuerdo con la tabla 1 los datos máximos de contagios nuevos en un día se encuentran en Brasil, Argentina, Colombia y México, esto es coherente con el orden de países con más casos hasta la fecha en Latinoamérica. Los países con promedio de casos más bajo son Uruguay y Paraguay los cuales oscilan entre 700 y 800 casos diarios, de estos últimos 3 países Paraguay exhibe que su desviación de casos con respecto a su promedio es de 837.01. En cuanto a la estadística de la información presentada, se observa que Uruguay presenta mayor variación mostrando un coeficiente igual a 1.63. dando señales de datos heterogéneos. (Statista Research Department. 2021).

A continuación, se da evidencia del desarrollo y análisis de los modelos de series de tiempo utilizados para el desarrollo de este trabajo.

Modelos ARIMA

Luego de realizar la comparación de diferentes modelos ARIMA para cada país, en la tabla 2 se observa los modelos seleccionados, los cuales fueron determinados por análisis de bondad de ajuste y la significancia de sus coeficientes. De los modelos comparados para Brasil, se evidencia que en el modelo ARIMA (3,1,1), estos comparados con el modelo (3,1,2) y (2,1,2). Con base a los criterios RMSE y ME, se selecciona el modelo ARIMA (3,1,1) presenta los menores valores en este criterio a comparación de los otros dos modelos estimados.

Tabla 2 Estadística Descriptiva de países con contagios diarios de SARS-COV-2

País	(p,d,q)	Coef	Pvalue	País	(p,d,q)	Coef	Pvalue
Argentina	(1,1,3)	-0.248	0.043	Paraguay	(1,1,2)	0.298	0.000
		0.262	0.020			-0.550	0.000
		-0.464	0.000			-0.212	0.000
		-0.381	0.000				
Bolivia	(1,1,2)	-0.653	0.000	Ecuador	(2,1,0)	-0.629	0.000
		-0.497	0.000			-0.337	0.000
		-0.216	0.001				
Brasil	(3,1,1)	0.275	0.000	Perú	(2,1,0)	-0.882	0.000
		-0.173	0.000			-0.330	0.000
		-0.256	0.000				
		-0.851	0.000				
Chile	(3,1,1)	0.174	0.000	Uruguay	(2,1,0)	-0.521	0.000
		-0.092	0.027			-0.196	0.000



País	(p,d,q)	Coef	Pvalue	País	(p,d,q)	Coef	Pvalue
		-0.285	0.000				
		-0.719	0.000				
		0.511	0.000				
Colombia	(2,1,1)	-0.135	0.002	México	(2,1,1)	0.143	0.002
		-0.641	0.000			-0.095	0.033
						-0.846	0.000

Respecto a Colombia, se estimaron los modelos ARIMA (2,1,1), (2,1,4) y (1,1,3), de los cuales se selecciona el modelo ARIMA (2,1,1), a pesar de que el modelo (2,1,4) presentara unos valores en los criterios RMSE y ME menores a comparación de los otros dos modelos, sus coeficientes M1, AR1 y AR2 presentan valores que dejan de ser significativos a la hora de hacer la selección del mejor modelo que ajuste los datos.

Modelos ARFIMA

En la Tabla 3, se observan las estimaciones de los parámetros de los mejores modelos ARFIMA para cada país. Todos los modelos arrojan un parámetro de diferenciación fraccional entre el intervalo [-0.5, 0.5] indicando que las series en estudio tienen una dinámica de memoria de largo plazo. Brasil por su parte con la estimación de los modelos ARFIMA (2,0.40,0), (1,0.37,1) y (3,0.45,0) para la selección del modelo con mejor ajuste, se analiza el p-valor de los diferentes parámetros en los modelos, del cual se puede afirmar que el modelo (3,0.45,0) al presentar un p-valor en el parámetro AR1 mayor a 0,05 este pierde significancia estadísticamente, a pesar de presentar un valor menor de bondad de ajuste en comparación de los otros dos modelos. Para el modelo seleccionado (2,0.40,0) este presenta un RMSE de 15719.23 y un ME 38.87 lo que significa que es el modelo que menos se desvía de los datos originales.

Tabla 3 Estadística Descriptiva de países con contagios diarios de SARS-COV-2.

País	(p,d,q)	Coef	Pvalue	País	(p,d,q)	Coef	Pvalue
		0.472	0.000	Ecuador	(0,0.45,2)	0.459	0.000
Argentina	(0,0.47,2)	-0.611	0.000			0.443	0.000
		-0.097	0.033			0.176	0.000
		0.176	0.000	Paraguay	(0,0.45,3)	0.495	0.000
		0.470	0.000			-0.366	0.000
Bolivia	(2,0.17,1)	0.504	0.000			-0.088	0.037
		0.827	0.000			0.092	0.041
		0.408	0.000	México	(0,0.49,2)	0.491	0.000
Brasil	(2,0.40,0)	0.138	0.005			0.197	0.000
		-0.175	0.000			0.154	0.000
		0.351	0.000	Uruguay	(2,0.14,1)	0.140	0.000
		-0.232	0.000			0.986	0.000
Chile	(1,0.35,3)	-0.525	0.000			0.004	0.000
		-0.433	0.000			0.783	0.000
		-0.647	0.000				
		0.301	0.000	Perú	(3,0.47,0)	0.479	0.000
Colombia	(2,0.30,1)	1.339	0.000			-0.684	0.000
		-0.349	0.000			-0.340	0.000
		0.821	0.000			-0.246	0.000



Redes Neuronales (NNAR)

Durante la ejecución del modelo de Red Neuronal para cada una de las series, se estableció una cantidad de 30 nodos para la capa oculta, teniendo en cuenta que estas series presentan una temporalidad secuencial diaria. Para cada serie se estableció una cantidad de 10 repeticiones mostrando un mejor procesamiento al momento de arrojar resultados. Para Brasil se realizaron tres simulaciones con diferentes repeticiones (1,5 y 10), donde se logra evidenciar que con 10 repeticiones esta muestra una red más entrenada mostrando unos datos más precisos a comparación de las otras dos simulaciones.

Respecto a la varianza de los modelos, para Brasil, Perú y México arrojan un σ^2 de proporciones altas, lo que significa que estos países presentan una volatilidad mayor a los demás, el único indicador que asume la determinación del ajuste para estos tres países es el MASE mostrando un valor <1 .

Tabla 4: Estimación modelos Redes Neuronales.

variable	MODELO	σ^2	variable	MODELO	σ^2
Argentina	(27,1,7)	50777.00	Ecuador	(14,1,7)	38659.00
Bolivia	(27,1,7)	16849.00	México	(24,1,7)	239431.00
Brasil	(23,1,7)	5946336.00	Paraguay	(27,1,7)	472.70
Chile	(16,1,7)	10493.00	Perú	(21,1,7)	179503.00
Colombia	(16,1,7)	27686.00	Uruguay	(27,1,7)	5767.00

Comparativa de modelos y elección de modelos según su medición.

Inicialmente se tomó una muestra de los contagios positivos en LATAM hasta el 15 de septiembre del 2021, por lo cual se le desarrollo un entrenamiento de los datos estimando los modelos que mejor se ajustaran a la serie, posterior a esto, se revisa la eficiencia de los modelos a través de una prueba con los datos más recientes hasta el 31 de octubre del 2021, analizando sus residuales y mediciones de criterios de bondad de ajuste.

Después de la ejecución de los modelos ARIMA, ARFIMA y NNAR se realiza una comparación entre los resultados obtenidos de las 10 series de tiempo, logrando dar evidencia al modelo que mejor ajustara los datos para cada país. En la tabla 5 se logra evidenciar que las 10 series de tiempo, todas obtuvieron un mejor ajuste con NNAR, esto basándonos en los resultados obtenidos de sus residuales. Respecto a Brasil este presenta el valor más alto en el índice RMSE y MAE en los modelos ARIMA y ARFIMA en comparación al resto de países. El modelo de NNAR lleva a determinar que es el modelo de mejor ajuste para esta serie al tener unos índices de RMSE de 1324.07 y MAE de 1324.07, aunque estos dos criterios presentan valores iguales en el caso de Brasil

México presenta un comportamiento similar entre ARIMA y ARFIMA, pero para el caso de la medición de los criterios de bondad de ajuste del modelo ARFIMA estos presentan unos índices mayores a los del modelo ARIMA. Al igual que el comportamiento de las demás series esta evidencia que el modelo de NNAR estudia de mejor manera los datos de este país. Realizando una verificación de los modelos



estudiados, se puede evidenciar que hay un ajuste más preciso de un pronóstico más acertado con el modelo de NNAR.

Realizando un análisis para el criterio MASE se puede evidenciar que el modelo de NNAR presenta unos índices en las series que se aproximan a 0 a comparación de ARIMA y ARFIMA que tienen tendencia a 1, demostrando que el modelo de NNAR realiza un ajuste más preciso con la prueba de eficiencia de los modelos y esto da certeza que el modelo de NNAR puede realizar un pronóstico más acertado a la realidad de los casos futuros por COVID-19 en LATAM.

Tabla 5 Estadística Descriptiva de países con contagios diarios de SARS-COV-2.

País	MODELO	RMSE	MASE	MAE	ME	Elección
Argentina	ARIMA(1,1,3)	442.17	0.73	358.53	-113.94	
	NNAR(27,1,7)	123.55	0.003371	123.55	-645.10	✓
	ARFIMA(0,0.47,2)	1290.37	0.68	1210.58	-1208.36	
Bolivia	ARIMA(1,1,2)	311.8	0.65	225.22	21.68	
	NNAR(27,1,7)	9.829	0.01280	9.83	-9.83	✓
	ARFIMA(2,0.17,1)	304.59	0.67	220.43	-3.80	
Brasil	ARIMA(3,1,1)	6945.55	0.76	4599.74	-752.30	
	NNAR(23,1,7)	1324.07	0.01221	1324.07	-6484.36	✓
	ARFIMA(2,0.40,0)	9645.73	0.73	8286.48	-6444.07	
Chile	ARIMA(3,1,1)	251.00	0.80	208.12	141.86	
	NNAR(16,1,7)	0.69	0.02567	0.69	-254.76	✓
	ARFIMA(1,0.35,3)	295.87	0.88	261.71	-139.06	
Colombia	ARIMA(2,1,1)	2161.33	0.59	686.42	4.94	
	NNAR(16,1,7)	27.99	0.02685	27.99	-368.86	✓
	ARFIMA(2,0.30,1)	2491.16	0.60	1602.85	-917	
Ecuador	ARIMA(2,1,0)	495.36	0.65	361.72	0.13	
	NNAR(14,1,7)	3.17	0.11184	3.17	-111.37	✓
	ARFIMA(0,0.45,2)	599.44	0.68	573.98	-423.40	
México	ARIMA(2,1,1)	4513.72	0.64	3318.53	-1074.02	
	NNAR(24,1,7)	579.32	0.0215	337.85	-7.82	✓
	ARFIMA(0,0.49,2)	4595.63	0.63	3549.53	-1157.24	
Perú	ARIMA(2,1,0)	486.49	0.68	385.20	5.82	
	NNAR(21,1,7)	33.07	0.02763	33.072	-958.1	✓
	ARFIMA(3,0.47,0)	499.55	0.67	383.22	-251.62	
Paraguay	ARIMA(1,1,2)	50.03	0.54	29.63	-0.87	
	NNAR(27,1,7)	3.344	0.00454	3.344	-49.42	✓
	ARFIMA(0,0.45,3)	115.57	0.58	105.30	-98.93	
Uruguay	ARIMA(2,1,0)	42.30	0.95	34.26	2.99	
	NNAR(17,1,7)	10.59	0.007146	10.59	-75.82	✓
	ARFIMA(2,0.14,1)	40.46	0.94	32.69	-3.11	

Conclusiones y recomendación

En la implementación de los modelos ARIMA se logra evidenciar que al realizar las estimaciones del modelo que mejor se ajustara a los datos de cada país en estudio, Brasil en particular es uno de los países con los criterios de bondad de ajuste más altos a comparación del resto países. Con los modelos



estimados para cada serie de tiempo se puede afirmar que el modelo ARIMA no es el apropiado para lograr una predicción real de los casos futuros de COVID-19 en estos países de LATAM, puesto que en comparación con el modelo NNAR, este presenta unos índices muy elevados, dando certeza que no se logra un ajuste preciso.

Con los datos obtenidos a través de los modelos de NNAR se puede afirmar que este tipo de modelo tiene una precisión más acertada de los datos en estudio, puesto que en comparación con los modelos ARIMA y ARFIMA los criterios de bondad de ajuste muestran valores mucho más bajos logrando dar confiabilidad a las predicciones realizadas. Los resultados y análisis muestran que por medio de los modelos de NNAR se puede pronosticar de forma más acertada y precisa la curva de contagios de COVID-19 en LATAM.

Agradecimientos

Los autores agradecen al Instituto Tecnológico Metropolitano de Medellín y a la Facultad de Ciencias Económicas y Administrativas por la oportunidad del proceso académico y de investigación.

Conflicto de intereses

Los autores de este artículo manifiestan la independencia en su proceso de investigación y redacción, sin tener ningún conflicto de intereses.

Referencias

- Abigail Orús. (2021). Casos confirmados de coronavirus en el mundo por continente 2021 | Statista. Número de Casos Confirmados de Coronavirus a Nivel Mundial a Fecha de 12 de Septiembre de 2021, Por Continente.
- Adesina, O. S., Onanaye, S. A., Okewole, D., & Egere, A. C. (2020). Forecasting of New Cases of COVID-19 in Nigeria Using Autoregressive Fractionally Integrated Moving Average Models. *Asian Research Journal of Mathematics*, 135–146. <https://doi.org/10.9734/arjom/2020/v16i930226>
- Alaraj, M., Majdalawieh, M., & Nizamuddin, N. (2021). Modeling and forecasting of COVID-19 using a hybrid dynamic model based on SEIRD with ARIMA corrections. *Infectious Disease Modelling*, 6, 98–111. <https://doi.org/10.1016/j.idm.2020.11.007>
- 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. *Results in Physics*, 27. <https://doi.org/10.1016/j.rinp.2021.104509>
- Bielsa, F. J. T. (2016). *bibliotecaitm - Introducción a la econometría*. <https://elibro-net.itm.elogim.com:2443/es/lc/bibliotecaitm/titulos/49156>
- Brockwell, P. J., & Davis, R. A. (2002). *Introduction to Time Series and Forecasting - Second Edition*. In



Springer-Verlag. <http://books.google.com/books?id=9tv0taI8I6YC>

- Castaño, E. (2016). $\hat{\tau}$ DE MODELOS ARFIMA a IDENTIFICACION IDENTIFICATION IN ARFIMA MODELS. 12–37.
- de la Fuente Fernández, S. (2016). Series Temporales: Modelo Arima. Universidad Autónoma de Madrid, 1–14. <http://www.estadistica.net/ECONOMETRIA/SERIES-TEMPORALES/modelo-arima.pdf>
- Dehesh, T., Mardani-Fard, H. A., & Dehesh, P. (2020). Forecasting of COVID-19 Confirmed Cases in Different Countries with ARIMA Models. MedRxiv, 1–12. <https://doi.org/10.1101/2020.03.13.20035345>
- Floréz López, R., & Fernandez Fernandez, J. M. (2008). Las Redes Neuronales Artificiales.
- Florez Raquel. (2008). Las Redes Neuronales Artificiales.
- Hamadneh, N. N., Tahir, M., & Khan, W. A. (2021). Using artificial neural network with prey predator algorithm for prediction of the COVID-19: The case of Brazil and Mexico. In Mathematics (Vol. 9, Issue 2, pp. 1–14). <https://doi.org/10.3390/math9020180>
- Ilie, O. D., Cojocariu, R. O., Ciobica, A., Timofte, S. I., Mavroudis, I., & Doroftei, B. (2020). Forecasting the spreading of COVID-19 across nine countries from Europe, Asia, and the American continents using the arima models. Microorganisms, 8(8), 1–19. <https://doi.org/10.3390/microorganisms8081158>
- Kartikasari, P., Yasin, H., & Asih I Maruddani, D. (2020). ARFIMA Model for Short Term Forecasting of New Death Cases COVID-19. E3S Web of Conferences, 202. <https://doi.org/10.1051/e3sconf/202020213007>
- Martin, R., & Pineros, L. (2020). Propuesta de un modelo con redes neuronales y metodología Box & Jenkins para el pronóstico del precio de bolsa de la energía en Colombia. 57. <https://repository.libertadores.edu.co/handle/11371/2654#.X3xvnsLRIJA.mendeley>
- Niazkar, H. R., & Niazkar, M. (2020). Application of artificial neural networks to predict the COVID-19 outbreak. Global Health Research and Policy, 5(1). <https://doi.org/10.1186/s41256-020-00175-y>
- OMS. (2020). COVID-19: cronología de la actuación de la OMS. In Organización Mundial de la Salud.
- OPS. (2021a). Controlar la COVID-19 en las Américas podría llevar años si continúa el ritmo lento de vacunación actual, advierte la directora de la OPS - OPS/OMS | Organización Panamericana de la Salud. Controlar La COVID-19 En Las Américas Podría Llevar Años Si Continúa El Ritmo Lento de Vacunación Actual, Advierte La Directora de La OPS.
- OPS. (2021b). OPS: sólo una de cada cuatro personas está completamente vacunada contra la COVID-19 en América Latina y el Caribe - OPS/OMS | Organización Panamericana de la Salud. OPS: Sólo Una de Cada Cuatro Personas Está Completamente Vacunada Contra La COVID-19 En América Latina y El Caribe.
- Pinzón, J. E. D. (2021). Perspectiva del tiempo para alcanzar la inmunidad de rebaño para COVID-19 a nivel mundial. Revista Repertorio de Medicina y Cirugía, 30, 73–78.



<https://doi.org/10.31260/REPERTMEDCIR.01217372.1245>

Statista Research Department. (2021). • Coronavirus en Latinoamérica: países con más casos | Statista. Número de Casos Confirmados de Coronavirus (COVID-19) En América Latina y El Caribe Al 10 de Septiembre de 2021, Por País.

Velasquez-H., J. D. (2011). Acotación del error de modelos de redes neuronales aplicados al pronóstico de series de tiempo. *Revista UIS Ingenierías*, 10(1), 63–69.

Velásquez, J. D., & Franco, C. J. (2012). Pronóstico de series de tiempo con tendencia y ciclo estacional usando el modelo airline y redes neuronales artificiales. *Ingeniería y Ciencia*, 8(15), 171–189. <https://doi.org/10.17230/ingciencia.8.15.9>

