

ANÁLISIS COMPARATIVO DEL DESEMPEÑO DE MODELOS DE  
SERIES DE TIEMPO TRADICIONALES, REDES NEURONALES  
ARTIFICIALES Y MODELOS HÍBRIDOS PARA PRONOSTICAR LOS  
CASOS POR INFECCIONES RESPIRATORIAS AGUDAS (IRA) EN LA  
CIUDAD DE MONTERÍA

Iván Josué Moreno Santamaría

Fernando Arturo Varilla Mendoza

Trabajo presentado como requisito parcial para optar al título de

**Estadístico**

Director:

Myladis Cogollo Flórez, Ph.D.



UNIVERSIDAD DE CÓRDOBA

FACULTAD DE CIENCIAS BÁSICAS

DEPARTAMENTO DE MATEMÁTICAS Y ESTADÍSTICA

MONTERÍA

2023

# Resumen

En este trabajo investigativo, se ha llevado a cabo el modelado de los casos de IRA en la ciudad de Montería en el periodo 2012-2023 presentados por semana epidemiológica, mediante tres diferentes técnicas de pronóstico: Series de tiempo tradicionales, redes neuronales artificiales y modelos híbridos, con el objetivo de comparar sus desempeños y encontrar la metodología que mejor modela los datos. Para ello, se consideraron cinco horizontes de pronóstico: 52, 35, 17, 9 y 4 semanas epidemiológicas, donde el primer horizonte corresponde al periodo de la serie y los cuatro valores restantes corresponden a horizontes que se han sido sugeridos en la literatura para datos similares a los aquí analizados (véase por ejemplo Becerra *et al.* (2020), Cogollo *et al.* (2021))

Se encuentra que el desempeño de las tres técnicas de pronóstico consideradas en este estudio, mejora a medida que se incrementa la cantidad de datos para entrenar el modelo. Con respecto a los modelos tradicionales el más adecuado para modelar los casos de IRA es el modelo autorregresivo integrado de media móvil estacional (SARIMA) debido a la presencia de tendencia y estacionalidad. Por otra parte, se evidencia que el modelo de redes neuronales artificiales es el que presenta mejores resultados, en los distintos horizontes, en términos de la calidad del pronóstico. Adicionalmente, se demuestra que

el uso de una metodología híbrida no mejora la calidad del pronóstico de los casos de IRA hallados con el modelo autorregresivo integrado de media móvil (ARIMA) y SARIMA. Se demuestra que es posible emplear los datos históricos reportados de los casos de IRA para proporcionar información estadística verídica a las entidades de salud en la ciudad de Montería, que pueda apoyar la elaboración del organigrama de prevención y control de la enfermedad.

*Palabras Claves:* Infección respiratoria aguda, pronóstico, modelo ARIMA, modelo SARIMA, red neuronal artificial, modelo híbrido.

# Abstract

In this research work, the modeling of ARI cases in the city of Montería in the period 2012-2023 presented by epidemiological week has been carried out, using three different forecasting techniques: Traditional time series, artificial neural networks and models. hybrids, with the objective of comparing their performances and finding the methodology that best models the data. For this, five forecast horizons were considered: 52, 35, 17, 9 and 4 epidemiological weeks, where the first horizon corresponds to the period of the series and the four remaining values correspond to horizons that have been suggested in the literature for data. similar to those analyzed here (see for example Becerra *et al.* (2020), Cogollo *et al.* (2021))

It is found that the performance of the three forecasting techniques considered in this study improves as the amount of data to train the model increases. With respect to traditional models, the most suitable for modeling ARI cases is the seasonal autoregressive integrated moving average model (SARIMA) due to the presence of trend and seasonality. On the other hand, it is evident that the artificial neural network model is the one that presents the best results, in the different horizons, in terms of the quality of the forecast. Additionally, it is demonstrated that the use of a hybrid methodology does not improve the quality of the prognosis of ARI cases found with the autoregressive integrated moving average model (ARIMA) and SARIMA. It is demonstrated that it is possible

to use the historical data reported on ARI cases to provide true statistical information to health entities in the city of Montería, which can support the development of the disease prevention and control organization chart.

*Keywords:* Acute respiratory infection, forecast, ARIMA model, SARIMA model, artificial neural network, hybrid model.

# Agradecimientos

Primeramente, gracias a Dios por guiarnos en todo nuestro proceso de formación académica y darnos sabiduría en los momentos difíciles. También, darles gracias a nuestros padres Sixto Iván Moreno Cantellón, Blanca Cecilia Santamaría Espejo, Miriam Rosa Mendoza y Arturo Manuel Varilla por brindarnos todo su apoyo y motivarnos a seguir luchando por nuestros sueños.

A nuestra docente y asesora Myladis Cogollo Flórez por orientarnos con sus conocimientos y consejos, los cuales han sido de gran ayuda para nuestro proceso de formación.

A todas las personas que de una u otra manera fueron una fuente de apoyo incondicional y sincero en el transcurso de nuestros estudios, especialmente a Elis Loana Jimenez Peña, Carolina Velásquez Arteaga y Maurin Lopez.

# Índice

<b>Resumen</b>	<b>I</b>
<b>Agradecimientos</b>	<b>V</b>
<b>Introducción</b>	<b>1</b>
<b>1. Estado del arte</b>	<b>6</b>
1.1. Proceso de búsqueda . . . . .	7
1.2. Criterios de inclusión y exclusión . . . . .	8
1.3. Resultados y análisis de artículos seleccionados . . . . .	8
1.4. Modelado del IRA en Colombia . . . . .	11
<b>2. Materiales y Métodos</b>	<b>13</b>
2.1. Descripción de los datos . . . . .	13
2.2. Propuesta de modelado de los <i>casos de IRA</i> en la ciudad de Montería . . . . .	15
2.2.1. Modelado tradicional . . . . .	17
2.2.1.1. Estrategia de construcción del modelo tradicional . . . . .	18
2.2.2. Modelado basado en redes neuronales artificiales . . . . .	25
2.2.2.1. Estrategia de construcción de la red . . . . .	29

2.3. Metodología híbrida . . . . .	32
<b>3. Resultados</b>	<b>35</b>
3.1. Análisis preliminar de la serie de tiempo . . . . .	35
3.2. Modelado tradicional . . . . .	39
3.3. Modelado basado en redes neuronales artificiales . . . . .	47
3.4. Metodología híbrida . . . . .	54
3.5. Comparación del desempeño de los modelos obtenidos con los tres enfoques	56
3.5.1. Conclusiones . . . . .	65
3.5.2. Recomendaciones . . . . .	66
<b>Bibliografía</b>	<b>68</b>

## Índice de figuras

2.1. Metodología de modelado clásico . . . . .	19
2.2. Configuración general de una red neuronal tipo MLP. . . . .	26
2.3. Función de activación sigmoidea. . . . .	27
2.4. Función de activación tangente hiperbólica. . . . .	27
2.5. Función de activación de Unidad lineal rectificada. . . . .	28
2.6. Modelo híbrido Aditivo . . . . .	33
2.7. Modelo híbrido multiplicativo . . . . .	34
3.1. Casos de IRA en la ciudad de Montería, periodo 2012-2023 . . . . .	36
3.2. Serie limpia vs original . . . . .	36
3.3. Serie temporal del logaritmo de los <i>casos de IRA</i> en Montería, 2012-2023 . . .	37
3.4. Estacionalidad del logaritmo de los <i>casos de IRA</i> . . . . .	38
3.5. ACF Y PAC de la serie de tiempo . . . . .	39
3.6. Gráfico de Autocorrelación Extendida (EACF) para la elección manual de los modelos SARIMA para cada horizonte de pronóstico, 17, 9 y 4 semanas	42
3.7. Gráfico de función de autocorrelación y función de autocorrelación parcial de la serie para determinar el orden estacional en los modelos <i>SARIMA</i> . . .	43

3.8. Pronostico del Número de <i>casos de IRA</i> en la ciudad de Montería, periodo 2012-2023 para los diferentes horizontes de pronostico usando series de tiempo tradicionales . . . . .	46
3.9. Desempeño de los modelos MLP cuando $h = 52$ , variando el número de variables de entrada, capas ocultas, y las funciones de activación. . . . .	48
3.10. Desempeño de los modelos MLP cuando $h = 35$ , variando el número de variables de entrada, capas ocultas, y las funciones de activación. . . . .	49
3.11. Desempeño de los modelos MLP cuando $h = 17$ , variando el número de variables de entrada, capas ocultas, y las funciones de activación. . . . .	50
3.12. Desempeño de los modelos MLP cuando $h = 9$ , variando el número de variables de entrada, capas ocultas, y las funciones de activación. . . . .	51
3.13. Desempeño de los modelos MLP cuando $h = 4$ , variando el número de variables de entrada, capas ocultas, y las funciones de activación. . . . .	52
3.14. Resultado del pronostico del Número de <i>casos de IRA</i> en la ciudad de Montería, periodo 2012-2023 para los diferentes horizontes de pronóstico usando una <i>ANN</i> . . . . .	53
3.15. Resultado del pronostico del Número de <i>casos de IRA</i> en la ciudad de Montería, periodo 2012-2023 para los diferentes horizontes de pronostico usando modelos híbridos . . . . .	56
3.16. Comparación del valor real vs pronosticado para cada enfoque de modelado considerando un horizonte de 52 semanas . . . . .	58
3.17. Comparación del valor real vs pronosticado para cada enfoque de modelado considerando un horizonte de 35 semanas . . . . .	59

3.18. Comparación del valor real vs pronosticado para cada enfoque de modelado considerando un horizonte de 17 semanas . . . . .	60
3.19. Comparación del valor real vs pronosticado para cada enfoque de modelado considerando un horizonte de 9 semanas . . . . .	61
3.20. Comparación del valor real vs pronosticado para cada enfoque de modelado considerando un horizonte de 4 semanas . . . . .	62

## Índice de tablas

1.1. Descripción de los artículos seleccionados en la revisión bibliográfica. . . . .	10
2.1. Configuraciones de los datos de entrenamiento y prueba considerados para evaluar el desempeño de los modelos . . . . .	16
3.1. Número diferenciaciones necesarias para que el conjunto de entrenamiento sea estacionario . . . . .	40
3.2. Modelos de pronóstico candidatos . . . . .	44
3.3. <i>valor – p</i> asociado a las pruebas de hipótesis realizadas en el diagnóstico de los modelos . . . . .	45
3.4. Desempeño del mejor modelo <i>ANN</i> seleccionado para cada horizonte de pronóstico utilizando datos de prueba . . . . .	53
3.5. Configuración del mejor modelo híbrido aditivo seleccionado para cada horizonte de pronóstico. . . . .	54
3.6. Configuración del mejor modelo híbrido multiplicativo seleccionado para cada horizonte de pronóstico. . . . .	54
3.7. Función de costo para los datos de prueba del pronostico obtenido con el método híbrido aditivo . . . . .	55

3.8. Métricas de desempeño para comparar el rendimiento de los modelos tradicionales, redes neuronales y híbrido. . . . . 57

# Introducción

La infección respiratoria aguda (IRA) conforma un grupo de enfermedades que afectan el aparato respiratorio alto y bajo; las infecciones respiratorias del tracto respiratorio superior corresponden al resfriado común y a la gripe, los cuales son muy frecuentes pero rara vez son mortales; sin embargo, las infecciones respiratorias bajas son responsables de cuadros más graves, y son una de las principales causas de morbilidad y mortalidad (Instituto Nacional de Salud, 2022).

La IRA se caracteriza por la presencia de microorganismos, como virus y bacterias, que atacan el sistema respiratorio. Siendo los virus influenza A y B, y el virus sincitial respiratorio (VSR) los más importantes por la severidad de la enfermedad y por la alta transmisibilidad (Behar, 2003). La IRA comienza de forma repentina y dura un aproximado de 15 días, y está asociada a diferentes factores, como son los cambios ambientales, la desnutrición, el uso inadecuado de antibióticos, entre otros (Mansbach y Camargo, 2012).

Dentro de las consecuencias negativas que ocasionan los múltiples brotes de IRA se encuentra el hecho de que sea considerada, a nivel mundial, como la décima enfermedad causante de muertes (particularmente en los países en desarrollo) y la principal causa de morbilidad; así como, las pérdidas económicas (ausentismo laboral), y los altos costos que genera su tratamiento (Behar, 2003; Instituto Nacional de Salud, 2022). Estas consecuen-

cias también se ven reflejadas en la ciudad de Montería, donde la Secretaría de Salud y Seguridad Social de Montería (2022) muestra que durante el periodo 2005-2019, la IRA es la enfermedad transmisible con mayores tasas de mortalidad en los distintos grupos de edades, y la segunda causa de morbilidad específica en el grupo de las enfermedades transmisibles.

Si bien la IRA es una enfermedad que produce diferentes manifestaciones, puede ser prevenible y tratable (Mansbach y Camargo, 2012). Lo cual ha conllevado a que el análisis temporal, con fines de pronóstico, del número pacientes diagnosticados con IRA sea un tema vigente y de mucho interés. En la literatura especializada se destaca el uso de algunos modelos tradicionales de series de tiempo, tales como el autorregresivo integrado de medias móviles (*ARIMA*) y el autorregresivo estacional multiplicativo integrado de media móvil (*SARIMA*) (véase por ejemplo M. Peña (2014); Chambi y Conde (2021)); así como, modelos de machine learning, tales como las redes neuronales artificiales (*ANN*, por su sigla en inglés) (véase por ejemplo Jiménez *et al.* (2019)). Sin embargo, no se encuentra evidencia de que se haya propuesto un estudio para pronosticar el número de casos de pacientes con diagnóstico de IRA en la ciudad de Montería. En particular, hasta la fecha no se han realizado estudios empleando la información reportada en SIVIGILA (2023), considerando las tres expresiones de la IRA asociadas con la morbilidad.

Adicionalmente, la vigilancia rutinaria es la manera más eficaz que se tiene en el país de recopilar datos oportunos y de buena calidad; los cuales según el decreto 780 de 2016 (por medio del cual se expide el decreto único reglamentario del sector salud y protección social) deben ser analizados permanentemente por las secretarías municipales y locales de salud, en las diferentes expresiones de la IRA, para determinar, detectar y caracterizar el

comportamiento y tendencia de los casos, lo cual sería de gran utilidad para la secretaría de salud y seguridad social de la ciudad de Montería para establecer con anticipación el organigrama de prevención y control de la enfermedad (Instituto Nacional de Salud, 2022).

En este trabajo se propone un análisis comparativo del desempeño de los modelos de series de tiempo tradicionales, redes neuronales artificiales y los modelos híbridos para pronosticar, a corto alcance, los casos de la IRA en la ciudad de Montería, empleando la información disponible en (SIVIGILA, 2023); para las expresiones de la enfermedad relacionadas con la morbilidad (ESI-IRAG, IRAG inusitado e IRA en todos los grupos de edad), en el periodo 2012-2023. Esto con el fin de disponer de un modelo confiable que permita obtener el número de casos esperados por la IRA, y sea fundamental para establecer la vigilancia de la IRA en Montería, puesto que los valores pronosticados servirían para implementar medidas de prevención y control de manera oportuna. Más aun, la secretaria de salud y seguridad social de Montería, podría anticipar las acciones relacionadas con la promoción, prevención, la inmunización oportuna, la planificación de la atención y el tratamiento de la IRA.

El documento está organizado como sigue: En el Capítulo 1 se describe el proceso de revisión de la literatura y muestran los resultados obtenidos para cada tipo de enfoque. El Capítulo 2 contiene la descripción de los datos empleados y las metodologías de modelado propuestas bajo cada enfoque. Posteriormente, en el Capítulo 3 se presentan los resultados obtenidos bajo cada enfoque de modelado; así como, la comparación del desempeño de los mejores modelos identificados en cada enfoque. Finalmente, se presentan la discusión, conclusiones y recomendaciones.

# Objetivos

## Objetivo general

Comparar el desempeño de los modelos de series de tiempo tradicionales, redes neuronales artificiales y los modelos híbridos para pronosticar, a corto alcance, los casos de la IRA en la ciudad de Montería, empleando la información disponible en el Sistema de Vigilancia en Salud Pública (SIVIGILA, 2023) para las expresiones de la enfermedad relacionadas con la morbilidad (ESI-IRAG, IRAG inusitado e IRA en todos los grupos de edad), en el periodo 2012-2023.

## Objetivos específicos

- Identificar los modelos de series de tiempo tradicionales, las redes neuronales artificiales y los modelos híbridos propuestos en la literatura para pronosticar el número de casos de infecciones respiratorias agudas.
- Establecer, a partir de la información disponible en SIVIGILA (2023), la serie temporal del número de casos de la IRA para la ciudad de Montería, periodo 2012-2023;

totalizando los casos registrados de ESI-IRAG, IRAG inusitado e IRA en todos los grupos de edad, por semana epidemiológica.

- Estimar un modelo de series de tiempo tradicional apropiado para pronosticar el número de casos de la IRA en Montería, usando un enfoque de validación cruzada simple.
- Determinar la configuración de una red tipo perceptrón multipaca para pronosticar el número de casos de la IRA en Montería, usando un enfoque de validación cruzada simple.
- Establecer una metodología de modelado híbrido para pronosticar el número de casos de la IRA reportados en Montería, bajo un enfoque de validación cruzada simple.
- Analizar el desempeño de los modelos para pronosticar el número de casos de la IRA en Montería, considerando métricas de desempeño no probabilísticas y distintos horizontes de pronóstico de corto alcance.

# Capítulo 1

## Estado del arte

La infección respiratoria aguda (IRA) es un grupo de infecciones que atacan el aparato respiratorio, y es considerada una de las enfermedades más riesgosas y prevalentes en todo el mundo. Específicamente es una de las principales causas de morbilidad y mortalidad en niños menores a 5 años (Instituto Nacional de Salud, 2022). Clínicamente se caracteriza por tos, rinorrea, obstrucción nasal, odinofagia, otalgia, disfonía, respiración ruidosa y dificultad respiratoria. La IRA es causada por microorganismos virales, bacterianos y otros; siendo los patógenos más frecuentes los siguientes: Virus respiratorio sincitial (RSV, por su sigla en inglés), metapneumovirus humano, rinovirus/enterovirus, virus de la influenza, adenovirus, coronavirus, streptococcus pneumoniae y mycoplasma pneumoniae (González-Bandala *et al.*, 2020).

Por otra parte, en la literatura especializada se encuentra que el modelado del número de casos de IRA se ha abordado desde tres enfoques diferentes: modelos de series de tiempo tradicionales, modelos híbridos y modelos de aprendizaje profundo. Santangelo *et al.* (2023) realiza una revisión sistemática de la literatura de los modelos empleados para predecir la propagación y aparición de enfermedades respiratorias agudas durante

el periodo 2017-2022; encontrando que se han propuesto 74 estudios, de los cuales el 27 % emplean modelos de series de tiempo tradicionales, 71 % emplean redes neuronales artificiales y sólo el 2 % modelos híbridos. Perone (2021) muestra que en el año 2020 hubo un incremento significativo en la cantidad de estudios reportados para pronosticar los casos de enfermedades respiratorias agudas, debido a la aparición del COVID-19. En la revisión de la literatura, realizada por este autor se identifican 30 estudios reportados en dicho año, de los cuales el 67 % emplean modelos de series de tiempo tradicionales, el 23 % redes neuronales artificiales y un 10 % emplean modelos híbridos.

En este Capítulo se describe la metodología empleada para identificar los modelos de series de tiempo tradicionales, las redes neuronales artificiales y los modelos híbridos propuestos en la literatura, en los últimos tres años, para pronosticar el número de casos de infecciones respiratorias agudas. El enfoque metodológico es de tipo documental, en el que se recupera, actualiza, ordena y clasifica el material bibliográfico indexados en bases de datos académicas. Los resultados de esta búsqueda constituyen una actualización de las revisiones de la literatura realizadas por Perone (2021) y Santangelo *et al.* (2023). Así mismo, se establece el estado del arte del modelado con fines de pronóstico de los casos de la IRA en Colombia.

## **1.1. Proceso de búsqueda**

El proceso de búsqueda se llevó a cabo mediante una combinación de búsqueda manual y de bola de nieve de los artículos publicados en journals indexados, desde el año 2020 hasta septiembre del 2023, en las bases datos science direct, MDPI, IEEE y PubMed.

Se realiza una búsqueda avanzada bajo las siguientes configuraciones: TITLE(XX) AND ABSTRACT(XX) AND KEY WORDS(XX) AND DOCTYPE (review or ar) AND PUBYEAR AFT 2020, empleando las palabras claves que se muestran a continuación: "acute respiratory infections", "forecasting", "model", "predictions".

## **1.2. Criterios de inclusión y exclusión**

En este estudio de revisión fueron considerados aquellos artículos que plantearan un nuevo enfoque de modelado o aplicaran los modelos existentes para pronosticar los *casos de IRA*. Así mismo, fueron excluidos aquellos artículos cuyo objetivo sea la clasificación del estado/diagnóstico de la IRA, o modelar otras enfermedades infecciosas que no estén relacionados a los patógenos de dicha enfermedad. También se excluyeron aquellos estudios que analizan los casos de IRA empleando modelos dinámicos deterministas, por ejemplo modelo SIR (susceptibles-infectados-recuperados). A cada documento recuperado con el proceso de búsqueda, se le examina el título, el resumen y las palabras claves, de tal manera que se pueda determinar si el objetivo del estudio es consistente con el propósito de la revisión de la literatura. Una vez verificado el cumplimiento, se lleva a cabo el análisis del texto completo.

## **1.3. Resultados y análisis de artículos seleccionados**

La Tabla 1.1 contiene la información de los estudios seleccionados después de aplicar los criterios de inclusión y exclusión expuestos anteriormente. La primera columna

corresponde al identificador de los artículos dentro de este documento, la segunda columna muestra la fuente bibliográfica; posteriormente se indica el tipo de documento: artículo (AR) o revisión (RE); luego se muestra el tipo de modelo de pronóstico abordado por los investigadores: tradicional (TRAD), redes neuronales artificiales (ANN) e híbrido (HIB). La última columna contiene información sobre los datos empleados en cada estudio seleccionado.

Por otra parte, el diagnóstico de los modelos es una etapa esencial en las diferentes técnicas de modelado, puesto que el cumplimiento de los supuestos del modelo ayudan a garantizar que éste sea adecuado para los datos y proporcionan confianza para la toma de decisiones basadas en los pronósticos. Es por ello, que en los artículos seleccionados se examina si validan los supuestos de normalidad, homocedasticidad, independencia y estacionariedad de los errores. En la penúltima columna de la Tabla 1.1 se especifica, para cada estudio, si se verifican o no todos éstos supuestos.

Tabla 1.1: Descripción de los artículos seleccionados en la revisión bibliográfica.

Estudio	Referencias	Tipo		Modelo			Diagnóstico	Datos de aplicación
		AR	RE	TRAD	ANN	HIB		
E1	González-Bandala <i>et al.</i> (2020)	x			x		no	Número de casos de IRA
E2	Becerra <i>et al.</i> (2020)	x		x			no	Registro de admisiones de emergencia respiratoria
E3	Hassan (2021)	x		x	x		no	Número de casos semanales de IRA.
E4	Nsoesie <i>et al.</i> (2021)	x		x	x		no	Casos de enfermedades relacionadas al IRA
E5	Chambi y Conde (2021)	x		x			si	Número de casos de IRA .
E6	Cogollo <i>et al.</i> (2021)	x			x		si	casos de virus respiratorio sincitial (VRS)
E7	Perone (2021)	x		x	x	x	no	Casos de COVID-19
E8	ArunKumar <i>et al.</i> (2021)	x		x			no	Casos de COVID-19
E9	Assad <i>et al.</i> (2022)	x		x	x		no	Casos de COVID-19
E10	Yunseo <i>et al.</i> (2022)	x			x		no	Número de casos de enfermedades respiratorias
E11	Tsan <i>et al.</i> (2022)	x		x	x		no	Casos de influenza y enfermedades respiratorias
E12	Santangelo <i>et al.</i> (2023)		x		x	x	no	Brotos de enfermedades infecciosas
E13	Jin <i>et al.</i> (2023)	x				x	no	Casos de COVID-19
E14	Yang <i>et al.</i> (2023)	x			x		no	Casos de influenza y de IRA

A partir Tabla 1.1 se encuentra que, para pronosticar la cantidad de casos de IRA,

el 21 % de los estudios emplean sólo modelos de series de tiempo tradicionales, el 29 % usa sólo redes neuronales artificiales y el 7 % presentan exclusivamente aplicaciones de las metodologías híbridas. Además, se observa que es frecuente contrastar el desempeño de los tipos de modelos: el 29 % de los estudios consideran tanto modelos tradicionales de series temporales como de redes neuronales artificiales, el 7 % evalúa el desempeño tanto de modelos de redes neuronales como la metodología híbrida, y el 7 % realiza la comparación de los tres tipos de modelos. Los resultados obtenidos están acordes a los hallados por Santangelo *et al.* (2023) y Perone (2021): los modelos de series de tiempo tradicionales y redes neuronales son los métodos que más se emplean para modelar los casos de IRA y los patógenos relacionados a este; siendo las redes neuronales las más utilizadas.

Por otra parte, se encuentra que sólo el 14 % de los estudios seleccionados verifican todos los supuestos para el diagnóstico de los modelos. El supuesto que se valida en todos los estudios es la independencia de los errores. Mientras, que el 14 % de los estudios no valida algunos de los supuestos del modelo.

## **1.4. Modelado del IRA en Colombia**

Si bien el Instituto Nacional de Salud (2022) promueve la utilización de datos epidemiológicos a través del sistema nacional de vigilancia para el desarrollo de modelos predictivos, que permitan anticipar brotes y mejorar la planificación de recursos médicos, son pocos los estudios que se han propuesto para predecir los casos de IRA en Colombia. Jerónimo-Martínez *et al.* (2017) compara modelos de aprendizaje automatizado como el

sistema de notificación temprana de aberraciones (EARS, por su sigla en inglés) y series temporales ARIMA y SARIMA para predecir el número de casos de IRA reportados en la ciudad Bogotá, considerando los datos históricos por semana epidemiológica reportados desde el año 2009 hasta el año 2014; encuentran que el modelo ARIMA es el que presenta un mejor desempeño. Jiménez *et al.* (2019) implementa diferentes modelos, tales como regresión lineal múltiple, el método de operador de selección y contracción mínima absoluta (LASSO, por su sigla en inglés) y una red neuronal tipo perceptrón multicapa (MLP, por su sigla en inglés) para el pronosticar del número de casos de las infecciones respiratorias agudas registrados en Colombia, considerando los reportes semanales del periodo 2013 a 2018; concluyendo que el modelo de red neuronal tipo perceptrón multicapa era el más eficiente. ArunKumar *et al.* (2021) aplica modelos de series temporales para predecir el número de casos acumulados de COVID-19 reportados el Colombia y otros países de latinoamerica y Europa, para el período del 22 de enero 2020 al 24 de julio de 2020. Cogollo *et al.* (2021) emplea un modelo de redes neuronales artificiales para pronosticar los casos de virus respiratorio sincitial (VRS) recopilados durante el periodo 2005 a 2010 por semana epidemiológica en la ciudad de Bogotá. En dicho estudio se concluye que los modelos de redes neuronales tiene una buena precisión para pronosticar este tipo de enfermedades respiratorias.

# Capítulo 2

## Materiales y Métodos

En este Capítulo se presentan las particularidades metodológicas propuestas para pronosticar, a corto alcance, la cantidad de casos de IRA en la ciudad de Montería. Inicialmente, se presenta la descripción de los datos empleados, los cuales son reportados por SIVIGILA (2023) para el periodo 2012-2023. Posteriormente, se detalla el esquema de modelado de cada uno de los métodos considerados en este estudio: series de tiempo tradicionales, redes neuronales artificiales y los modelos híbridos los cuales fueron modelados utilizando el software RStudio (2021).

### 2.1. Descripción de los datos

Se consideran la cantidad de casos de IRA reportados por SIVIGILA (2023) para la ciudad de Montería, Colombia, por semana epidemiológica, desde el año 2012 hasta mayo de 2023. Para la extracción de la información se descargaron 12 bases de datos correspondientes al periodo 2012-2023 (una base por cada año), en donde se selecciona solo la

información de la ciudad de Montería y se crea una única base de datos. Esta base de datos contiene desde la primera semana epidemiológica del 2012 hasta la semana 20 del 2023, los siguientes indicadores asociados al IRA:

**ESI-IRAG:** Número de casos confirmados de enfermedad similar a la influenza (ESI) e infección respiratoria aguda grave (IRAG).

**IRAG inusitado:** Número de casos confirmados que cumplan con las siguientes condiciones: Pacientes con antecedentes de fiebre y tos, pacientes de 5 a 65 años previamente sano con IRAG con antecedente de fiebre y tos que requiera manejo hospitalario con necesidad de vasopresores y/o apoyo ventilatorio, conglomerados de IRAG (dos o más casos de IRAG) en entornos familiares, lugares de trabajo, lugares con población confinada.

**Morbilidad por IRA:** Número de casos de hospitalizados en UCI, hospitalización general, consulta externa, urgencias y muertes debido al IRA.

Debido a que los años 2012 y 2020 tienen 53 semanas epidemiológicas y en el resto de años sólo 52 semanas, se acoge la sugerencia de González-Bandala *et al.* (2020); quienes establecen que en los años en donde se tenga una semana adicional es necesario descartar ésta para asegurar un tamaño constante de 52 semanas; y para ello se debe agregar la información de la semana 53 a la 52.

Una vez garantizada la uniformidad en el número de semanas epidemiológicas por año, se procede a calcular la variable respuesta, denominada *casos de IRA*, la cual corresponde a la suma de los indicadores ESI-IRAG, IRAG inusitado y morbilidad por IRA, en

todos los grupos de edad, por semana epidemiológica. La base de datos resultante está conformada por 592 registros de *casos de IRA*.

## **2.2. Propuesta de modelado de los *casos de IRA* en la ciudad de Montería**

Los *casos de IRA* de la ciudad de Montería en el periodo 2012-2023, son modelados bajo tres enfoques: series de tiempo tradicionales, redes neuronales artificiales y los modelos híbridos, con el fin de identificar cuál de ellos tiene un mejor desempeño para pronosticar a corto alcance.

Previo al modelado de los *casos de IRA*, se realiza el análisis preliminar de la serie de tiempo descrita en la sección anterior. Este análisis consiste en: (i) realizar la limpieza de la serie por medio de la función *tsclean* de R, la cual emplea el suavizamiento de Friedman para series no estacionales, y una descomposición estacional (STL) robusta para series estacionales, con el fin de que la estimación de los valores faltantes y los reemplazos de valores atípicos reduzca la variabilidad de los datos; (ii) analizar las componentes de la serie (es decir, identificar la presencia de tendencia, estacionalidad y patrones cíclicos), y (iii) verificar la estacionariedad por medio de la prueba Dickey-Fuller (ADF), la cual es apropiada para detectar la presencia estacionariedad cuando la variabilidad de los datos es alta (Serikov *et al.*, 2021).

Una vez realizado el análisis preliminar de la serie, se procede a emplear la técnica de validación cruzada simple, la cual consiste en dividir el total de datos disponibles en un

conjunto de entrenamiento y un conjunto de prueba. El conjunto de entrenamiento se usa para entrenar y estimar el modelo, y el conjunto de prueba para determinar el rendimiento del modelo. De acuerdo a lo mencionado por Hyndman y Athanasopoulos (2018), se considera que el horizonte de pronóstico es tan grande como el tamaño del conjunto de prueba seleccionado. En este estudio se consideran cinco particiones del conjunto de datos, es decir, cinco configuraciones de datos de entrenamiento- datos de prueba; variando desde un mínimo de 4 semanas epidemiológicas ( equivalentes a un mes) a pronosticar hasta un máximo de 52 semanas ( 12 meses), como se muestra en la Tabla 2.1.

Tabla 2.1: Configuraciones de los datos de entrenamiento y prueba considerados para evaluar el desempeño de los modelos

Nº configuración	Datos de entrenamiento-prueba	Horizonte	Nº Meses <sup>a</sup>
1	540-52	52	12
2	557-35	35	8
3	575-17	17	4
4	583-9	9	2
5	588-4	4	1

<sup>a</sup>El número de meses corresponde a la cantidad de meses que equivale el número de semanas epidemiológicas que se pronosticaran ( es decir, el horizonte).

A continuación se describe la metodología de modelado empleada en cada uno de los tres enfoques.

### 2.2.1. Modelado tradicional

Se emplea el modelo autorregresivo integrado de medias móviles de orden  $p, d, q \in \mathbf{Z}^+$ , denotado  $ARIMA(p, d, q)$ , el cual se utiliza para analizar series que no presentan patrones estacionarios, y es definido como:

$$\phi(B)(1 - B)^d y_t = \theta(B)a_t \quad (2.1)$$

donde  $p$  corresponde al orden de la parte autorregresiva,  $d$  es el número de veces que se deben calcular las diferencias entre las observaciones consecutivas de la serie hasta obtener una serie diferenciada estacionaria,  $q$  es el orden de la parte de media móvil, y  $\nabla^d y_t = (1 - B)^d y_t$  es el operador de diferencias ordinarias (Box *et al.*, 2015).

Si adicionalmente, la serie temporal presenta patrones estacionales cada  $S$  periodos, se utiliza el modelo autorregresivo integrado de medias móviles estacional, también llamado  $SARIMA$  y denotado como  $SARIMA(p, d, q)(P, D, Q)_S$ , donde  $p$  es el orden de la parte autorregresiva,  $d$  es el número de diferencias ordinarias necesarias para que la serie sea estacionaria,  $q$  es el orden de la parte de media móvil,  $P$  corresponde al orden autorregresivo estacional,  $D$  es el orden de diferenciación estacional,  $Q$  es el orden de la de media móvil estacional y  $S$  representa el período en el que se presenta la estacionalidad. Matemáticamente el modelo  $SARIMA$  se define como (Hyndman y Athanasopoulos, 2018):

$$\phi_p(B)\Phi_p(B^S)(1 - B)^d(1 - B^S)^D Y_t = \theta_q(B)\Theta_Q(B^S)a_t, \quad (2.2)$$

donde

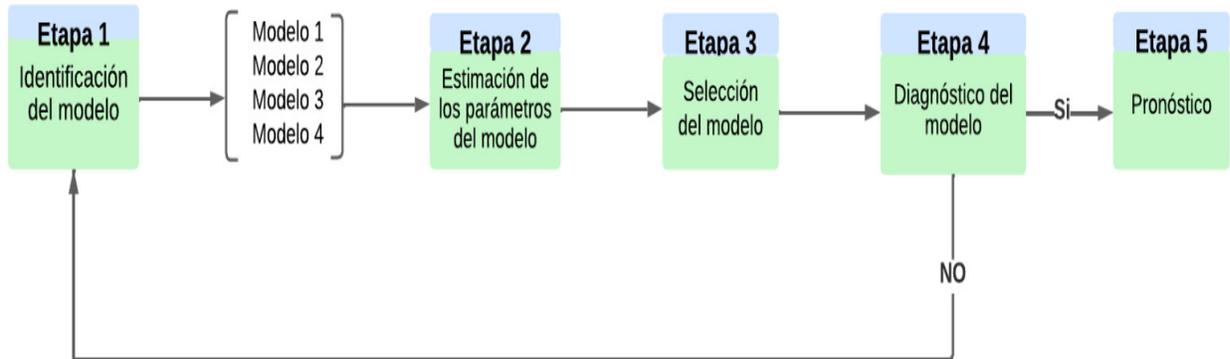
- $B$  es el operador de rezagos y  $a_t$  es un proceso de ruido blanco.
- $\phi_p(B) = 1 - \phi_1(B) - \dots - \phi_p(B^p)$  es el operador AR regular de orden  $p$ .

- $\Phi_P(B^S) = 1 - \Phi_S B^S - \phi_{2S} B^{2S} - \dots - \Phi_{pS} B^{pS}$  es el operador AR estacional de orden  $P$ .
- $\nabla^d = (1 - B)^d$  representa la diferencia regular.
- $\nabla_s^D = (1 - B^s)^D$  representa la diferencia estacional ( $D = 1$  si existe estacionalidad, y  $D = 0$  en caso contrario).
- $\theta_q(B) = 1 + \theta_1(B) + \dots + \theta_q(B^q)$  es el operador MA estacional de orden  $q$ .
- $\Theta_Q(B^S) = 1 + \Theta_S B^S + \Theta_{2S} B^{2S} + \dots + \Theta_{QS} B^{QS}$  es el operador MA estacional de orden  $Q$ .

### 2.2.1.1. Estrategia de construcción del modelo tradicional

La selección del mejor modelo de series de tiempo tradicional, para cada una de las cinco configuraciones mostradas en la Tabla 2.1, se hizo mediante una estrategia de modelado que fusiona la metodología de Box-Jenkins (Jenkins *et al.*, 2011) con la técnica de validación cruzada, como se muestra en la Figura 2.1. Específicamente, esta consta de cinco etapas descritas a continuación.

Figura 2.1: Metodología de modelado clásico



Fuente: Elaboración propia.

### Etapa 1: Identificación del modelo.

Conforme a los resultados del análisis preliminar de la serie, se procede a seleccionar el modelo tradicional más adecuado, con sus respectivos ordenes. Inicialmente se considera el resultado obtenido en la prueba de estacionariedad, en caso de que la serie no sea estacionaria se procede a identificar el valor del orden  $d$  mediante la función  $ndiffs$  de R, la cual determina el número de diferenciaciones requeridas para que la serie sea estacionaria. Si adicionalmente, en el análisis preliminar no se detecta la presencia de patrones estacionales en la serie temporal, entonces el modelo candidato es un  $ARIMA(p, d, q)$ . Los valores iniciales de los ordenes  $p$  y  $q$  de dicho modelo se determinan a partir de los resultados obtenidos con la función *Autoarima* del paquete *forecast* de R; los cuales son modificados gradualmente conforme a lo sugerido por Hyndman y Athanasopoulos (2018).

Por otra parte, si en el análisis preliminar se detecta que hay indicios de estaciona-

lidad, el modelo candidato es un  $SARIMA(p, d, q)(P, D, Q)_S$ , cuyos valores  $p$  y  $q$  de la parte regular se identifican utilizando la función de autocorrelación extendida (EACF, por su sigla en inglés) como lo plantean Tsay y Tiao (1984). Los ordenes de la parte estacional  $(P, D, Q)_S$  son determinados como sigue:

- El valor de  $D$  se elige con la función *nsdiffs*, la cual indica el número de diferenciaciones estacionales necesarias para volver la serie estacionaria.
- El valor de  $S$  se determina identificando el primer rezago estacional significativo al analizar la función de autocorrelación simple (ACF, por su sigla en inglés).
- Los valores de  $P$  y  $Q$  se identifican utilizando la función de autocorrelación parcial (PACF, por su sigla en inglés). Si al examinar la PACF no se encuentra que los rezagos estacionales decaen exponencialmente hacia cero, entonces se considera la incorporación de términos de promedios móviles estacionales ( $S(MA)$ ). En caso de que se encuentren retardos estacionales o no estacionales, que resulten significativos, se incluyen términos autoregresivos estacionales ( $S(AR)$ ) en el modelo; de modo que los valores posibles del orden autoregresivo estacional dependerá del número de retardos que superen el umbral de significancia.

Finalmente como resultado de este proceso, se eligen cuatro modelos candidatos para cada horizonte de pronóstico, donde tres son ajustados manualmente teniendo en cuenta las consideraciones anteriores y uno es obtenido con la función *Autoarima*.

## Etapa 2: Estimación de los parámetros del modelo.

Una vez identificados los cuatro modelos con sus respectivos ordenes, para cada uno de los horizontes de pronóstico, se procede a realizar la estimación de los parámetros de dichos modelos usando el método de máxima verosimilitud, disponible en la función *Arima* de R.

Dada una serie de tiempo  $y_1, \dots, y_n$ , la función de verosimilitud para un modelo *ARIMA* está dada por:

$$L(\Theta; y_1 \dots, y_n) = f(y_1 \dots, y_n; \Theta)$$

donde  $\Theta$  representa el vector de parámetros a estimar, mientras que  $f$  es la función de densidad de probabilidad conjunta de los datos observados y el parámetro  $\Theta$ . En este caso,  $L$  cuantifica qué tan bien un modelo estadístico específico explica los datos observados para los parámetros estimados (Ospina *et al.*, 2023).

Si se asume que los errores en cada momento siguen una distribución normal y son independientes entre sí a largo del tiempo, entonces para una muestra de tamaño  $n$ , la función de verosimilitud se expresa como:

$$L(\phi, \theta, \sigma^2) = \prod_{t=1}^n \frac{1}{\sqrt{2\phi\sigma}} \exp\left(\frac{-\epsilon_t^2}{2\sigma^2}\right) \quad (2.3)$$

donde  $\epsilon_1, \epsilon_2, \dots, \epsilon_n$  denotan los errores del modelo.

La estimación del vector de parámetros  $\Theta$  se elige de manera que se maximice la función de verosimilitud de los datos observados dada en la Ecuación (2.3), considerando valores iniciales aleatorios en el proceso de optimización.

### **Etapas 3: Selección del modelo.**

En esta etapa se procede a seleccionar el modelo ajustado que mejor explica el comportamiento de la serie temporal, para cada configuración del horizonte de pronóstico. Se acude a los criterios de información sugeridos por D. Peña (2005), y se selecciona aquel modelo cuyo criterio arroje el valor más pequeño en comparación a los demás. Los criterios considerados se presentan a continuación:

- Criterio de Información de Akaike (AIC), definido por:

$$AIC = E(-2L(\beta)) = T \ln(\hat{\sigma}_{MV}^2) + 2k \quad (2.4)$$

donde  $T$  es el tamaño muestral utilizado para estimar el modelo,  $\hat{\sigma}_{MV}^2$  es el estimador de máxima verosimilitud de la varianza de las innovaciones y  $k$  el número de parámetros estimados. Este criterio tiende a seleccionar modelos más complejos, pero puede sobrestimar los parámetros cuando se tienen conjuntos de datos pequeños.

- Criterio de Información Bayesiana (BIC), el cual desde un enfoque Bayesiano maximiza la probabilidad a posteriori del modelo. Este criterio viene dado por:

$$BIC = T \ln(\hat{\sigma}_{MV}^2) + k \ln T \quad (2.5)$$

donde,  $T$ ,  $\hat{\sigma}_{MV}^2$  y  $k$  se definen como en la Ecuación (2.4). Una de las ventajas del BIC es que funciona mejor para conjuntos de datos grandes, ya que penaliza modelos complejos a medida que se introducen más parámetros para evitar el sobreajuste.

### **Etapas 4: Diagnóstico del modelo.**

Para garantizar la confiabilidad en los pronósticos en los modelos seleccionados para cada horizonte, es de vital importancia verificar que los errores constituyan un proceso de ruido blanco. Para ello se emplean los residuales de los modelos para verificar la estacionariedad por medio de la prueba de Dickey-Fuller (ADF) y la función de autocorrelación simple (ACF). Además, se verifica la no autocorrelación serial de los errores, por medio de la prueba de Ljung-Box, la cual es una prueba estadística que examina si un grupo cualquiera de coeficientes de autocorrelación de una serie de tiempo son diferentes de cero y emplea el estadístico de prueba dado por (Chambi y Conde, 2021):

$$Q_h = T(T + 2) \sum_{j=1}^h \frac{\hat{\rho}_j^2}{T - j}, \quad (2.6)$$

donde  $T$  es el tamaño de la muestra  $\hat{\rho}_j^2$  es la autocorrelación de la muestra en el retraso  $j$  y  $h$  es el número de retardos que se están probando.

Por otra parte, la prueba de efecto ARCH es empleada para verificar la homocedasticidad del error, es decir, que la varianza del error sea constante y finita; y se utiliza una prueba  $t$  para verificar que los errores estén centrados en cero.

Finalmente, si bien el supuesto de normalidad de los errores puede ser validado por medio de métodos inferenciales (tales como, las pruebas Anderson-Darling y Jarque-Bera), Knief y Forstmeier (2021) demuestran que los modelos lineales de series temporales son robustos a la violación del supuesto de normalidad, siempre y cuando los valores atípicos se manejen correctamente.

#### **Etapas 5: Pronóstico.**

En esta etapa final, el desempeño del mejor modelo seleccionado es evaluado em-

pleando los datos de prueba. Se determinan los pronósticos de dichos datos, empleando el modelo ajustado con los datos de entrenamiento, y posteriormente, se calculan métricas de desempeño; las cuales, adicionalmente, son utilizadas para comparar el desempeño de los tres enfoques de modelado considerados, en cada una de las configuraciones de validación cruzada. Específicamente, las métricas de desempeño consideradas son:

**Raíz del Error Estándar Medio (RMSE)**

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_t - \hat{y}_{t+h})^2} \quad (2.7)$$

**Error absoluto medio (MAE)**

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_t - \hat{y}_{t+h}| \quad (2.8)$$

**Error absoluto medio porcentual (MAPE)**

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_t - \hat{y}_{t+h}}{y_t} \right| \quad (2.9)$$

donde  $y_t$  es el valor real,  $\hat{y}_{t+h}$  el valor pronosticado,  $N$  el tamaño de la muestra de la serie temporal,  $t$  el periodo de tiempo y  $h$  el horizonte de pronostico. Las métricas  $MSE$ ,  $RMSE$  y  $MAE$  no son invariantes a la escala de los errores, es decir, su valor está influenciado por cómo se miden los errores. Sin embargo éstas comparten la característica de penalizar los errores más grandes. Por otro lado, el  $MAPE$  es invariante de la escala pero tiene la desventaja de ser infinita si  $y_t = 0$  para cualquier  $t$ , y para valores extremos  $y_t$  cercanos a 0 (Ballesteros y Cogollo, 2023).

### 2.2.2. Modelado basado en redes neuronales artificiales

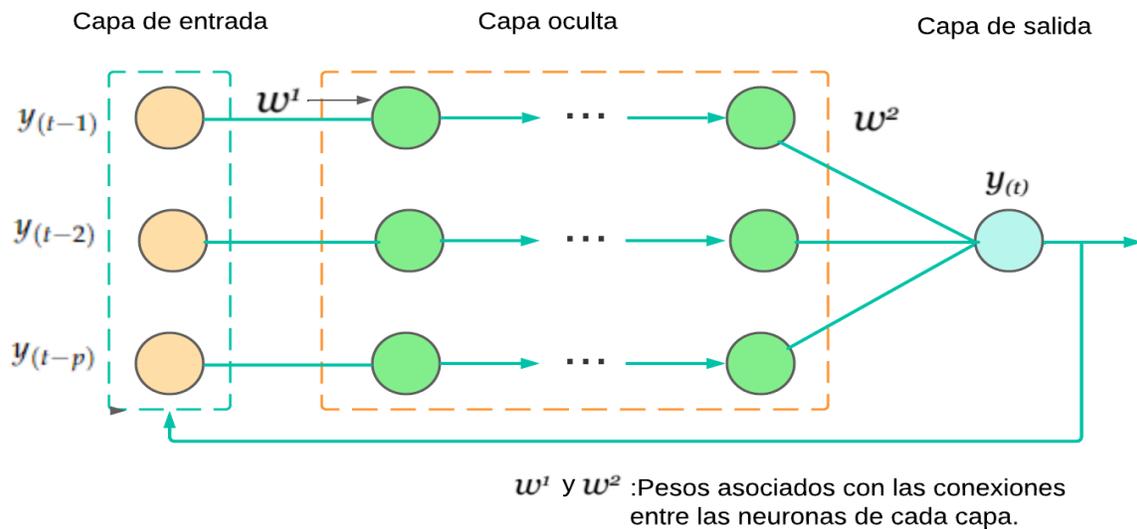
Se considera el modelado de los *casos de IRA* en la ciudad de Montería, utilizando la técnica no lineal de redes neuronales artificiales. Se considera un modelo Perceptrón Multicapa (MLP, por su sigla en inglés), que se compone de una capa con  $N$  neuronas (o nodos) de entrada, una capa con  $M$  neuronas de salida, y una o más capas ocultas. Este tipo de red se caracteriza porque las conexiones entre neuronas siempre se alimentan hacia adelante, es decir, las conexiones se alimentan de las neuronas en una determinada capa hacia las neuronas de la siguiente capa (Montano *et al.*, 2011; Hajirahimi y Khashei, 2019).

Cuando se modela una serie de tiempo usando una red neuronal artificial (*ANN*, por su sigla en inglés), se utiliza un cierto número de términos rezagados de la serie como entrada (análogo a como se usan valores rezagados en un modelo autoregresivo lineal) y los pronósticos como salida. La Figura 2.2 muestra la estructura general de un modelo MLP cuando es empleado para pronosticar series temporales.

En esta investigación se emplea un modelo MLP con una sola capa oculta, dado que se ha demostrado que para la mayoría de los problemas de pronóstico usando modelos *ANN*, basta con tener una sola capa oculta con  $L$  neuronas ( véase Montano *et al.* (2011); Cogollo *et al.* (2021)); de modo que el modelo resultante es equivalente a la versión no lineal del modelo autoregresivo propuesto por Hyndman y Athanasopoulos (2018). La configuración del modelo MLP considerado es la siguiente (Hajirahimi y Khashei, 2019):

- **Capa de entrada:** Los valores rezagados de los datos reales  $y_{t-1}, \dots, y_{tp}$  son considerados como las entradas del modelo MLP. En este sentido, la capa de entrada está

Figura 2.2: Configuración general de una red neuronal tipo MLP.



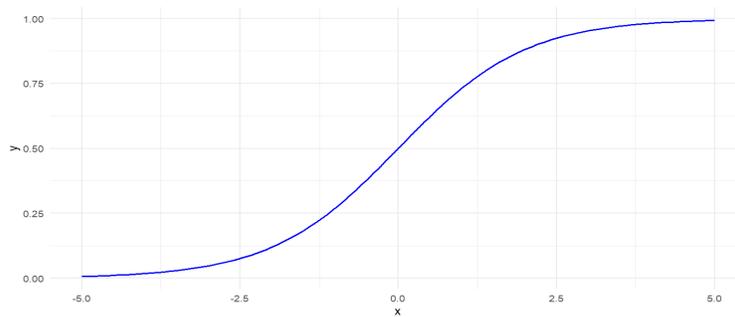
Fuente: Elaboración propia basado en Alsuwaylimi (2023).

compuesta de  $p$  nodos.

- **Capa oculta:** La capa oculta reproduce una interfaz entre las capas de entrada y salida. En este paso, se debe determinar la función no lineal  $g((y_{t-1}, \dots, y_{tp}))$ , denominada función de activación, que transforma la señal de entrada de una neurona en una sola señal de salida para ser transmitida en la red. Las funciones de activación se utilizan para introducir no linealidad, lo que permite que los modelos de redes neuronales aprendan patrones complejos. Existen varias tipos de función de activación, entre las que se destacan:

*Función sigmoidea:* Se utiliza en la capa de salida al realizar predicciones binarias con valores de salida entre 0 a 1 (véase la Figura 2.3).

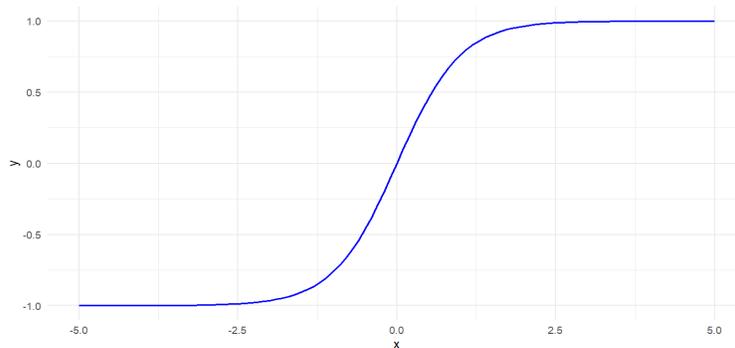
Figura 2.3: Función de activación sigmoidea.



Fuente: Elaboración propia.

*Tangente hiperbólica*: Se utiliza en la capa de salida al realizar predicciones binarias con valores de salida entre  $-1$  a  $1$  (véase la Figura 2.4).

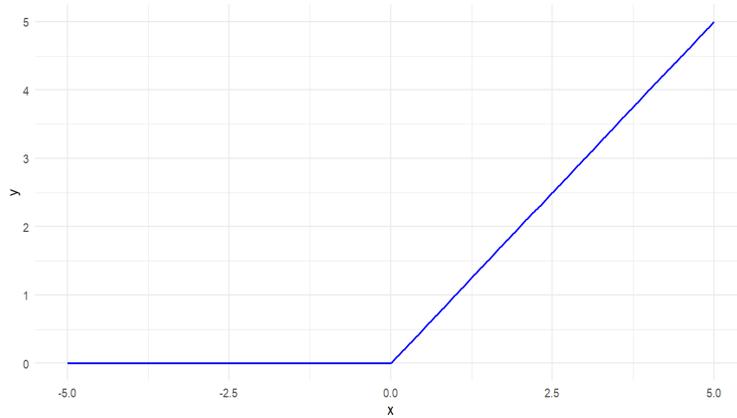
Figura 2.4: Función de activación tangente hiperbólica.



Fuente: Elaboración propia.

*Unidad lineal rectificadora*: La unidad lineal rectificadora (ReLU, por su sigla en inglés) se utiliza en las capas ocultas de la red neuronal cuyos valores negativos los vuelve cero en la salida. Las entradas con valores positivos no sufren modificación alguna en la salida (véase la Figura 2.5).

Figura 2.5: Función de activación de Unidad lineal rectificada.



Fuente: Elaboración propia.

- Capa de salida :** La capa de salida de las redes neuronales contiene un único nodo correspondiente al pronóstico de un paso hacia adelante. Generalmente, se usa una función de activación lineal para la capa de salida; de modo que la formulación matemática del modelo MLP, está dada por:

$$y_t = \omega_0 + \sum_{j=1}^q \omega_j \cdot g \left[ \omega_{0,j} + \sum_{i=1}^p \omega_{i,j} y_{t-i} \right] + \varepsilon_t, \quad (2.10)$$

donde  $\omega_{i,j}$  ( $i = 0, 1, \dots, p, j = 1, 2, \dots, q$ ) y  $w_l$  ( $l = 0, 1, 2, \dots, q$ ) son los pesos de conexión, y  $\varepsilon_t$  es el término de ruido o error. La estimación del vector parámetros  $W = (\omega_{0,1}, \dots, \omega_{p,q}, w_0, \dots, w_q)$  es obtenida minimizando iterativamente una función de costo o pérdida  $L_n(W)$  (Montano *et al.*, 2011):

$$\hat{W} = \arg, \min \{L_n(W) : W \in \Omega\}, \quad \Omega \subset \mathbf{R}^r \quad (2.11)$$

donde  $L_n(W)$  es, por ejemplo, el error cuadrático medio:

$$L_n(W) = MSE = \frac{1}{N} \sum_{i=1}^N (y_t - \hat{y}_{t+h})^2 \quad (2.12)$$

El proceso iterativo se realiza por medio de algoritmos de optimización, que como su nombre lo indica, se encargan de optimizar la red neuronal y modificar los pesos de la red conforme pasan los ciclos hasta encontrar el mínimo global de la función de costo (2.12). Los algoritmos de optimización más comunes son el gradiente descendiente y el backpropagation. El gradiente descendiente ajusta los pesos en la dirección en la que la función de pérdida disminuye más rápido, es decir, si una derivada parcial es grande y positiva para un peso, al aumentar dicho peso se reducirá el error. En caso de ser negativa, se disminuye el peso. El backpropagation se encarga de calcular las derivadas (o gradientes) de los parámetros del modelo para ajustar los pesos de la red de manera que minimicen la función de costo.

#### **2.2.2.1. Estrategia de construcción de la red**

Los *casos de IRA* de la ciudad de Montería fueron modelados mediante una red neuronal tipo MLP, siguiendo los siguientes pasos:

##### **Paso 1. Selección de la arquitectura de la red:**

Inicialmente, para controlar de forma directa la estructura, configuración y rendimiento de la red neuronal, se establecen los valores de los siguientes hiperparámetros (Kelleher, 2019):

**Tasa de aprendizaje:** Permite regular la rapidez o lentitud con que aprende una red y como se adapta frente a nuevos patrones de entrada. El valor de la tasa de aprendizaje es positivo y está comprendido entre 0 y 1. Si la tasa de aprendizaje es pequeña, puede llevar mucho tiempo para el proceso de aprendizaje

pero llega a converger sin problemas; mientras que, una tasa de aprendizaje demasiado grande, acelera el proceso de aprendizaje pero es posible que no tenga convergencia. De acuerdo a esto, para elegir el valor de la tasa de aprendizaje se toma un valor pequeño entre 0,01 y 0,1. En esta investigación se considera una tasa de aprendizaje de  $learnrate = 0,05$ , como lo consideran Kelleher (2019).

**Número de épocas:** Corresponde al número de veces que todo el conjunto de entrenamiento pasa por la red neuronal; de modo que sirve para determinar las mejores ponderaciones y sesgos de entrada para obtener un resultado con mayor precisión. El valor preferible se obtiene al aumentar el número de épocas hasta que la precisión de la validación empieza a disminuir incluso cuando la precisión del entrenamiento esté aumentando (sobreajuste). Cogollo *et al.* (2021) encuentra que un valor adecuado es  $epochs = 1000$ .

Una vez fijados los valores de los hiperparámetros, se procede a seleccionar la cantidad de rezagos  $p$  a ser considerados como variables de entradas, el número de nodos o neuronas (*size*) en la capa oculta, y la función de activación en la capa oculta:

- La selección del número de rezagos  $p$  se hizo aplicando la estrategia propuesta por Yu *et al.* (2021): con la función *nnetar* de R, se obtiene un valor inicial  $p$  empleando el criterio de información *AIC*. El valor hallado se asocia al número máximo de rezagos  $p_{max}$  a considerar; de modo que se entrenan varias redes MLP variando el número de rezagos de entrada  $p \in \{1, 2, \dots, p_{max}\}$ .

- Para determinar el número de neuronas (*size*) en la capa oculta, se realiza un proceso iterativo de prueba y error. Para ello se comienza con un valor inicial pequeño y luego se aumentan gradualmente. como lo indica Hyndman y Athanasopoulos (2018).
- Se consideran diferentes funciones de activación: sigmoidea, tangente hiperbólica, y unidad lineal rectificadas, y elige como mejor función aquella que proporcione el mejor rendimiento a la hora de ser ajustar las redes MLP, conforme a lo planteado por Kelleher (2019).

Al finalizar este paso, se construye una malla que contiene todas las combinaciones posibles de los valores  $p$ ,  $size$  y las tres funciones de activación consideradas. Para cada combinación se ajusta una red MLP como se describe en el siguiente paso.

### **Paso 2. Ajuste del modelo MLP:**

Para los cinco escenarios de validación cruzada considerados en esta investigación (véase la Tabla 2.1), se ajustaron las redes MLP considerando cada combinación establecida en el paso anterior. Los parámetros de la red se estimaron usando la función *nnetar* de *R*, la cual inicializa los pesos de la red de forma aleatoria, luego ajusta los pesos de manera iterativa mediante algoritmos backpropagation y algoritmos de optimización basados en gradientes.

### **Paso 3. Selección del mejor modelo:**

La estrategia a utilizar para seleccionar el mejor modelo se basa en en la *búsqueda por cuadrícula* o también conocida como *malla*. Esta estrategia tiene como objetivo

considerar diferentes valores de los parámetros y encontrar la mejor combinación de estos en términos de la función de costo definida en (2.12), es decir, se toma para cada configuración aquella combinación que proporcione el menor *MSE* en los datos de prueba. Adicionalmente, una vez seleccionado el mejor modelo para cada horizonte, se calculan las métricas de desempeño descritas en la Subsección 2.2.1.1, tanto para el conjunto de entrenamiento como de prueba.

## 2.3. Metodología híbrida

Los métodos híbridos integran las ventajas de los modelos *ARIMA* y *ANN*, en el modelado de comportamientos lineales y no lineales en un conjunto de datos Wang *et al.* (2013). Para el modelado de *casos de IRA* se contrastan dos enfoques: modelo **aditivo** propuesto por Hajirahimi y Khashei (2019) vs **multiplicativo** propuestos por Alsuwaylimi (2023), los cuales suponen que la serie de tiempo es la suma y el producto de una parte lineal y una no lineal como se muestra en las ecuaciones (2.13) y (2.14), respectivamente:

$$y_t = L_t + N_t \quad (2.13)$$

$$y_t = L_t * N_t \quad (2.14)$$

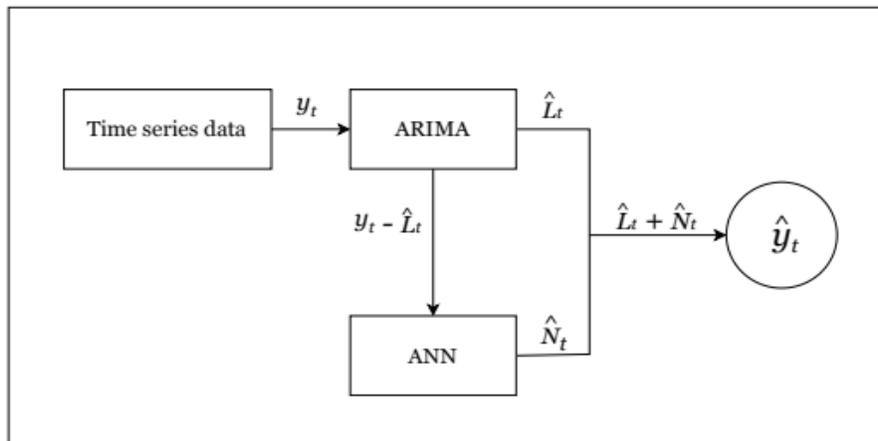
donde  $L_t$  y  $N_t$  representan las componentes lineal y no lineal respectivamente.

Inicialmente para desarrollar el modelo híbrido, se extrae la componente lineal  $L_t$  de la serie de tiempo utilizando el mejor modelo *ARIMA* seleccionado en la parte tradicional. Se obtienen los pronósticos de los datos de prueba  $\hat{L}_t$  empleando el modelo ajustado. La componente no lineal  $N_t$  que será empleada como entrada en la red neuronal, depende

del tipo de modelo híbrido. En caso de usar un método aditivo,  $N_t$  corresponde a los errores del modelo *ARIMA* (véase la Figura 2.6), los cuales vienen dados por:

$$e_t = y_t - \hat{L}_t \quad (2.15)$$

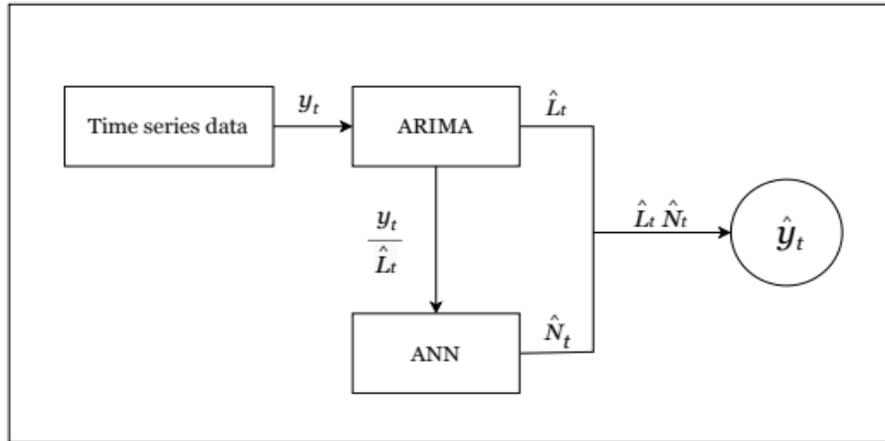
Figura 2.6: Modelo híbrido Aditivo



Fuente: (Hajirahimi y Khashei, 2019).

Por otra parte, si el método es multiplicativo entonces la componente no lineal  $N_t$  corresponde al cociente entre los datos de entrenamiento del modelo *ARIMA* y el pronóstico  $\hat{L}_t$  (véase la Figura 2.7).

Figura 2.7: Modelo híbrido multiplicativo



Fuente: (Alsuwaylimi, 2023).

En los dos métodos la componente no lineal es modelada mediante una red MLP, bajo un proceso de construcción análogo al descrito anteriormente; es decir, el esquema de selección de la malla propuesto en las ANN. La salida de la red son los pronósticos  $\hat{N}_t$ , los cuales son usados para calcular el resultado de los modelos híbridos.

# Capítulo 3

## Resultados

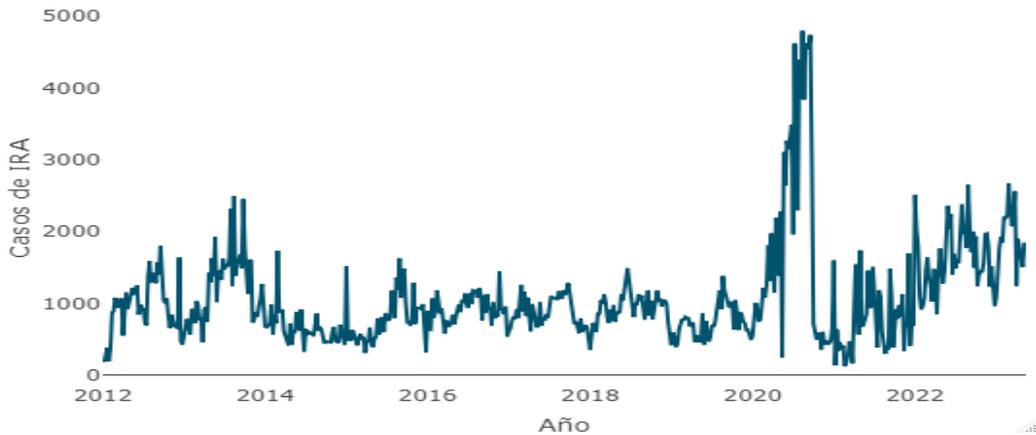
Este Capítulo contiene los resultados obtenidos después de aplicar las metodologías propuestas para modelar el número de *casos de IRA* en la ciudad de Montería, bajo tres enfoques: Series de tiempo tradicionales, redes neuronales artificiales y modelos híbridos; considerando cinco horizontes de pronóstico. Inicialmente, se muestran los resultados del análisis preliminar de la serie de tiempo. Posteriormente, se presentan los resultados obtenidos bajo cada enfoque, y finalmente, se comparan los desempeños de los modelos seleccionados para cada horizonte y enfoque.

### 3.1. Análisis preliminar de la serie de tiempo

La Figura 3.1 muestra los datos originales del número de *casos de IRA* en la ciudad de Montería, durante el periodo 2012-2023; en ella se evidencia que no hay un patrón de tendencia a largo plazo, pero si se observa tendencia en algunos cortos periodos de tiempo, por ejemplo alrededor de los años 2013 y 2021-2023. Adicionalmente, se observa

una alta variabilidad en los datos, lo cual ratifica la necesidad de realizar la limpieza de la serie con la finalidad de reducir la variabilidad.

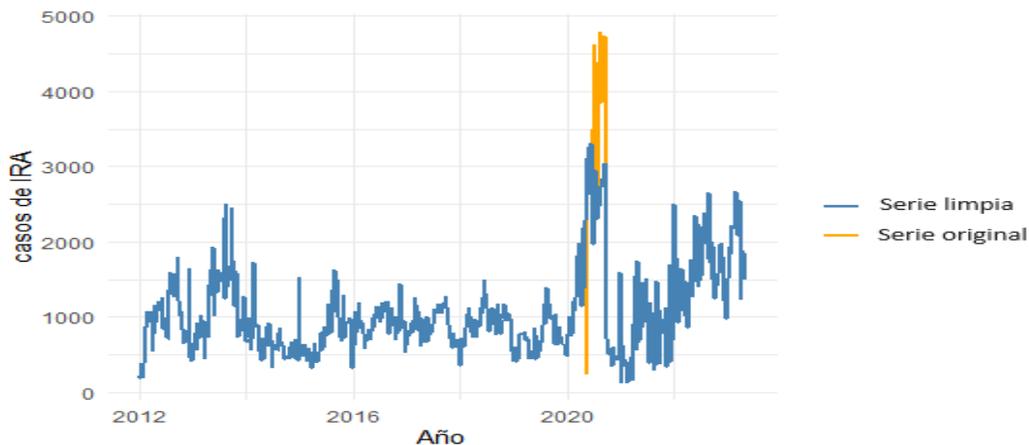
Figura 3.1: Casos de IRA en la ciudad de Montería, periodo 2012-2023



Fuente: Elaboración propia.

Una vez se realiza la limpieza de la serie, se observa en la Figura 3.2 que se suaviza el comportamiento de la serie en el año 2020 con respecto a la serie original, es decir, que se reducen los picos altos que representan la variabilidad alrededor de dicho año.

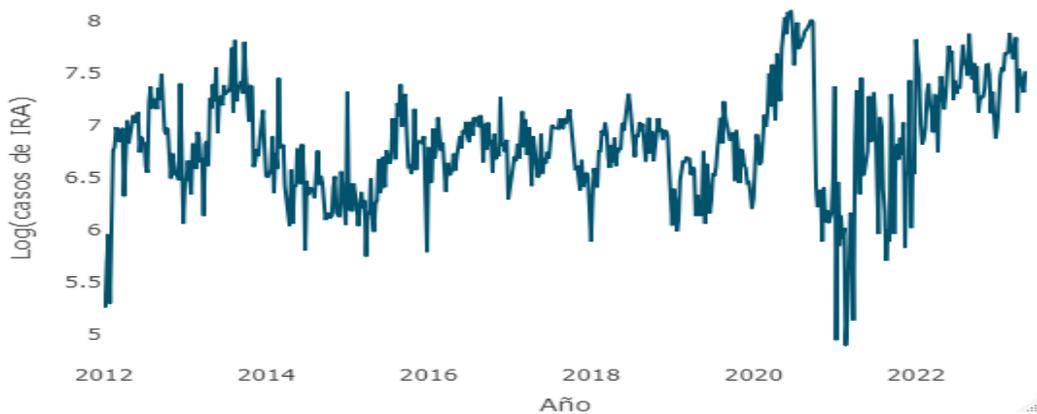
Figura 3.2: Serie limpia vs original



Fuente: Elaboración propia.

No obstante, se observa aún la existencia de mucha variabilidad en la serie limpia; por lo que se hace necesario estabilizar su varianza. Esto se hace tomando el logaritmo natural de los *casos de IRA*, con lo cual la escala del eje *y* se reduce a valores entre 5 y 8 (véase la Figura 3.3). Por lo tanto, la variable respuesta que se empleará en el modelado es el logaritmo natural de los *casos de IRA*.

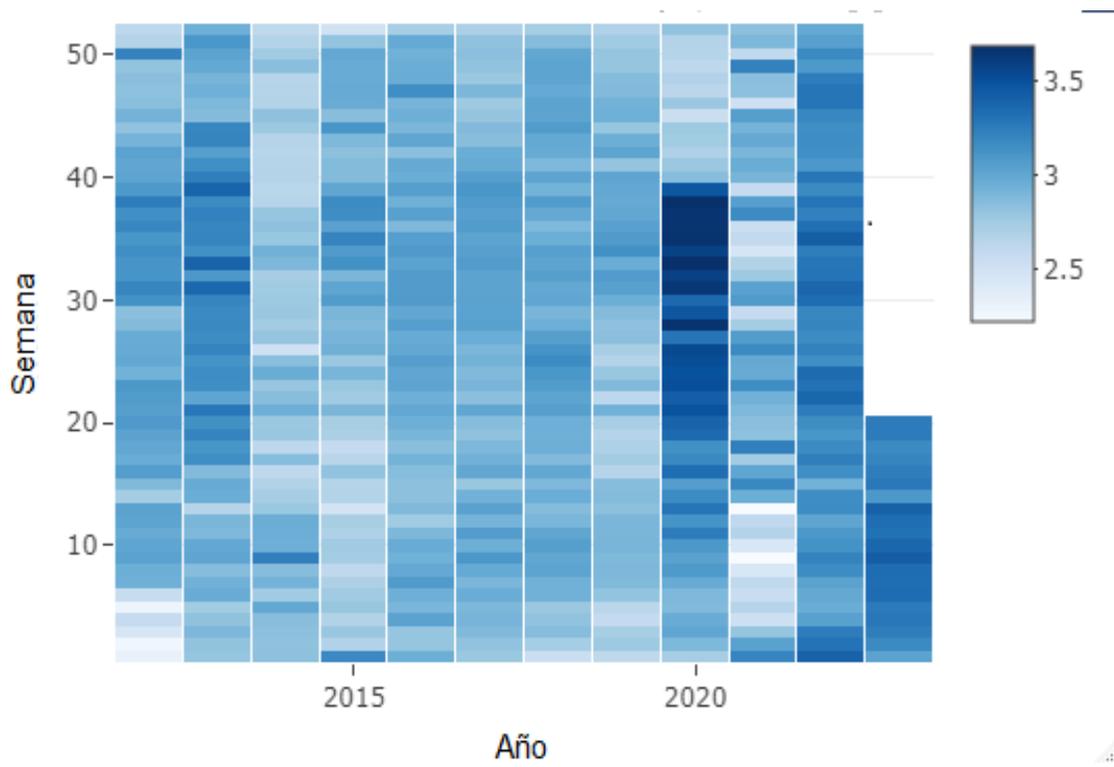
Figura 3.3: Serie temporal del logaritmo de los *casos de IRA* en Montería, 2012-2023



Fuente: Elaboración propia.

Después de estabilizar la variabilidad de la serie, se analiza su componente estacional. En este análisis, se observa que el logaritmo natural de los casos de Infecciones Respiratorias Agudas (IRA) en la ciudad de Montería muestran un patrón estacional leve. Este patrón se caracteriza por un ligero descenso en la variable respuesta, que se repite principalmente en las semanas 51 y 52 correspondiente a los años 2014-2019. Gráficamente, se observa en la Figura 3.4 una reducción en la intensidad de los colores para las semanas mencionadas, cuya intensidad es similar a la de los otros años.

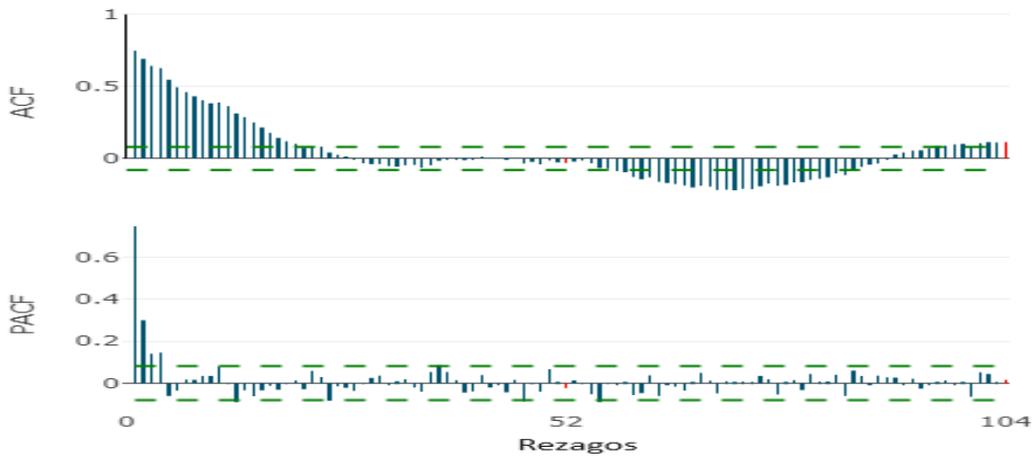
Figura 3.4: Estacionalidad del logaritmo de los *casos de IRA*



Fuente: Elaboración propia.

Por último, para verificar si la serie es estacionaria, se analiza la Figura 3.5. En dicha figura se observa que los coeficientes de autocorrelación son estadísticamente significativos, y disminuyen gradualmente hacia cero, siguiendo patrones sinusoidales, tanto en forma de senos como de cosenos. Además, al examinar la función de autocorrelación parcial (PACF), se evidencia la presencia de correlación lineal entre las observaciones rezagadas, ya que algunos coeficientes son significativos. Estos resultados permiten establecer que la serie no presenta estacionariedad. Lo cual es corroborado mediante la prueba Dickey-Fuller ( $p$ -valor=0,3937) con un nivel de significancia del 5%. Por tanto, se concluye que la serie no es estacionaria y requiere de una diferenciación.

Figura 3.5: ACF Y PAC de la serie de tiempo



Fuente: Elaboración propia.

A continuación, se presentan los resultados obtenidos con cada uno de los enfoques de modelado considerados para los *casos de IRA* reportados en la ciudad de Montería.

## 3.2. Modelado tradicional

Si bien se determina que la serie no es estacionaria cuando se considera todo el conjunto de datos (esto es, los 592 logaritmos naturales de *casos de IRA*), al particionar ésta en cada una de las cinco configuraciones se encontró que este resultado cambia para los horizontes de 52 y 35 semanas. Tal y como se muestra en la Tabla 3.1 dichos horizontes no requirieron diferenciación. Al examinar este suceso se evidencia en la serie completa, una tendencia a corto plazo prominente alrededor del periodo 2021 hasta 2023 (véase la Figura 3.1). Esto indica que la presencia de esta tendencia en la serie temporal podría no haberse detectado al dividir los datos en conjuntos de entrenamiento más pequeños, como en el caso de los dos primeros horizontes.

Tabla 3.1: Número diferenciaciones necesarias para que el conjunto de entrenamiento sea estacionario

Datos de entrenamiento-prueba	Horizonte	Nº de diferenciaciones
540-52	52	0
557-35	35	0
575-17	17	1
583-9	9	1
588-4	4	1

Una vez realizado el número de diferenciaciones identificadas para cada horizonte de pronóstico, se obtienen los siguientes modelos usando la función *autoarima*:

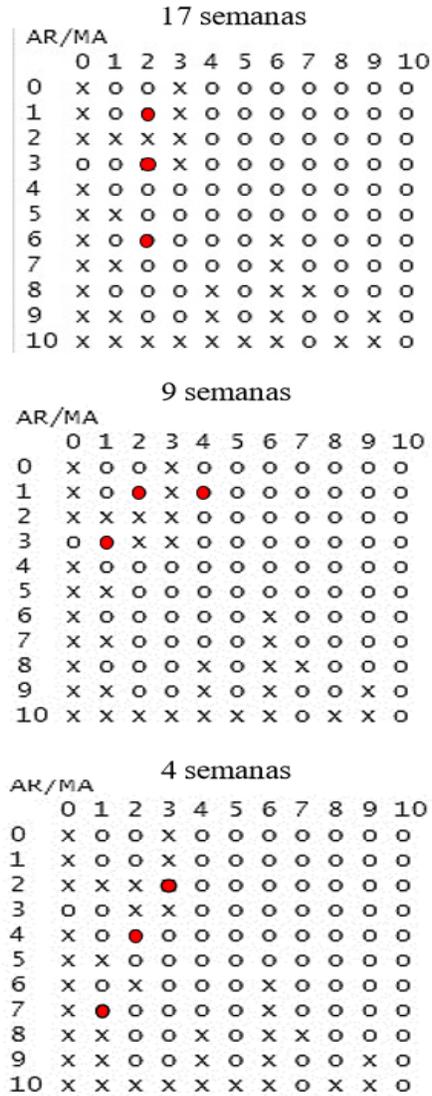
- **52 semanas:**  $ARIMA(1,0,1)$
- **35 semanas:**  $ARIMA(1,0,1)$
- **17 semanas:**  $SARIMA(2,1,2)(1,0,0)_{52}$
- **9 semanas:**  $SARIMA(2,1,2)(1,0,0)_{52}$
- **4 semanas:**  $SARIMA(2,1,2)(1,0,0)_{52}$

De acuerdo a este resultado se puede evidenciar que a medida que se dispone de una mayor cantidad de datos para entrenar el modelo se vuelve más fácil identificar la estacionalidad que presenta la serie. Sin embargo, cuando se cuenta con un conjunto de datos de entrenamiento más pequeño, como en los casos de los horizontes de 52 y 35 semanas,

es posible que no se logre captar completamente el patrón estacional ni de tendencia. Por lo tanto, en estos casos el modelo candidato es un  $ARIMA(p, d, q)$ . Esta situación conlleva que para ajustar los modelos  $SARIMA(p, d, q)(P, D, Q)_S$  es esencial disponer de un conjunto de datos de prueba que cubra un período mínimo de 17 semanas epidemiológicas (4 meses).

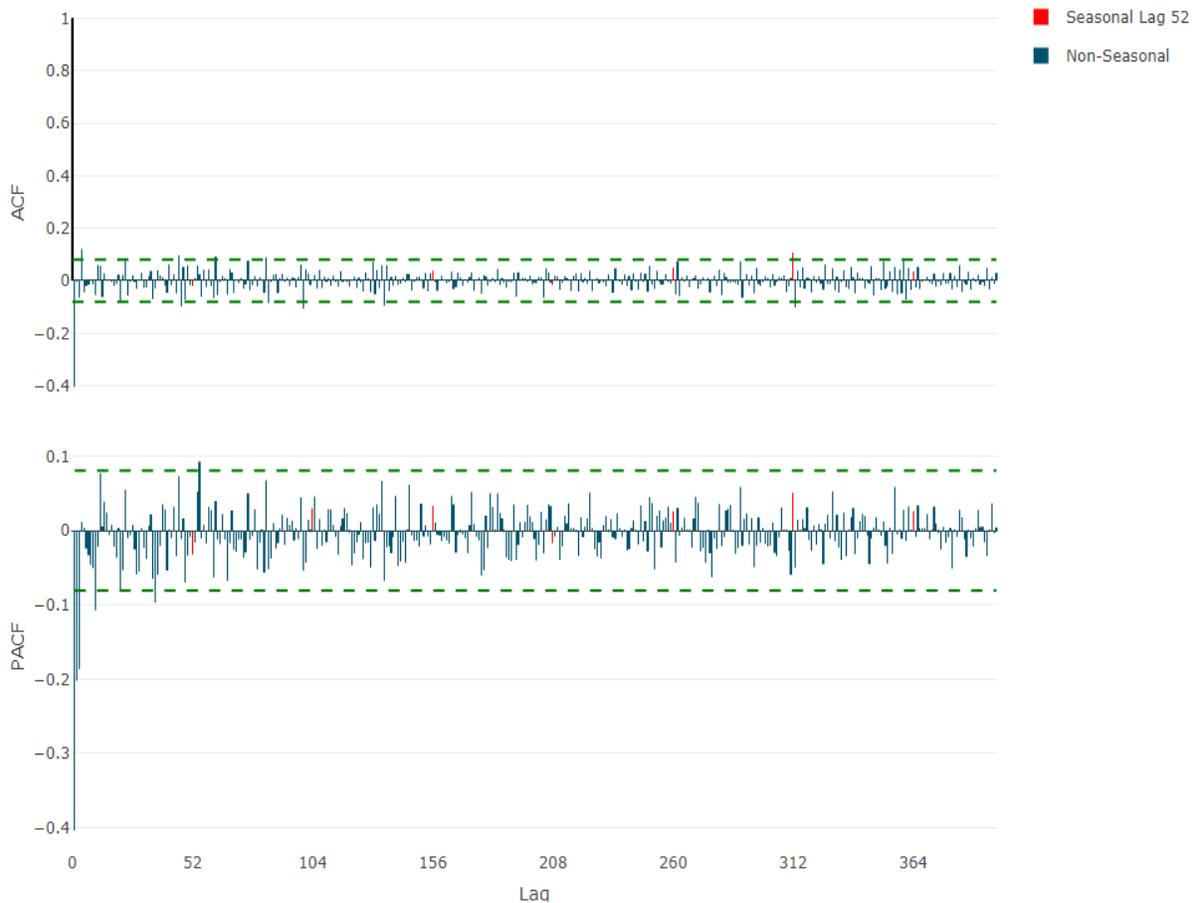
Por otra parte, en la Figura 3.6 se resaltan los modelos seleccionados para la parte regular de los modelos  $SARIMA$  de acuerdo a la metodología de Tsay y Tiao (1984). Asimismo, en la Figura 3.7 se identifica un patrón estacional de 52 semanas epidemiológicas, debido a que el rezago 312 (correspondiente a la semana 52 del año 2018) es significativo. Además, al observar la función de autocorrelación parcial (PACF), los rezagos estacionales no tienen un decaimiento hacia cero, lo que indica que no se incluyen términos de medias móviles estacionales en el orden  $Q$  si no términos autorregresivo  $P$  ya que hay retardos que sobresalen las bandas de significancia.

Figura 3.6: Gráfico de Autocorrelación Extendida (EACF) para la elección manual de los modelos SARIMA para cada horizonte de pronóstico, 17, 9 y 4 semanas



Fuente: Elaboración propia.

Figura 3.7: Gráfico de función de auctorrelación y función de autocorrelación parcial de la serie para determinar el orden estacional en los modelos *SARIMA*



Fuente: Elaboración propia.

La Tabla 3.2 contiene los modelos candidatos ajustados para cada combinación de horizonte de pronóstico. El primer modelo que se muestra para cada horizonte corresponde al proporcionado por el *Autoarima* y los tres restantes son los modelos tentativos ajustados manualmente. Una vez se analizan los valores de los criterios de información AIC y BIC, se selecciona como mejor modelo de cada horizonte aquel que contenga los valores más pequeños y consistentes:

- 52 semanas:  $ARIMA(1,0,1)$
- 35 semanas:  $ARIMA(1,0,1)$
- 17 semanas:  $SARIMA(1,1,2)(1,0,0)_{52}$
- 9 semanas:  $SARIMA(1,1,2)(1,0,0)_{52}$
- 4 semanas:  $SARIMA(4,1,2)(1,0,0)_{52}$

Tabla 3.2: Modelos de pronóstico candidatos

Horizonte	Modelo	AIC	BIC
52 Semanas	$ARIMA(1,0,1)$	314,51	331,67
	$ARIMA(1,0,2)$	316,45	337,91
	$ARIMA(4,0,3)$	315,36	353,98
	$ARIMA(5,0,2)$	314,79	353,41
35 Semanas	$ARIMA(1,0,1)$	316,68	333,98
	$ARIMA(1,0,2)$	318,67	340,28
	$ARIMA(2,0,2)$	319,79	345,72
	$ARIMA(5,0,2)$	317,09	355,99
17 Semanas	$SARIMA(2,1,2)(1,0,0)_{52}$	331,59	357,7
	$SARIMA(1,1,2)(1,0,0)_{52}$	321,14	342,9
	$SARIMA(3,1,2)(1,0,0)_{52}$	327,32	353,44
	$SARIMA(6,1,2)(0,0,2)_{52}$	322,31	365,83
9 Semanas	$SARIMA(2,1,2)(1,0,0)_{52}$	330,14	356,34
	$SARIMA(1,1,4)(1,0,0)_{52}$	329,47	360,04
	$SARIMA(1,1,2)(1,0,0)_{52}$	320,72	342,55
	$SARIMA(3,1,1)(1,0,0)_{52}$	325,81	352,01
4 Semanas	$SARIMA(2,1,2)(1,0,0)_{52}$	332,26	358,51
	$SARIMA(7,1,1)(1,0,0)_{52}$	330,93	374,68
	$SARIMA(4,1,2)(1,0,0)_{52}$	320,5	355,5
	$SARIMA(2,1,3)(1,0,0)_{52}$	329,92	360,54

Nótese que, para los horizontes de 52 y 35 semanas, el mejor modelo seleccionado fue el proporcionado por la función *Autoarima*, mientras que para los horizontes de 4, 9 y 17 semanas el mejor modelo se encontró manualmente. Este último resultado apoya

lo mencionado por Huertas *et al.* (2018), el cual demuestra que en algunas ocasiones la función automática puede incurrir en fallas o violación de supuestos, por lo que se hace necesario identificar el modelo de manera manual para obtener resultados más robustos.

Los resultados del diagnóstico de los modelos seleccionados para cada horizonte de pronóstico se presentan en la Tabla 3.3.

Tabla 3.3: *valor – p* asociado a las pruebas de hipótesis realizadas en el diagnóstico de los modelos

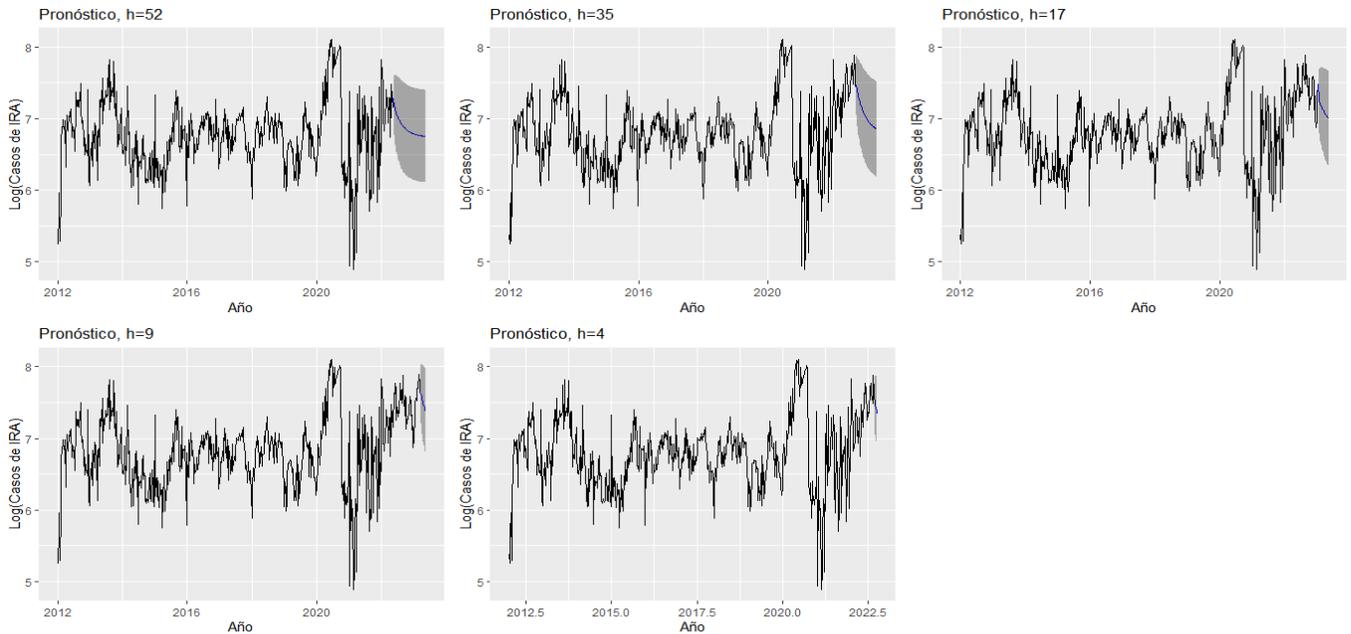
Prueba	Hipótesis	Horizonte de pronóstico				
		52	35	17	9	4
ARCH	$H_0$ : Homocedasticidad del error vs $H_1$ : Heterocedasticidad del error	0,461	0,417	0,334	0,3048	0,391
Ljung-Box	$H_0$ : No autocorrelación serial de los residuales vs $H_1$ : Hay autocorrelación serial de los residuales	0,7665	0,8060	0,8845	0,8484	0,9132
Prueba t	$H_0$ : Errores centrados en cero vs $H_1$ : Errores no centrados en cero	0,6491	0,6301	0,0776	0,0733	0,0744
Anderson-D	$H_0$ : Los errores se distribuyen como una normal vs $H_1$ : Los errores no se distribuyen como una normal	$3,55E - 17$	$1,28E - 17$	$1,33E - 17$	$3,73E - 18$	$5,58E - 17$
Jarque-Bera	$H_0$ : Los errores se distribuyen como una normal vs $H_1$ : Los errores no se distribuyen como una normal	0	0	0	0	0
ADF.test	$H_0$ : Los errores no son ruido blanco vs $H_1$ : Los errores son ruido blanco	0,01	0,01	0,01	0,01	0,01

Se infiere, con un nivel de significancia  $\alpha = 0,05$ , que todos los supuestos de los modelos se cumplen, excepto el supuesto de normalidad. Sin embargo, Hyndman y Athanopoulos (2018); Knief y Forstmeier (2021) resaltan que los modelos lineales de series

temporales son robustos a la violación del supuesto de normalidad, siempre y cuando los valores atípicos se manejen correctamente, lo cual se realiza en este estudio mediante la limpieza de la serie. De modo que los modelos seleccionados, para cada horizonte, pueden ser utilizados para pronosticar los datos de prueba.

La Figura 3.8 ilustra el pronóstico obtenido para cada horizonte, donde se evidencia que la amplitud del intervalo de predicción mejora a medida que se tiene mayor cantidad de datos para entrenar el modelo, es decir, cuando el horizonte de pronóstico es más pequeño. Además, se identifica una tendencia decreciente en los pronósticos en varios horizontes.

Figura 3.8: Pronostico del Número de *casos de IRA* en la ciudad de Montería, periodo 2012-2023 para los diferentes horizontes de pronostico usando series de tiempo tradicionales



Fuente: Elaboración propia.

### 3.3. Modelado basado en redes neuronales artificiales

La búsqueda por cuadrícula establecida en el Capítulo 2 para determinar la mejor configuración de la red MLP para cada una de las cinco configuraciones de validación cruzada, considera 126 combinaciones obtenidas a partir de la combinación de los siguientes parámetros:

- **Número de rezagos** :  $p = 1, 2, 3, 4, 5, 6, 7$
- **Tamaño del lote o de capas ocultas**:  $size = 1, 2, 4, 6, 8, 10$
- **Tasa de aprendizaje**:  $learnrate = 0,05$
- **Número de épocas**:  $epochs = 1000$
- **Función de activación**: *ReLU, sigmoide y tanh*

La cantidad de nodos en la capa oculta (*size*) a evaluar se determina considerando que, si bien, la función *nnetar* de R no permite ajustar directamente el parámetro de regulación para evitar el sobreajuste, la forma más sencilla de evitar este, es mediante la selección del número de nodos en la capa oculta. Giustolisi y Laucelli (2005) y Haykin (1999) sugieren que para regularizar la red se debe aumentar gradualmente el número de nodos en la capa oculta, buscando que el rendimiento de la red sea consistente tanto para los datos de entrenamiento como los de prueba, y evitando que se obtenga un rendimiento perfecto (función de costo igual cero) debido a que sería un modelo sobreajustado.

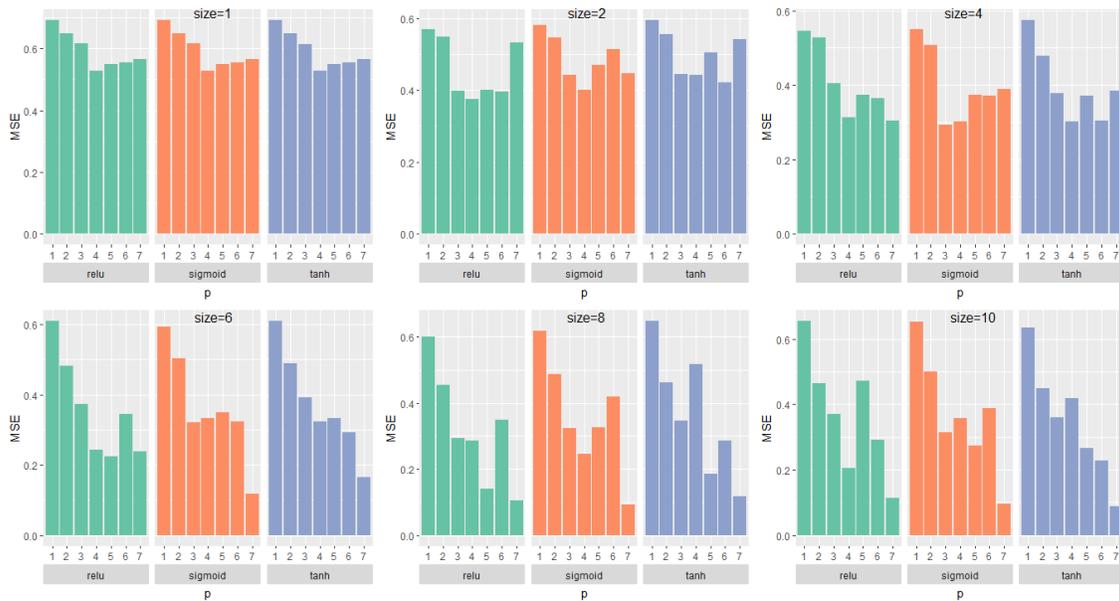
Los resultados del proceso de selección del mejor modelo MLP descrito en el Capítulo 2 se resumen en las Figuras 3.9, 3.10, 3.11 , 3.12 y 3.13, en las cuales se contrasta el valor

del *MSE* obtenido para las combinaciones del número de rezagos, función de activación y número de nodos en la capa oculta.

A continuación, se analizan los resultados obtenidos y se define la mejor configuración  $p - size - 1$ , para cada horizonte de pronóstico. Nótese que todas las configuraciones tienen en la capa de salida un sólo nodo correspondiente al pronóstico de un paso hacia adelante:

- Horizonte de 52 semanas:** En la Figura 3.9 se observa que a partir de la sexto nodo en la capa oculta la función de costo *MSE* disminuye, específicamente cuando se aumenta el valor de  $p$  a 7, siendo mejor la función de activación la *tanh* con la configuración 7-10-1.

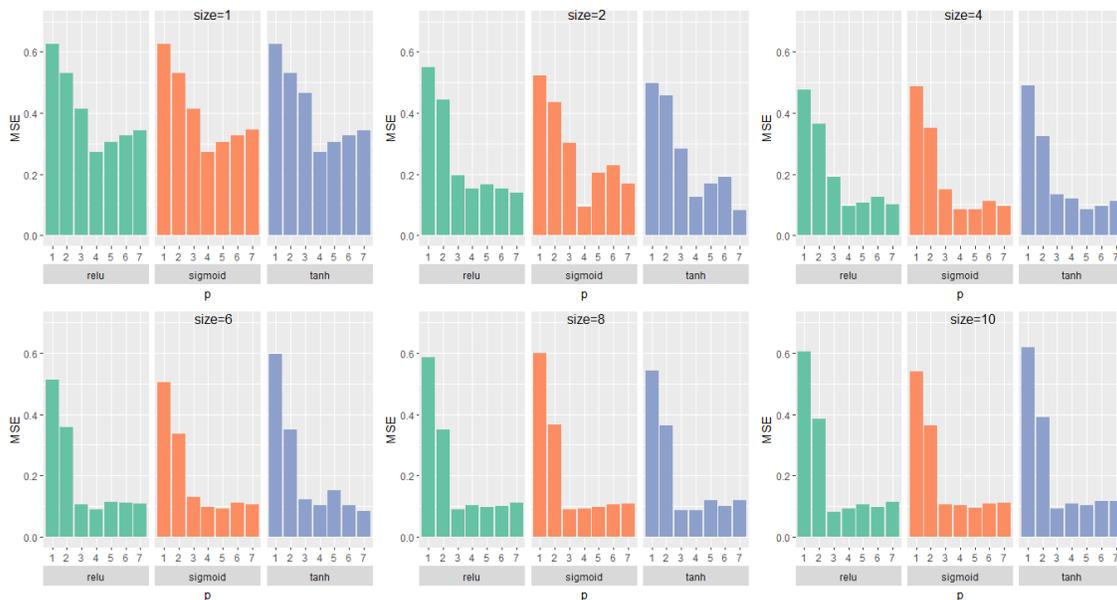
Figura 3.9: Desempeño de los modelos MLP cuando  $h = 52$ , variando el número de variables de entrada, capas ocultas, y las funciones de activación.



Fuente: Elaboración propia.

- Horizonte de 35 semanas:** En la Figura 3.10 se evidencia un decaimiento rápidamente del  $MSE$  cuando se tienen más de 2 nodos, particularmente a partir de  $p = 2$  con función de activación  $ReLU$ , siendo la mejor configuración la 3-8-1. Sin embargo, al examinar la configuración con 6 nodos en la capa oculta,  $p = 4$  y función de activación  $ReLU$  se encuentra que la diferencia en su  $MSE$  con respecto a la mencionada anteriormente es mínima (0,009), por tanto, se opta por tomar la configuración 6-4-1, ya que tiene menos parámetros, lo que aumenta la rapidez para entrenar el modelo.

Figura 3.10: Desempeño de los modelos MLP cuando  $h = 35$ , variando el número de variables de entrada, capas ocultas, y las funciones de activación.

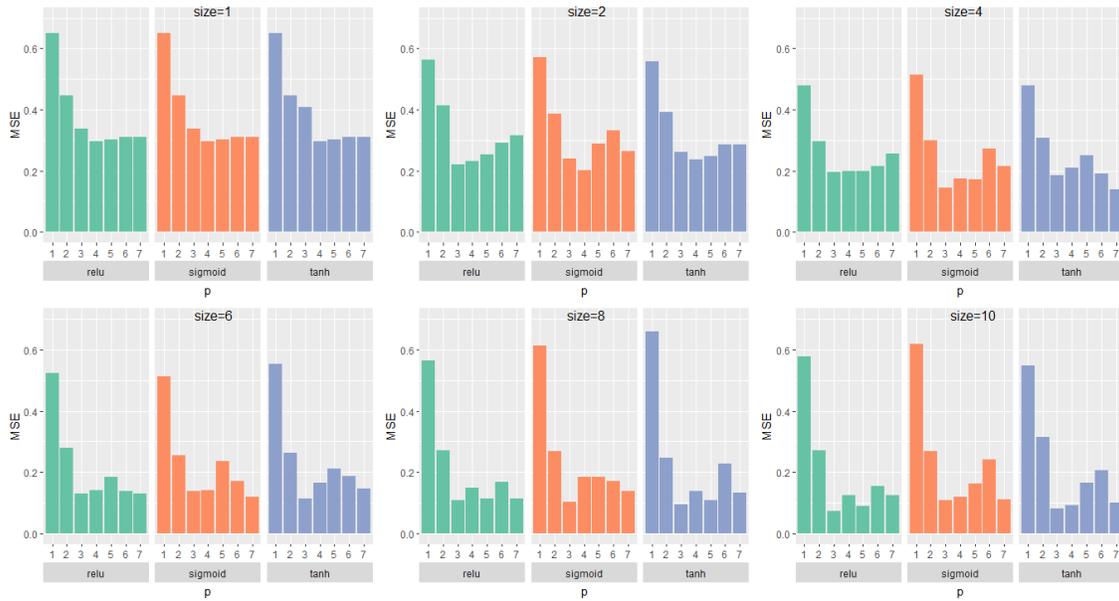


Fuente: Elaboración propia.

- Horizonte de 17 semanas:** La función de costo  $MSE$  tiene una reducción progresiva notable en los rezagos  $p = 3, 4$  y  $5$  y a partir de 6 nodos en la capa oculta, obteniéndose que el mejor modelo tiene la configuración 3-10-1 con función de activación

*ReLU* (Ver Figura 3.11).

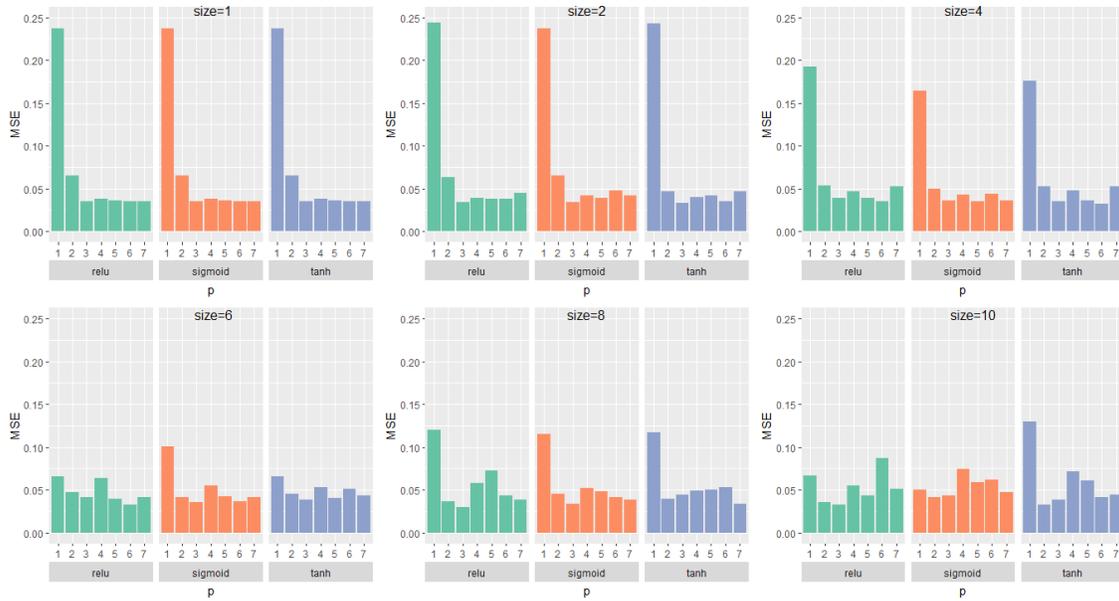
Figura 3.11: Desempeño de los modelos MLP cuando  $h = 17$ , variando el número de variables de entrada, capas ocultas, y las funciones de activación.



Fuente: Elaboración propia.

- **Horizonte de 9 semanas.** En la Figura 3.12 se observa que hay un comportamiento aproximadamente constante en el valor del *MSE* cuando se aumenta el número de rezagos y de capas ocultas. El mejor modelo se obtiene bajo una función de activación *ReLU* con configuración 3-8-1.

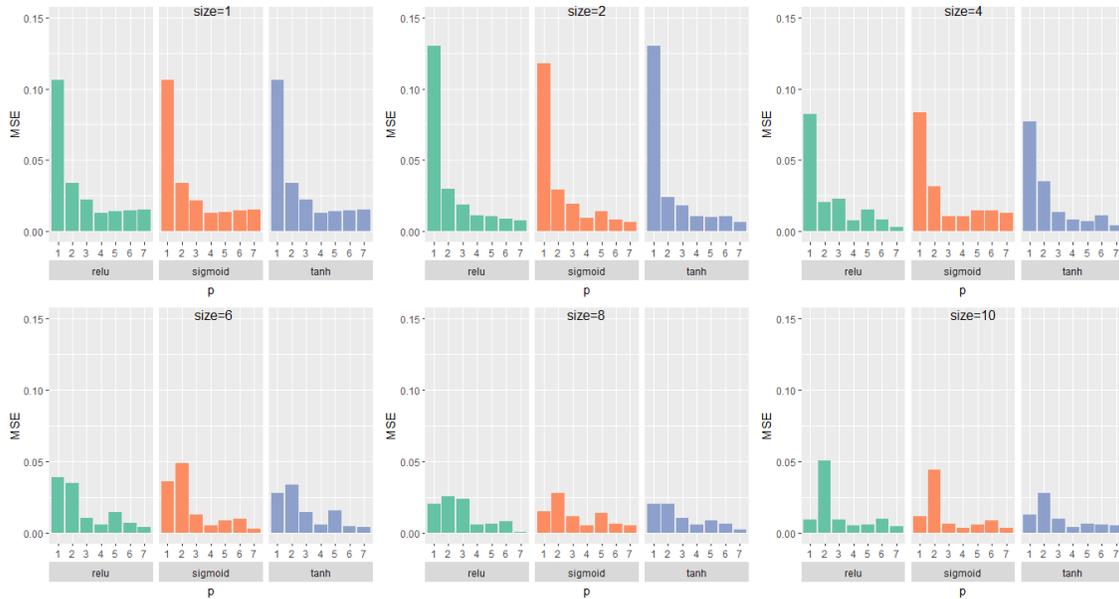
Figura 3.12: Desempeño de los modelos MLP cuando  $h = 9$ , variando el número de variables de entrada, capas ocultas, y las funciones de activación.



Fuente: Elaboración propia.

- **Horizonte de 4 semanas:** En la Figura 3.13 se observa que a medida que aumenta el número de rezagos  $p$  y se aumenta el número de capas ocultas se disminuye la función de costo  $MSE$ , por tanto el mejor modelo  $ANN$  se obtiene con una función de activación  $ReLU$  y una configuración 7-8-1.

Figura 3.13: Desempeño de los modelos MLP cuando  $h = 4$ , variando el número de variables de entrada, capas ocultas, y las funciones de activación.



Fuente: Elaboración propia.

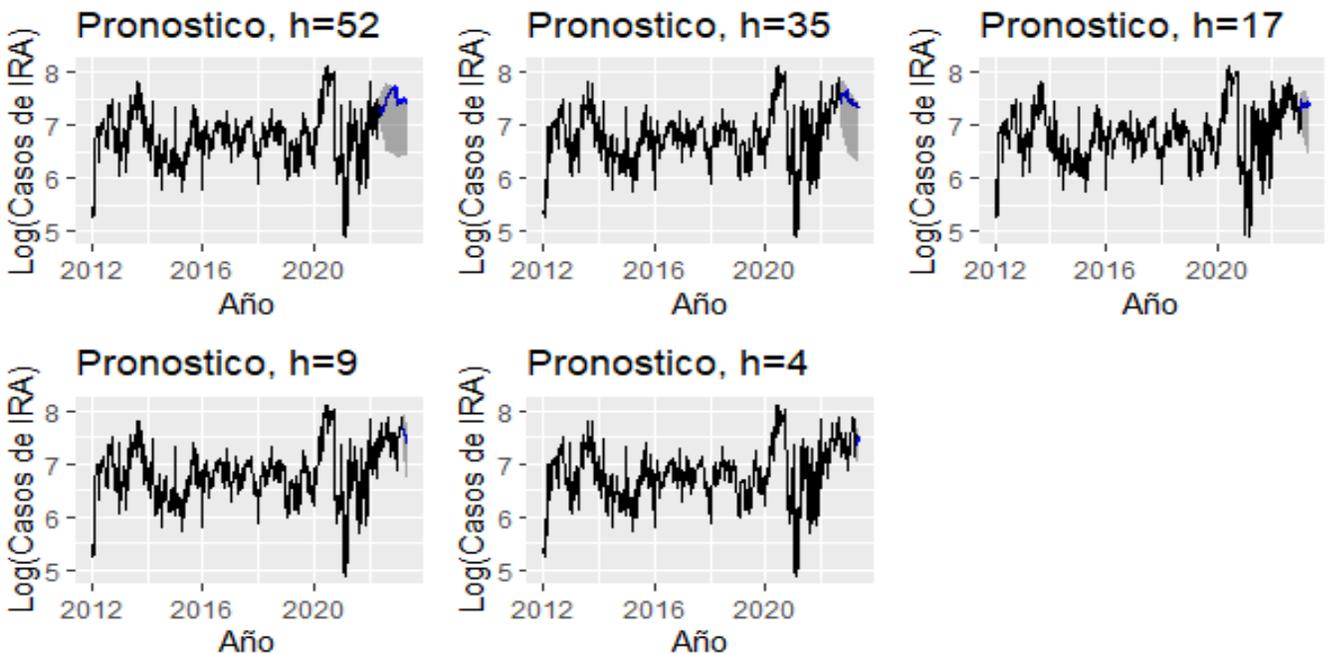
De acuerdo a los resultados anteriores, de todas las posibles combinaciones, los mejores modelos seleccionados empleando los datos de prueba se presentan en la Tabla 3.4. En dicha tabla se puede evidenciar que a medida que se aumenta el conjunto de datos para entrenar el modelo, este adquiere la capacidad de aprender patrones y estructuras más sólidas ya que el valor de la función de costo disminuye. En consecuencia, la precisión del modelo tiende a mejorar y a su vez sus pronósticos. Lo cual es ratificado a través de la Figura 3.14, en donde se observa para cada horizonte la dirección en la que se espera que se muevan los valores en el futuro y sus límites del pronóstico; estos límites se reducen a medida que el horizonte aumenta, particularmente en los últimos 3 horizontes se observa un menor error de pronóstico.

Por otra parte se encontró que a partir del horizonte de 35 semanas en adelante, la función de activación *ReLU* proporciona los resultados más favorables. Este resultado concuerda con lo mencionado por Kelleher (2019), el cual resalta que al usar dicha función de activación se pueden obtener mejores resultados.

Tabla 3.4: Desempeño del mejor modelo *ANN* seleccionado para cada horizonte de pronóstico utilizando datos de prueba

Horizonte	p (rezagos)	Nodos en la capa oculta	Función de activación	MSE
52	7	10	Tangente	0,0876
35	6	4	Relu	0,0898
17	3	10	Relu	0,0718
9	3	8	Relu	0,0296
4	7	8	Relu	0,00045

Figura 3.14: Resultado del pronóstico del Número de *casos de IRA* en la ciudad de Montevideo, periodo 2012-2023 para los diferentes horizontes de pronóstico usando una *ANN*



Fuente: Elaboración propia.

### 3.4. Metodología híbrida

Usando la metodología descrita en la Sección 2.3 y el esquema de selección por medio de mallas de las *ANN* para modelar la componente  $N_t$ , usando como entrada los residuales de los modelos tradicionales, se obtiene para cada horizonte de pronóstico y método (aditivo y multiplicativo) las configuraciones y funciones de costo, presentadas en las Tablas 3.5 y 3.6.

Tabla 3.5: Configuración del mejor modelo híbrido aditivo seleccionado para cada horizonte de pronóstico.

Horizonte	p (rezagos)	Nodos en la capa oculta	Función de activación	MSE
52	2	10	tanh	54,8105
35	2	10	relu	54,3058
17	2	8	tanh	56,5040
9	2	10	relu	55,1653
4	6	10	sigmoid	53,4799

Tabla 3.6: Configuración del mejor modelo híbrido multiplicativo seleccionado para cada horizonte de pronóstico.

Horizonte	p (rezagos)	Nodos en la capa oculta	Función de activación	MSE
52	2	10	tanh	41,8770
35	2	10	relu	41,4146
17	2	10	sigmoid	43,2506
9	2	8	sigmoid	42,0622
4	7	4	relu	41,1571

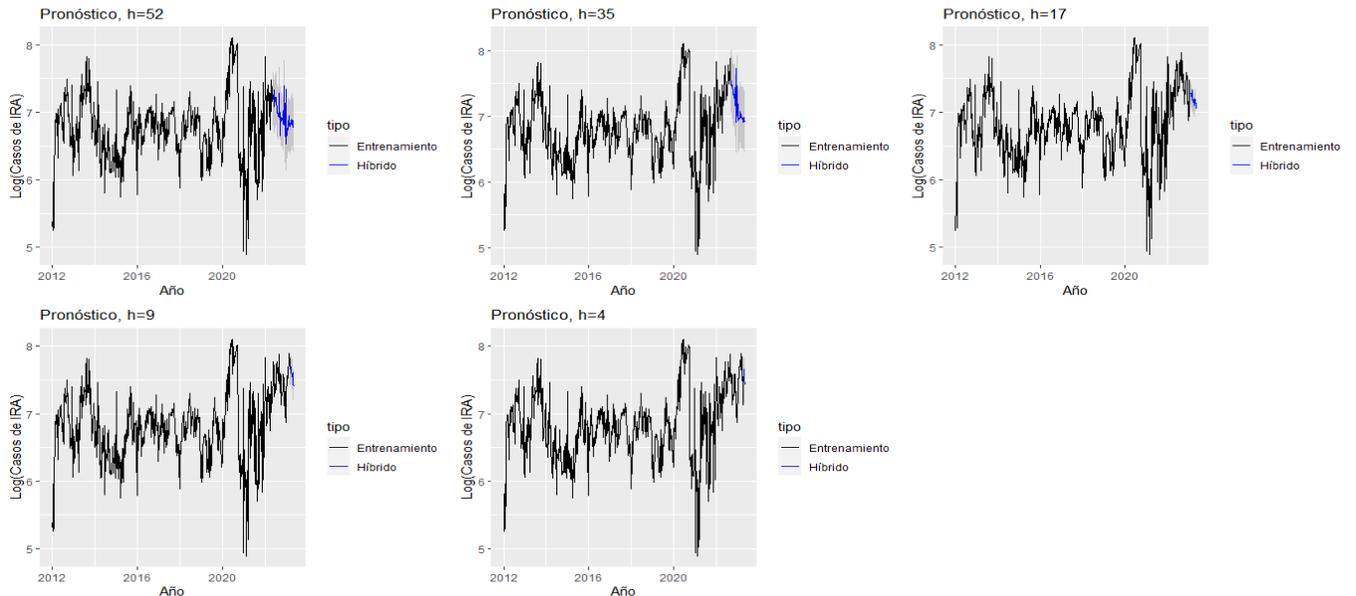
Por otra parte, la estimación final de cada método fue hallada considerando como estimación de la componente lineal  $L_t$ , los pronósticos obtenidos con los modelos tradicionales; y como estimación de la componente  $N_t$  las salidas de la redes antes mencionadas, y empleando las expresiones de las Ecuaciones (2.13) y (2.14). Se encuentra que los mejores resultados ( tanto en el conjunto de prueba como de entrenamiento) son proporcionados por el método híbrido aditivo. La Tabla 3.7 contiene la métrica de desempeño  $MSE$  obtenida en los datos de prueba para cada horizonte de pronóstico, cuando se emplea el método híbrido aditivo.

Tabla 3.7: Función de costo para los datos de prueba del pronostico obtenido con el método híbrido aditivo

<b>Horizonte</b>	<b>Modelo tradicional</b>	<b>modelo ANN</b>	<b>Combinación</b>	<b>MSE</b>
52	$ARIMA(1,0,1)$	$NNAR(2,10)$	$ARIMA/NNAR$	0,3820
35	$ARIMA(1,0,1)$	$NNAR(2,10)$	$ARIMA/NNAR$	0,2451
17	$SARIMA(1,1,2)(1,0,0)_{52}$	$NNAR(2,10)$	$SARIMA/NNAR$	0,1863
9	$SARIMA(1,1,2)(1,0,0)_{52}$	$NNAR(2,8)$	$SARIMA/NNAR$	0,0447
4	$SARIMA(4,1,2)(1,0,0)_{52}$	$NNAR(7,4)$	$SARIMA/NNAR$	0,0297

Adicionalmente, los pronósticos de los modelos híbridos aditivos ajustados presentan un comportamiento similar al obtenido en los modelos tradicionales y los modelos de redes neuronales, donde a medida que se tiene mayor cantidad de datos para entrenar el modelo, mejor será su desempeño ( véase la Figura 3.15).

Figura 3.15: Resultado del pronóstico del Número de *casos de IRA* en la ciudad de Montería, periodo 2012-2023 para los diferentes horizontes de pronóstico usando modelos híbridos



Fuente: Elaboración propia.

### 3.5. Comparación del desempeño de los modelos obtenidos con los tres enfoques

Para que un modelo sea adecuado para pronosticar y no presente sobreajuste, se requiere que tenga un excelente desempeño tanto en el conjunto de datos de entrenamiento como de prueba (Giustolisi y Laucelli, 2005; Haykin, 1999). La Tabla 3.8 contiene los valores de las métricas de desempeño no probabilísticas obtenidas en los datos de entrenamiento y prueba, de los modelos seleccionados para pronosticar el logaritmo natural del

número de *casos de la IRA* en Montería, durante el periodo 2012-2023, en cada horizonte de pronóstico y enfoque. En dicha tabla se observa un patrón característico: Las métricas de desempeño tanto para entrenamiento como prueba son mas consistentes cuando se tienen un horizonte de 35, 17 y 9 semanas, siendo la red neuronal el enfoque con mejores resultados. Si bien en el horizonte de 4 semanas, los modelos tienen un buen desempeño, esto se debe de manera a la cantidad limitada de nuevas observaciones en ese horizonte. Finalmente, el horizonte de 52 semanas presenta resultados robustos, pero en comparación con los demás horizontes, es el que tiene menor desempeño.

Tabla 3.8: Métricas de desempeño para comparar el rendimiento de los modelos tradicionales, redes neuronales y híbrido.

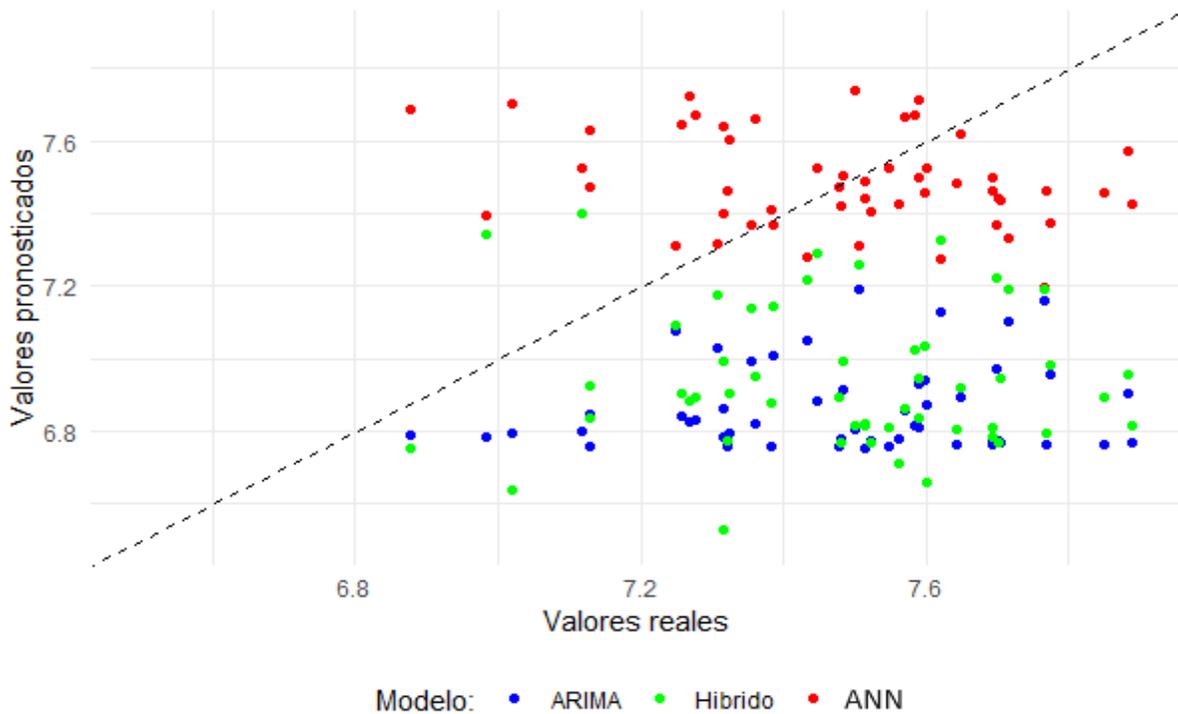
Horizonte	Conjunto de datos	Tradicional			ANN			Híbrido		
		RMSE	MAE	MAPE	RMSE	MAE	MAPE	RMSE	MAE	MAPE
52	Entrenamiento	0,3210	0,2240	3,3835	0,2027	0,1494	2,2327	0,2634	0,1878	172,2527
	Prueba	0,6646	0,6178	8,1779	0,2961	0,2317	3,1211	0,6180	0,5600	7,4146
35	Entrenamiento	0,3188	0,2222	3,3476	0,2554	0,1839	2,7545	0,2643	0,1884	133,0655
	Prueba	0,5144	0,4235	5,5917	0,2996	0,2413	3,2796	0,4951	0,4202	5,5829
17	Entrenamiento	0,3164	0,2212	3,3127	0,2514	0,1799	2,6865	0,2734	0,1929	127,5533
	Prueba	0,4940	0,4641	6,0738	0,2679	0,2286	2,9869	0,4360	0,4047	5,2922
9	Entrenamiento	0,3152	0,2202	3,2946	0,2602	0,1859	2,7769	0,2645	0,1872	124,2418
	Prueba	0,1827	0,1351	1,8198	0,1720	0,1251	1,6839	0,2116	0,1559	2,1194
4	Entrenamiento	0,3128	0,2195	3,2801	0,2241	0,1654	2,4635	0,2083	0,1524	137,3787
	Prueba	0,1162	0,1021	1,3664	0,0214	0,0196	0,2651	0,1723	0,1538	2,0785

Un resultado más detallado se obtiene al comparar gráficamente los valores pronosti-

cados con respecto a los valores reales, para cada enfoque y horizonte. Se incluye un línea de 45 grados, que sirve como referencia fundamental para evaluar visualmente cuán cerca o lejos se encuentran los pronósticos de los valores reales. A continuación, se describen los resultados obtenidos para cada horizonte de pronóstico:

**Horizonte de 52 semanas:** En la Figura 3.16 se evidencia que los puntos de color rojo, que representan las predicciones generadas por la red neuronal se encuentran más cercanos a la línea. Esta proximidad indica que usando la configuración datos entrenamiento-prueba 540-52 , se obtiene una mayor precisión en las predicciones realizadas por el modelo *ANN* del logaritmo natural de los *casos de IRA*.

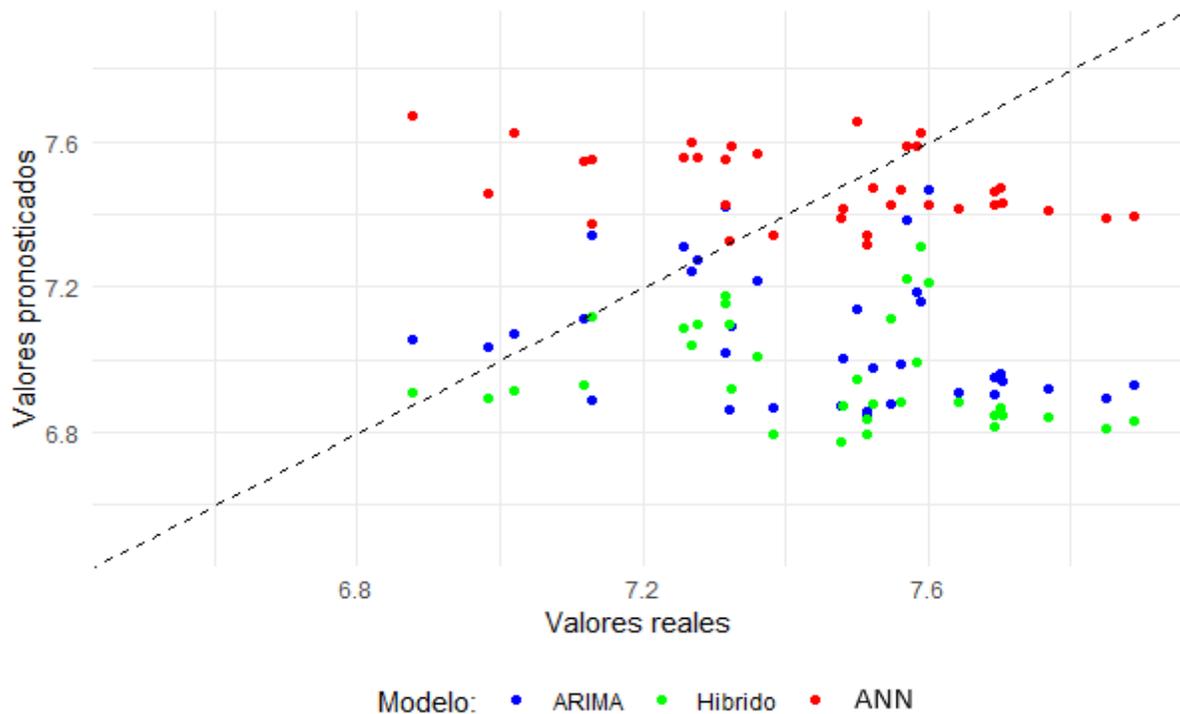
Figura 3.16: Comparación del valor real vs pronosticado para cada enfoque de modelado considerando un horizonte de 52 semanas



Fuente: Elaboración propia.

**Horizonte de 35 semanas:** Como se aprecia en la Figura 3.17 el enfoque tradicional e híbrido presentan mejores pronósticos en comparación con el anterior horizonte. No obstante, se observa que hay puntos que se alejan significativamente del valor real en dichos enfoques. Este fenómeno se presenta con menor frecuencia en el caso de la ANN, donde sus predicciones tienden a no alejarse considerablemente de la curva de 45 grados. Por tanto considerando una configuración entrenamiento y prueba de 575-35 se obtiene una mayor precisión en las predicciones realizadas por el modelo ANN.

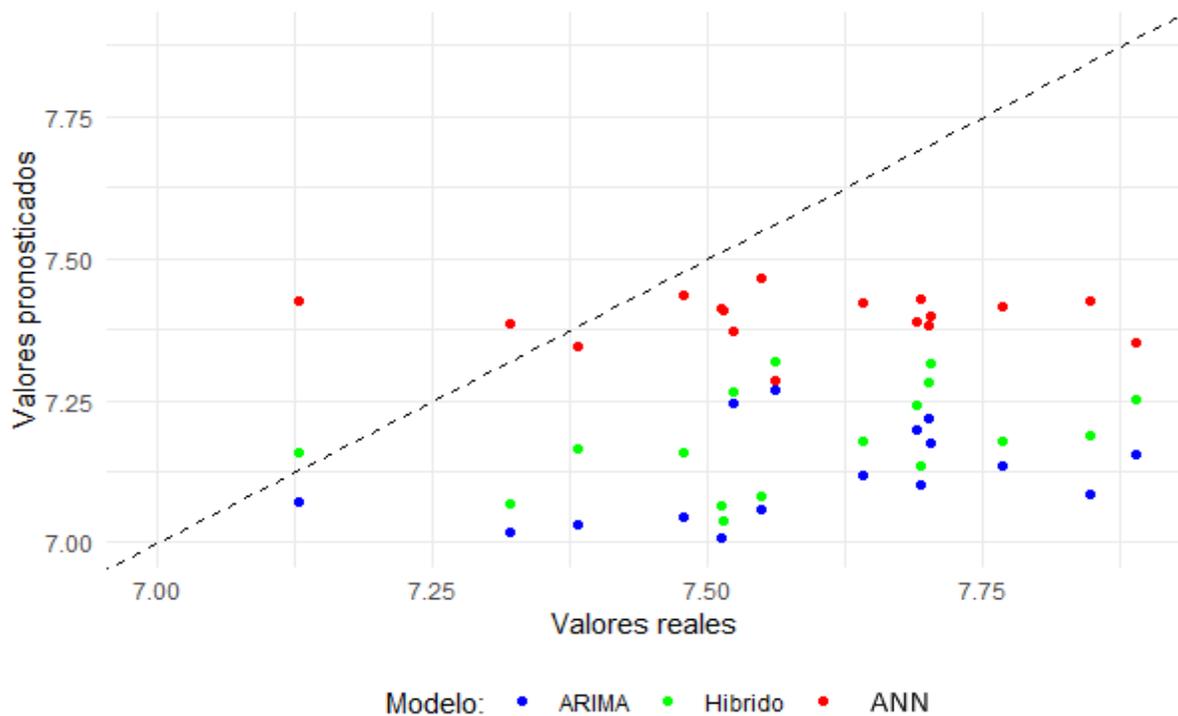
Figura 3.17: Comparación del valor real vs pronosticado para cada enfoque de modelado considerando un horizonte de 35 semanas



Fuente: Elaboración propia.

**Horizonte de 17 semanas:** La dispersión de los datos de la Figura 3.18 muestra que el enfoque *ANN* es ligeramente mejor al modelado tradicional e híbrido ajustando de manera leve a la recta. Por tanto, considerando 575 semanas de entrenamiento y 17 de prueba, se obtiene una mayor precisión en las predicciones realizadas por el modelo *ANN* para un horizonte de  $h = 17$ .

Figura 3.18: Comparación del valor real vs pronosticado para cada enfoque de modelado considerando un horizonte de 17 semanas

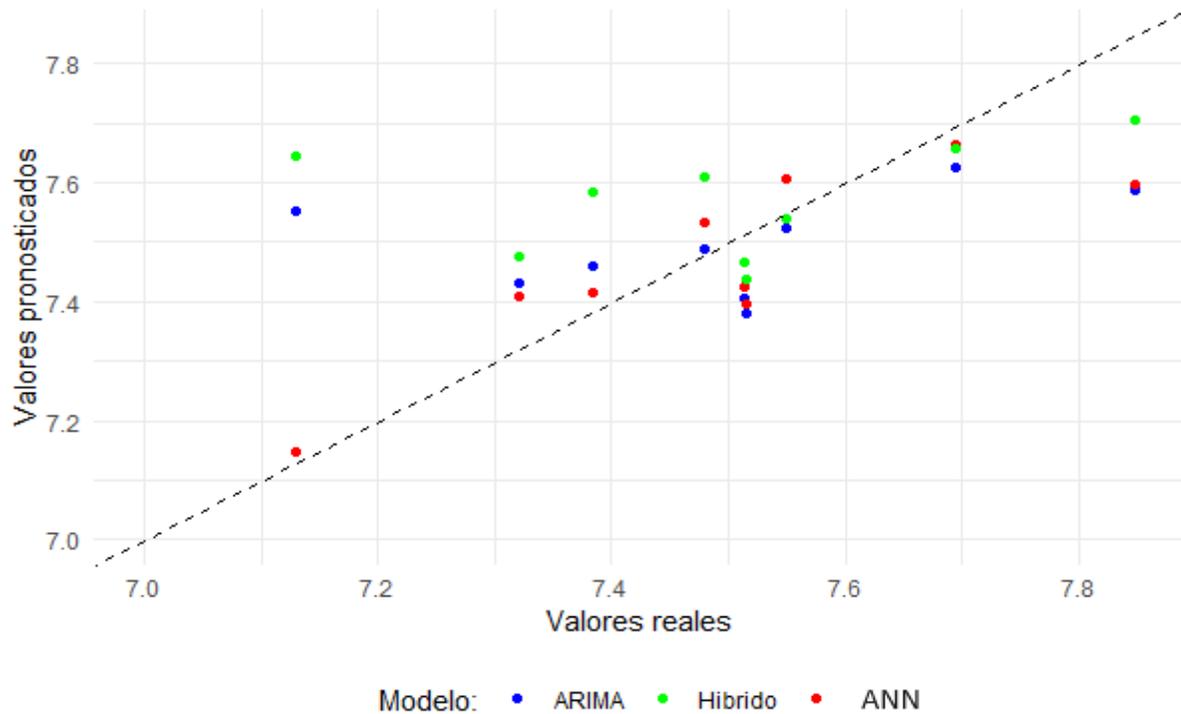


Fuente: Elaboración propia.

**Horizonte de 9 semanas:** Cuando se considera un horizonte de 9 semanas epidemiológicas el valor pronosticado se acerca al valor real para los 3 enfoques, siendo la *ANN* la que mejor se ajusta a la recta (ver Figura 3.19). consecuentemente a esto cuando se

consideran conjunto de datos más pequeño para validar el modelo ( $h = 9$ ), la ANN sigue siendo superior a los enfoques tradicionales e híbridos.

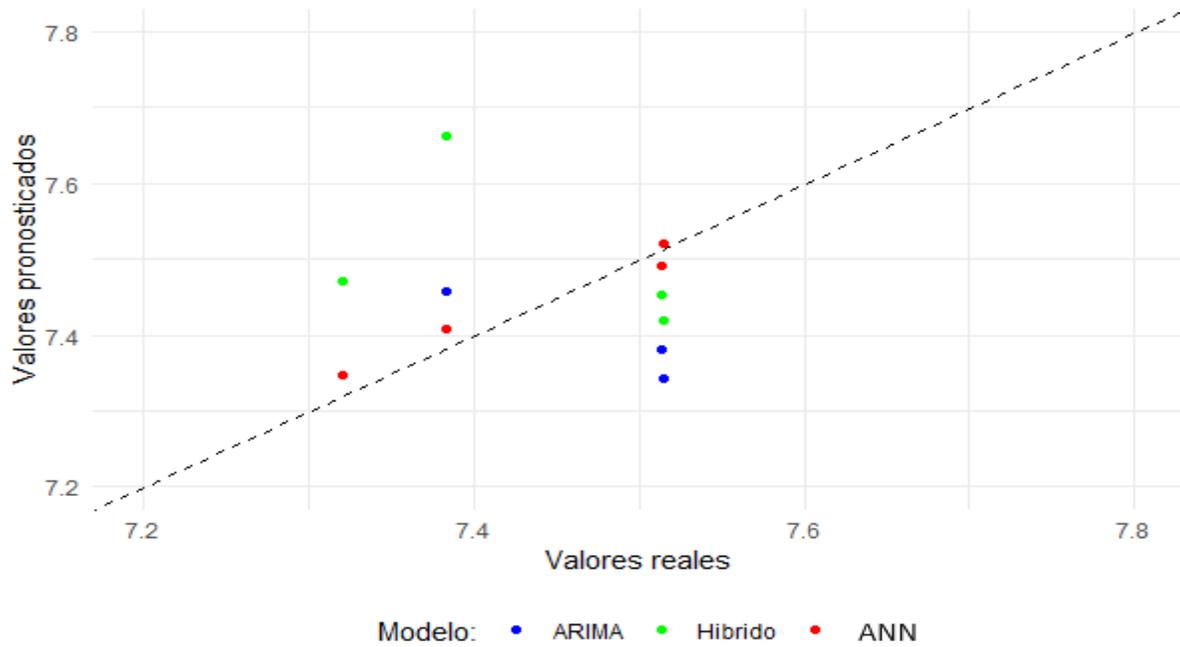
Figura 3.19: Comparación del valor real vs pronosticado para cada enfoque de modelado considerando un horizonte de 9 semanas



Fuente: Elaboración propia.

**Horizonte de 4 semanas:** En la Figura 3.20 se observa que los valores pronosticados de la ANN se ajustan de manera correcta a la curva de 45 grados, siguiendo el mismo comportamiento que dicha recta. Por tanto considerando un horizonte de 4 semanas para validar el modelo y 588 para entrenar éste, la red neuronal arroja resultados más satisfactorios.

Figura 3.20: Comparación del valor real vs pronosticado para cada enfoque de modelado considerando un horizonte de 4 semanas



Fuente: Elaboración propia.

# Discusión

Después de aplicar las metodologías para modelar los *casos de IRA* en la ciudad de Montería, en el periodo 2012-2023 usando un enfoque de series de tiempo tradicional, red neuronal artificial y un modelo híbrido, se obtiene evidencia convincente de que los modelos de red neuronal no solo superan significativamente al enfoque tradicional e híbrido en términos de precisión de pronóstico, sino que también demuestra un desempeño adecuado para modelar este tipo de datos. Este resultado concuerda con lo encontrado con Jiménez *et al.* (2019) y Tsan *et al.* (2022), donde los modelos de red neuronal tienen mejor desempeño en comparación con otros enfoques. Además, los hallazgos de este trabajo, coinciden con los resultados obtenidos en los estudios realizado por Cogollo *et al.* (2021) y Hassan (2021). En dichos estudios, se aplicó un enfoque *ANN* para modelar casos de enfermedades relacionadas al IRA, encontrando que dicho modelo tiene una buena precisión para pronosticar este tipo de enfermedades. Esta consistencia o coherencia en los resultados fortalece la robustez y la aplicabilidad de las redes neuronales artificiales para pronosticar a corto alcance los casos de IRA lo cual, respalda la revisión sistemática de literatura realizada por Santangelo *et al.* (2023), donde los modelos *ANN* demuestran ser la elección más utilizada en la actualidad para capturar el comportamiento de enferme-

dades respiratorias.

Por otra parte, se ha comprobado que los modelos híbridos pueden mejorar significativamente la precisión de los pronósticos en comparación con los modelos tradicionales y *ANN*, gracias a la ventaja de combinar un enfoque lineal con uno no lineal, lo cual ha sido demostrado en estudios realizados por Perone (2021) y Jin *et al.* (2023). Sin embargo, es de destacar un hallazgo particular en este estudio, donde se evidenció que los modelos híbridos propuestos para modelar los *casos de IRA* no mejoran la precisión del pronóstico. Este hallazgo, aunque es inusual se ha presentando en otros estudios, tales como los realizados por Safi y Sanusi (2021) y Demir y Kirisci (2022). Los cuales muestran que no siempre el modelo híbrido es el enfoque que mejor rendimiento arroja para modelar casos relacionados a dicha enfermedad. Este resultado resalta la importancia de la evaluación cuidadosa de los métodos de pronósticos, puesto que este dependerá de las características de los datos y las particularidades de cada caso.

# Conclusiones y recomendaciones

## 3.5.1. Conclusiones

En este trabajo se consideraron diferentes enfoques de modelado de series temporales para pronosticar a corto alcance los *casos de IRA* en la ciudad de Montería, durante el periodo 2012-2023. Estos enfoques incluyeron tanto métodos tradicionales, redes neuronales artificiales y la combinación de estos, tales como los modelos híbridos. A lo largo de este análisis, se demostraron una serie de aspectos fundamentales que ayudan a orientar la selección entre estos métodos, así como también las ventajas y limitaciones de éstos, teniendo en cuenta las características específicas de los datos y los objetivos de predicción.

Adicionalmente, a partir de los procesos de modelado realizados, bajo los tres enfoques, se puede concluir lo siguiente:

- En general, en el proceso de evaluación, se probó que el modelo de Redes Neuronales Artificiales (*ANN*) es más eficaz para pronosticar los *casos de IRA*, en comparación con los modelos tradicionales y los métodos híbridos, para cualquier horizonte de pronóstico. Demostrando así, su capacidad para capturar patrones no lineales y complejos en los datos.

- Para cada horizonte de pronóstico se demostró que independientemente de cual sea el enfoque que se use, entre más datos se tenga para entrenar el modelo, mejores serán los resultados en la evaluación de desempeño. Lo cual argumenta la idea de que estos enfoques son relevante en aplicaciones que requieren una visión de pronóstico a corto plazo.
- En particular para los modelos tradicionales se mostró que la función automática (*autoarima*) funciona mejor cuando la serie temporal no presenta tendencia ni estacionalidad. Para los horizontes en que había presencia de dichos componentes, la búsqueda manual arrojó mejores resultados.
- Se determinó que los modelos de redes neuronales a pesar de que son susceptibles al sobreajuste y requieren mayor tiempo computacional, específicamente para los horizontes en que se tienen más datos para entrenar, éste modela de manera satisfactoria el número de *casos de IRA* en la ciudad de Montería, siempre y cuando se les suministren los valores de los parámetros de manera adecuada. Al respecto, se comprobó que la función de activación *relu* y el numero de rezagos a considerar como variables de entrada, son los valores que ejercen mayor influencia significativa en la eficacia de un modelo predictivo, sin despreciar la relevancia de otros parámetros.

### 3.5.2. Recomendaciones

Con base en los hallazgos de este estudio y la importancia de un pronóstico preciso se recomienda, que para futuros estudios relacionados al modelado de *casos de IRA* en la ciudad de Montería, entrenar el modelo *ANN* considerando mínimo 575 semanas

epidemiológicas para entrenar la red y un conjunto de datos de prueba de 17,9 semanas con el fin de obtener no solo un pronóstico preciso sino consistente. Como trabajo futuro se considera el ajuste y evaluación de modelos que consideren variables exógenas para pronosticar los *casos de IRA* en la ciudad de Montería.

# Referencias

Alsuwaylimi, A. A. (2023). Comparison of arima, ann and hybrid arima-ann models for time series forecasting.

ArunKumar, K., Kalaga, D. V., Kumar, C. M. S., Chilkoor, G., Kawaji, M., y Brenza, T. M. (2021). Forecasting the dynamics of cumulative covid-19 cases (confirmed, recovered and deaths) for top-16 countries using statistical machine learning models: Auto-regressive integrated moving average (arima) and seasonal auto-regressive integrated moving average (sarima). *Applied soft computing*, 103, 107161.

Assad, D., Cara, J., y Ortega-Mier, M. a. (2022). Comparing short-term univariate and multivariate time-series forecasting models in infectious disease outbreak. *Bulletin of Mathematical Biology*. Descargado de <https://doi.org/10.1007/s11538-022-01112-5>  
doi: 10.1007/s11538-022-01112-5

Ballesteros, F., y Cogollo, M. (2023). Estructuras híbridas para el modelado y pronóstico de series temporales: metodologías y aplicaciones.

Becerra, M., Jerez, A., Aballay, B., Garcés, H. O., y Fuentes, A. (2020). Forecasting emergency admissions due to respiratory diseases in high variability scenarios using time

- series: A case study in chile. *Science of The Total Environment*, 706, 134978. Descargado de <https://www.sciencedirect.com/science/article/pii/S0048969719349708> doi: <https://doi.org/10.1016/j.scitotenv.2019.134978>
- Behar, R. (2003). Prevención de las infecciones respiratorias agudas. presente y futuro. *Revista Cubana de Pediatría*, 75(4), 1-10.
- Box, G. E., Jenkins, G. M., Reinsel, G. C., y Ljung, G. M. (2015). *Time series analysis: forecasting and control*. John Wiley & Sons.
- Chambi, J., y Conde, S. (2021). Modelo de predicción mensual de infección respiratoria aguda (ira) en niños menores de 5 años en la micro red el descanso–cusco, 2014-2019.
- Cogollo, M. R., González-Parra, G., y Arenas, A. J. (2021). Modeling and forecasting cases of rsv using artificial neural networks. *Mathematics*, 9(22), 2958.
- Demir, I., y Kirisci, M. (2022). Forecasting covid-19 disease cases using the sarima-nnar hybrid model. *Universal Journal of Mathematics and Applications*, 5(1), 15–23.
- Giustolisi, O., y Laucelli, D. (2005). Improving generalization of artificial neural networks in rainfall–runoff modelling/amélioration de la généralisation de réseaux de neurones artificiels pour la modélisation pluie-débit. *Hydrological Sciences Journal*, 50(3).
- González-Bandala, D. A., Cuevas-Tello, J. C., Noyola, D. E., Comas-García, A., y García-Sepúlveda, C. A. (2020). Computational forecasting methodology for acute respiratory infectious disease dynamics. *International Journal of Environmental Research and Public Health*, 17(12). Descargado de <https://www.mdpi.com/1660-4601/17/12/4540> doi: 10.3390/ijerph17124540

- Hajirahimi, Z., y Khashei, M. (2019). Hybrid structures in time series modeling and forecasting: A review. *Engineering Applications of Artificial Intelligence*, 86, 83–106.
- Hassan, M. Y. (2021). The deep learning lstm and mtd models best predict acute respiratory infection among under-five-year old children in somaliland. *Symmetry*, 13(7). Descargado de <https://www.mdpi.com/2073-8994/13/7/1156> doi: 10.3390/sym13071156
- Haykin, S. S. (1999). *Neural networks: A comprehensive foundation*..
- Huertas, N., G, Donado Torres, S., y cols. (2018). Evaluación crítica de la función autoarima de r en la identificación de procesos de series de tiempo.
- Hyndman, R., y Athanasopoulos, G. (2018). *Forecasting: Principles and practice* (2nd ed.). Australia: OTexts.
- Instituto Nacional de Salud. (2022). *Protocolo de vigilancia de infección respiratoria aguda (ira)*. [https://www.ins.gov.co/buscador-eventos/Lineamientos/PRO\\_IRA.pdf](https://www.ins.gov.co/buscador-eventos/Lineamientos/PRO_IRA.pdf). (Accessed: 2023-08-11)
- Jenkins, G. M., Box, G. E., y Reinsel, G. C. (2011). *Time series analysis: forecasting and control* (Vol. 734). John Wiley & Sons.
- Jerónimo-Martínez, L., Menéndez, R. E., y Bolívar, H. (2017). Forecasting acute respiratory infection cases in southern bogota: Ears vs. arima and sarima. , 1-6.
- Jiménez, M., y cols. (2019). Aplicación de analítica de datos para predicción de infección respiratoria aguda en colombia.

- Jin, Y.-C., Cao, Q., Wang, K.-N., Zhou, Y., Cao, Y.-P., y Wang, X.-Y. (2023). Prediction of covid-19 data using improved arima-lstm hybrid forecast models. *IEEE Access*, 11, 67956-67967. doi: 10.1109/ACCESS.2023.3291999
- Kelleher, J. D. (2019). *Deep learning*. MIT press.
- Knief, U., y Forstmeier, W. (2021). Violating the normality assumption may be the lesser of two evils. *Behavior Research Methods*, 53(6), 2576–2590.
- Mansbach, J. M., y Camargo, C. A. (2012). Acute respiratory infections. En A. A. Litonjua (Ed.), *Vitamin d and the lung: Mechanisms and disease associations* (pp. 181–200). Totowa, NJ: Humana Press. Descargado de [https://doi.org/10.1007/978-1-61779-888-7\\_9](https://doi.org/10.1007/978-1-61779-888-7_9) doi: 10.1007/978-1-61779-888-7\_9
- Montano, J., Palmer, A., y Munoz, P. (2011). Artificial neural networks applied to forecasting time series. *Psicothema*, 23, number=2, pages= 322-329 .
- Nsoesie, E. O., Oladeji, O., Abah, A. S. A., y Ndeffo-Mbah, M. L. (2021). Forecasting influenza-like illness trends in cameroon using google search data. *Scientific Reports*, 11(1), 6713.
- Ospina, R., Gondim, J. A. M., Leiva, V., y Castro, C. (2023). An overview of forecast analysis with arima models during the covid-19 pandemic: Methodology and case study in brazil. *Mathematics*, 11(14). Descargado de <https://www.mdpi.com/2227-7390/11/14/3069> doi: 10.3390/math11143069
- Peña, D. (2005). *Análisis de series temporales*. Alianza editorial.

- Peña, M. (2014). Análisis de series temporales utilizando modelos arima y su aplicación en la predicción de indicadores del ministerio de salud en el departamento de santa ana. *Trabajo de investigación*.
- Perone, G. (2021, 08). Comparison of arima, ets, nnar, tbats and hybrid models to forecast the second wave of covid-19 hospitalizations in italy. *The European Journal of Health Economics*, 23. doi: 10.1007/s10198-021-01347-4
- RStudio. (2021). Rstudio: Integrated development environment for r [Manual de software informático]. Boston, MA. Descargado de <https://www.rstudio.com/> (Version 4.1.1)
- Safi, S. K., y Sanusi, O. I. (2021). A hybrid of artificial neural network, exponential smoothing, and arima models for covid-19 time series forecasting. *Model Assisted Statistics and Applications*, 16(1), 25–35.
- Santangelo, O. E., Gentile, V., Pizzo, S., Giordano, D., y Cedrone, F. (2023). Machine learning and prediction of infectious diseases: A systematic review. *Machine Learning and Knowledge Extraction*, 5(1), 175–198. Descargado de <https://www.mdpi.com/2504-4990/5/1/13> doi: 10.3390/make5010013
- Secretaría de Salud y Seguridad Social de Montería. (2022). *Análisis de situación de salud con el modelo de los determinantes sociales de salud del municipio de montería, 2021*. <https://www.monteria.gov.co/loader.php?lServicio=Tools2&lTipo=descargas&lFuncion=descargar&idFile=2219>. (Accessed: 2023-08-11)

- Serikov, T., Zhetpisbayeva, , khmediyarova, A., Mirzakulova, S., Kismanova, A., Tolegenova, A., y Wójcik, W. (2021). City backbone network traffic forecasting. *International Journal of Electronics and Telecommunications*, 319–324.
- SIVIGILA. (2023). *Sistema de vigilancia en salud publica. estadísticas de vigilancia rutinaria*. <https://portalsivigila.ins.gov.co/Paginas/Vigilancia-Rutinaria.aspx>. (Accessed: 2023-08-11)
- Tsan, Y.-T., Chen, D.-Y., Liu, P.-Y., Kristiani, E., Nguyen, K. L. P., y Yang, C.-T. (2022). The prediction of influenza-like illness and respiratory disease using lstm and arima. *International Journal of Environmental Research and Public Health*, 19(3), 1858.
- Tsay, R. S., y Tiao, G. C. (1984). Consistent estimates of autoregressive parameters and extended sample autocorrelation function for stationary and nonstationary arma models. *Journal of the American Statistical Association*, 79(385), 84-96. doi: 10.1080/01621459.1984.10477068
- Wang, L., Zou, H., Su, J., Li, L., y Chaudhry, S. (2013). An arima-ann hybrid model for time series forecasting. *Systems Research and Behavioral Science*, 30(3), 244–259.
- Yang, L., Li, G., Yang, J., Zhang, T., Du, J., Liu, T., ... others (2023). Deep-learning model for influenza prediction from multisource heterogeneous data in a megacity: Model development and evaluation. *Journal of Medical Internet Research*, 25, e44238.
- Yu, G., Feng, H., Feng, S., Zhao, J., y Xu, J. (2021). Forecasting hand-foot-and-mouth disease cases using wavelet-based sarima–nnar hybrid model. *PLoS one*, 16(2), e0246673.

Yunseo, K., Bin, K. S., y Munyoung, Y. J.-H. M. S.-K. C. (2022). Machine learning models for predicting the occurrence of respiratory diseases using climatic and air-pollution factors. *Clin Exp Otorhinolaryngol*, 15(2), 168-176. Descargado de <http://www.e-ceo.org/journal/view.php?number=799> doi: 10.21053/ceo.2021.01536