

Predicción con modelo ARIMA en series temporales de *Salmonella spp* en Chile entre 2014-2022

Nicolas Ayala-Aldana

nayalaaldana@gmail.com

<https://orcid.org/0000-0002-3530-6734>

Departamento de Genética, Microbiología y Estadística.
Facultad de Biología. Universidad de Barcelona.
Barcelona, España.

Antonio Monleon-Getino

amonleong@ub.edu

<https://orcid.org/0000-0001-8214-3205>

Departamento de Genética, Microbiología y Estadística.
Facultad de Biología. Universidad de Barcelona.
Barcelona, España.

Jaume Canela-Soler

jcanela@ub.edu

<https://orcid.org/0000-0002-3280-6899>

Escuela de Medicine y Ciencias de la Salud, Hospital Clínic.
Universidad de Barcelona.
Barcelona, España.

Erika Retamal-Contreras

eretamal@utalca.cl

<https://orcid.org/0000-0002-5112-181X>

Departamento de Salud Pública, Facultad de Ciencias de la Salud.
Universidad de Talca.
Talca, Chile

Correspondencia: ciro. nayalaaldana@gmail.com

Artículo recibido 25 diciembre 2022 Aceptado para publicación: 25 enero 2023

Conflictos de Interés: Ninguna que declarar

Todo el contenido de **Ciencia Latina Revista Científica Multidisciplinar**, publicados en este sitio están disponibles bajo

Licencia [Creative Commons](https://creativecommons.org/licenses/by/4.0/) 

Cómo citar: Ayala-Aldana, N., Monleon-Getino, A., Canela-Soler, J., & Retamal-Contreras, E. (2023). Predicción con modelo ARIMA en series temporales de *Salmonella spp* en Chile entre 2014-2022. *Ciencia Latina Revista Científica Multidisciplinar*, 7(1), 1337-1351. https://doi.org/10.37811/cl_rcm.v7i1.4484

RESUMEN

Introducción. Las Enfermedades Transmitidas por Alimentos (ETA), constituyen un problema de salud pública de relevancia mundial, siendo motivo de vigilancia epidemiológica y son el resultado del consumo de alimentos que contienen toxinas o microorganismos patógenos vivos. El objetivo de este estudio es analizar las series temporales de *Salmonella spp.* para el periodo 2014-2022 en Chile y desarrollar un modelo predictivo de Media Móvil Autorregresiva (ARIMA). Métodos. Se realizó una descomposición de la serie para estudiar tendencia y estacionalidad. Se utilizó la prueba de Dickey-Fuller para estacionalidad y Kruskal-Wallis para comparación de grupos. Se aplicó el modelo ARIMA para realizar una predicción de casos en un año adelante. Resultados. La serie de estudio para *Salmonella spp.* tuvo un comportamiento estacional sin diferencias significativas entre grupos (periodos). El modelo ARIMA tuvo un buen desempeño para predecir casos en una serie continua. Conclusiones. El análisis de series temporales en epidemiología es una herramienta valiosa para prever futuros brotes o epidemias en el territorio nacional. El modelo ARIMA tiene un buen desempeño en la serie estacional analizada para *Salmonella spp.* en muestras de deposición.

Palabras clave: *salmonella; series temporales; ARIMA.*

Prediction with ARIMA model in time series of *Salmonella spp* in Chile between 2014-2022

ABSTRACT

Introduction. Foodborne Diseases (ETA) constitute a public health problem of worldwide relevance, being a reason for epidemiological surveillance. ETA are the result of the consumption of foods that contain toxins or pathogenic microorganisms. The objective of this study is to analyze the time series of *Salmonella spp.* for 2014-2022 in Chile and to perform a predictive model of Autoregressive Moving Average (ARIMA). Methods. The decomposition of the series was performed to study trends and seasonality. The Dickey-Fuller test was used for seasonality and the Kruskal-Wallis test for group comparison. The ARIMA model was applied to make a prediction of cases in a year ahead. Results. The study series for *Salmonella spp.* had a seasonal performance without significant differences between groups (periods). The ARIMA model performed well in predicting cases in a continuous series. Conclusions. The analysis of time series in epidemiology is a valuable tool to anticipate future outbreaks or epidemics in the national territory. The ARIMA model has a satisfactory performance in the seasonal series analyzed for *Salmonella spp* in deposition samples.

Keywords: *salmonella; time series; ARIMA.*

INTRODUCCIÓN

Las Enfermedades Transmitidas por Alimentos (ETA) constituyen una patología gastrointestinal de tipo infecciosa que se caracteriza por diarrea aguda, fiebre y dolor abdominal. Puede ser ocasionada por virus, bacterias y hongos transmitidos por vía fecal-oral a través de la ingestión de patógenos que se encuentran en agua potable insegura, alimentos contaminados o manos sucias (Gut et al., 2018). Los agentes etiológicos bacterianos más frecuentes pueden ser *Campylobacter spp.*, *Escherichia Coli*, *Shigella spp.* y *Salmonella spp.* Las bacterias del género *Salmonella* son bacterias Gram negativas de la familia de las enterobacterias que puede ocasionar desde una enfermedad diarreica aguda hasta fiebres entéricas que podría tener un desenlace fatal en grupos de riesgo de la población (Lamas et al., 2018).

Las ETA como fenómeno epidemiológico son objeto de vigilancia, estudio y control por parte de los centros de investigación epidemiológica y entidades gubernamentales. Según la Organización Mundial de la Salud (OMS) se estima que en el mundo enferman dos mil millones personas por ETA y la gastroenteritis es la segunda causa de enfermedad prevenible y una de las principales causas de muerte en niños menores de cinco años. Esta situación se agrava en países con menores ingresos o con dificultades de acceso a la atención los recintos asistenciales (Odeyemi, 2016; Popa & Popa, 2021).

En el hemisferio sur, los resultados de la vigilancia de las ETA muestran una alta incidencia entre los meses de noviembre y abril. El análisis de series temporales es una herramienta que otorga información relevante para caracterizar los periodos con mayor cantidad de contagios y generar estrategias para su prevención. Con el avance de la tecnología, se han implementado modelos predictivos, con cálculos computacionales, que se utilizan para predecir casos de gastroenteritis a nivel nacional e internacional (Martin-Moreno et al., 2022; Payedimarri et al., 2021). Algunos de los modelos predictivos más utilizados son modelos de regresiones lineales, regresión local polinomial (LOESS), medias móviles ponderadas, vectores autorregresivos (VAR) y también las herramientas de aprendizaje supervisado como Tree Decision, Random Forest y Redes Neuronales (Benedick et al., 2021; Du et al., 2021; C. C. Yang, 2022).

En este estudio se evalúa el desempeño de un modelo con Media Móvil Integrada Autorregresiva (ARIMA), con enfoque univariado, para comprender y predecir los casos

de gastroenteritis causados por *Salmonella spp.* para la serie temporal 2014-2022 en Chile.

METODOLOGÍA

Área de Estudio

Estudio descriptivo de corte transversal con análisis predictivo con un modelo ARIMA. Se ha realizado una tanda de entrenamiento con datos entre enero 2014 y diciembre 2020. La tanda de prueba contiene datos entre enero de 2021 y febrero de 2022 obtenidos en el repositorio abierto de datos del Instituto de Salud Pública (ISP) en Chile .

Se analizaron las series temporales para diagnóstico de *Salmonella spp.* para todo Chile en el periodo 2014-2022. En Chile, el diagnóstico de *Salmonella spp.* en deposiciones es un patógeno de vigilancia de laboratorio de notificación obligatoria, según decreto del Ministerio de Salud número 7. Reglamento sobre notificación de Enfermedades Transmisibles La detección de *Salmonella spp.* en muestras de deposiciones mediante coprocultivo se debe confirmar en el ISP para el control de enfermedades de notificación obligatoria. La especie del diagnóstico de Salmonella no está detallada en la base de datos del ISP por lo que se han utilizado los totales del género de la bacteria. Se utilizaron estadísticos de tendencia central como rango, cuartiles, mediana, media, desviación estándar y coeficiente de variación para caracterizar cada serie temporal.

Componentes de la serie de tiempo

Tendencia : La tendencia es un movimiento de valores más altos y valores más bajos durante un largo tiempo. Cuando los valores se dirigen hacia arriba en una serie de tiempo, se conoce como una tendencia al alza. Por el contrario, los patrones que disminuyen se conocen como tendencia a la baja.

Estacionalidad: La estacionalidad generalmente tiene oscilaciones hacia arriba o hacia abajo. Sin embargo, a diferencia del análisis de la tendencia ,la estacionalidad muestra un patrón repetido durante un período fijo.

En este caso, la prueba Dickey–Fuller fue utilizado para medir la estacionalidad en complemento a la descomposición gráfica (figura 2). La prueba de Kruskal-Wallis fue utilizada para comparar las series temporales. Para el análisis de las pruebas de hipótesis, se consideró una prueba significativa con un valor- $p < 0,05$.

Para predecir un análisis de series de tiempo, es crucial considerar la estacionariedad del conjunto de datos. Las series de tiempo requieren que los datos sean estacionarios, y es

imprescindible para el análisis. La estacionalidad tiene tres componentes: la media constante, la varianza constante y la autocovarianza que no depende del tiempo.

Modelo ARIMA

Los modelos ARIMA son una combinación de cálculos estocásticos utilizados para analizar series temporales. Para realizar la serie de tiempo en el modelo ARIMA, en primer lugar, los datos sin procesar deben estar listos y ejecutar algunas pruebas con los datos, como la prueba de Dickey-Fuller, para determinar la tendencia y encontrar las estadísticas móviles del conjunto de datos.

ARIMA es uno de los mejores modelos para datos de series temporales, que es la combinación de dos modelos. El modelo AR representa el componente autorregresivo y el modelo MA representa la media móvil. El modelo ARIMA tiene tres parámetros: "P" son los retrasos autorregresivos, "Q" es el promedio móvil y "d" es el orden de diferenciación. La ecuación del modelo ARIMA viene representada por:

$$Y_t = -(\Delta^d Y_t - Y_t) + \phi_0 + \sum_{i=1}^p \phi_i \Delta^d Y_t - Y_i - \sum_{i=1}^q \theta_i \varepsilon_{t-i} + \varepsilon_t$$

Donde d corresponde a las "d" diferencias para convertir la serie inicial en una serie estacionaria, " ϕ_1, \dots, ϕ_p " son los parámetros autorregresivos del modelo, " $\theta_1, \dots, \theta_p$ " son los parámetros de las medias móviles del modelo, " ϕ_0 " es una constante, y " ε_t " es el error o perturbación estocástica.

Para evaluar el desempeño del modelo ARIMA se utilizó la función "accuracy" del paquete "forecast". Se reportaron Error Medio (ME), Desviación Media Cuadrática (RMSE), Error Medio Absoluto (MAE), Porcentaje Medio de Error (MPE), Porcentaje Medio de Error Absoluto, error medio absoluto a escala (MASE) y Autocorrelación de error con 1 retraso (ACF1).

Los datos fueron analizados por el Software R-Studio (V. 4.0.2). Se utilizaron los paquetes "ggplot2" y "ggpubr" para visualización de gráficos y el paquete "forecast" para el análisis predictivo con el modelo ARIMA. Se utilizó la función "auto.arima" para modelar el modelo con mejor ajuste en el software.

RESULTADOS

En la tabla 1 se observan los estadísticos de tendencia central de las series temporales de *Salmonella spp.* entre 2014 y 2022 en Chile. La mayor cantidad de casos se observa en la serie de tiempo 2021 (2499) y la menor cantidad de casos se observa en la serie temporal

2017 (n=1719). Se observa un aumento sostenido de los casos desde el año 2018 hasta el 2021. La serie temporal 2021 y 2022 se utilizaron como series de prueba para evaluar el desempeño del modelo.

La serie temporal con menor variación de sus resultados fue 2021 (DE= 58,4 ; CV= 28). La prueba Dickey Fuller para evaluar estacionalidad tuvo un valor $p < 0.05$ por lo tanto se acepta la hipótesis alternativa que la serie tiene un componente estacional. No se observaron diferencias significativas en el total de casos confirmados de *Salmonella spp.* al comparar los años en estudio (valor- $p = 0,35$).

Tabla 1.

Descripción de serie temporal para confirmación de Salmonella spp. en Chile para el periodo 2014-2022.

Serie temporal	Total (n)	Min	Max	Q ₁	Q ₃	mediana	\bar{x}	DE	CV (%)	Diferencia
2014	2337	84	359	112,5	194,8	171	194,8	96,7	49,7	0
2015	2167	100	326	145,5	224,4	159,9	180,6	61,8	34,2	-171
2016	1944	86	300	101,8	216	114,5	162	80,3	49,5	-223
2017	1719	80	254	88,5	188	131	143,2	60,8	42,4	-225
2018	1937	95	249	121,5	194	158,5	161,4	50,9	31,5	+218
2019	2043	95	296	121	216,8	156	170,2	61,9	36,3	+106
2020	2264	81	395	112,5	246	163	188,7	97,4	51,6	+221
2021	2499	124	303	163,2	264	303	208,2	58,4	28,0	+235
2022	1212	98	289	179,8	228	211	202	63,9	31,6	*

Test de Hipótesis	Valor de la prueba	Valor p	Hipótesis Alternativa
Dickey-Fuller test	-7.69	0.01	Serie Temporal Estacionaria
Kruskall-Wallis	8.8079	0.35	Diferencia entre series anuales

Q: Cuartil ; *Incomparable por corresponder a una serie de 6 meses.

Figura 1.

Tendencia estacional para la serie temporal para muestras confirmadas de *Salmonella spp.* 2014-2022 en Chile.

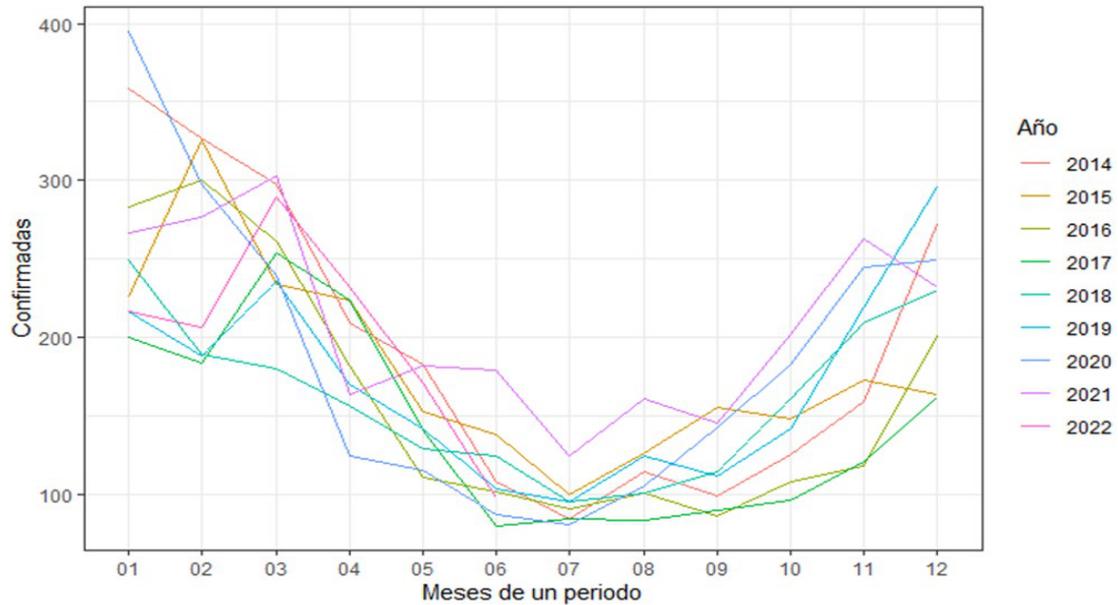
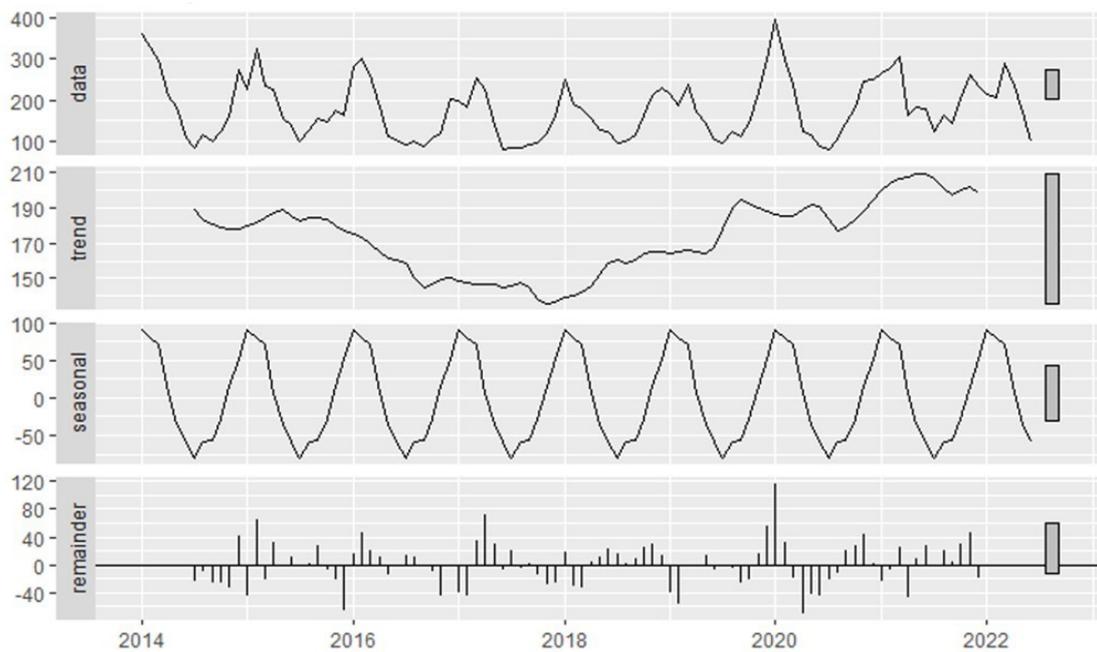


Figura 2.

Descomposición con Modelo Aditivo de series temporales para *Salmonella spp.* 2014-2022.

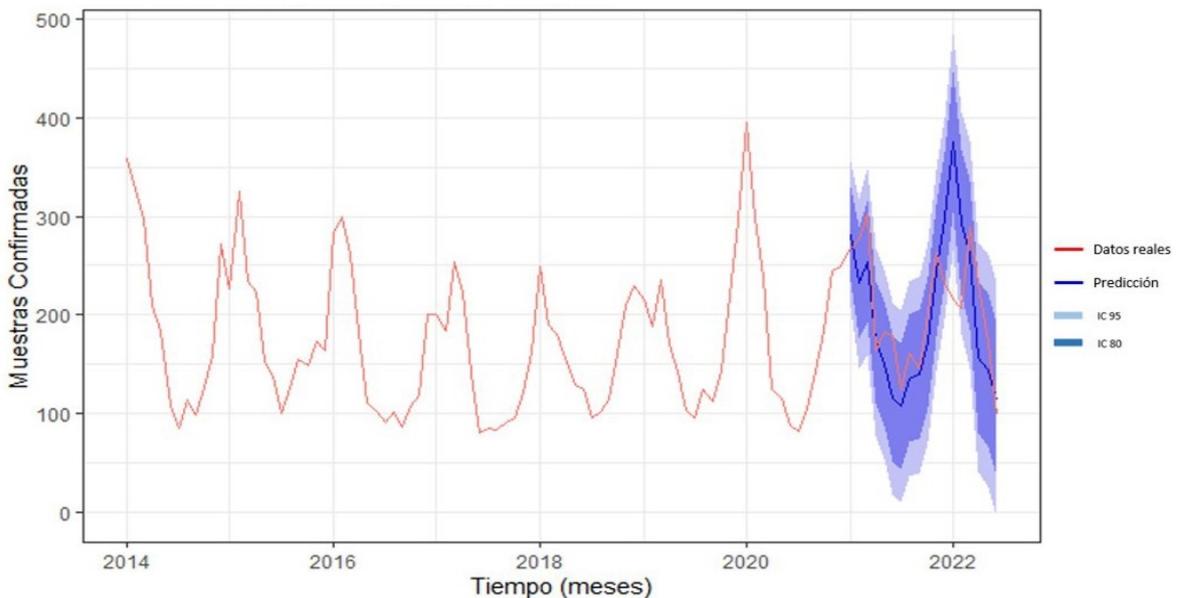


La representación gráfica del modelo se observa en la figura 3. Los casos reales (serie de prueba) tienen un comportamiento muy similar con la predicción que realizar el modelo excepto por el quiebre de notificación observado al finalizar el año 2021 que puede ser explicado por la disminución del reporte de casos en diciembre. Los valores netos se encuentran dentro del intervalo de confianza del método.

La tabla 2 muestra desempeño del método de predicción ARIMA para la serie temporal de *Salmonella spp.* El modelo tiene un muy buen desempeño en la serie de entrenamiento entre 2014 y 2020 (RMSE = 3,49 ; MAE; 1,05; MAPE= 0.51).

Figura 3

Serie temporal de Salmonella spp. 2014-2022 y predicción con modelo ARIMA.



Predicción para el modelo ARIMA (0,1,3)(1,1,0).

Tabla 2.

Desempeño para el modelo ARIMA (0,1,3)(1,1,0).

Serie test	ME	RMSE	MAE	MPE	MAPE	MASE	ACF1
Prueba (n= 14 meses)	-0.99	3.49	1.05	-0.48	0.51	0.01	0.06

ME: Error Medio; RMSE: Desviación Media Cuadrática ; MAE: Error Medio Absoluto ; MPE: Porcentaje Medio de Error ; MAPE: Porcentaje medio de error absoluto ; MASE: error medio absoluto a escala ; ACF1: Autocorrelación de error con 1 retraso (lag).

DISCUSIÓN

El diagnóstico de las ETA es relevante para realizar la búsqueda activa de casos y contactos en estudios epidemiológicos, para así planificar medidas preventivas para cortar la cadena de transmisión de la enfermedad, evitando el contagio. Las ETA pueden ser transmitidas por virus o bacterias y tienen una alta incidencia en el verano. Esto puede ser explicado por interrupciones en la cadena de frío que favorece la replicación bacteriana y la vida media de estas. *Salmonella spp.* se caracteriza por ser una bacteria termoestable y con una alta tasa de reproducción entre los 35 y 37°C (Fong & Wang, 2016; Gut et al., 2018; Huang, 2004; Y. Yang et al., 2014).

Además, producto de la mayor movilidad durante los meses de vacaciones de planteles educacionales y lugares de trabajo, aumenta el consumo de alimentos fuera del hogar ya sea, en restaurantes, servicios de alimentación que son posibles focos de preocupación para la propagación de ETA. Sería necesario promover diversas medidas preventivas en la comunidad, como la importancia del lavado de mano, educar en mecanismos de contagio, y control de la temperatura en la conservación de alimentos en los servicios alimentarios (Sánchez-Vargas et al., 2011).

En Chile, se ha observado una tendencia en el aumento del diagnóstico de Salmonelosis desde el 2018. Las explicaciones para este fenómeno podrían ser un aumento en el diagnóstico microbiológico, mayor conciencia clínica en la notificación y aumento en el número de brotes reportados para las series 2019, 2020 y 2021 por todos los enteropatógenos (Pública, 2019). La mayor cantidad de brotes reportados tienen origen en la venta de servicios alimentarios como cafeterías, restaurantes y concesionarias de cocina.

La salmonelosis y las ETA, en general, son patologías gastrointestinales altamente frecuentes en países industrializados. Estudios desarrollados en Asia en países como India, Mozambique, Bangladesh (Chao et al., 2019) y China (Xu et al., 2015) mostraron similares resultados para estacionalidad y presencia de *Salmonella spp.* y otros enteropatógenos. Casos reportados en países de Latinoamérica como Colombia (Calle et al., 2021) y Perú (Delahoy et al., 2021) reportaron una situación similar respecto a la estacionalidad de la *Salmonella spp.* y la alta incidencia del diagnóstico en meses cercanos al verano (noviembre-marzo). Misma situación de estacionalidad se observa en los estudios de Canadá (Thomas et al., 2013), Estados Unidos (Li et al., 2021; Naumova et al.,

2007) y México (Flores Monter et al., 2021) respecto a la alta incidencia de ETA o gastroenteritis en el verano del hemisferio norte (mayo-septiembre).

La diferencia de predicción del modelo en el mes de diciembre año 2021 puede ser explicado por el inicio de las vacaciones de verano, limitaciones en el acceso a los recintos asistenciales o el subdiagnóstico ocasionado por la pandemia del COVID-19 (Pública, 2019). Otros modelos que utilizan metodologías de media móvil, modelos de regresión o Machine Learning reportan resultados similares y con buen desempeño de las técnicas para diagnóstico de casos de *Salmonella spp* y contaminación de aguas por dicho patógeno (Akil & Ahmad, 2016; Vereen et al., 2013; Wang et al., 2021; Weller et al., 2020). Finalmente, el estudio de patologías con comportamiento estacional favorece una predicción efectiva y precisa de los resultados.

Limitaciones

El estudio de series temporales de *Salmonella spp.* para el periodo 2014-2022 recoge la información mensual de las muestras procesadas por el ISP en Chile. La limitación de este enfoque es que no permite generalizar cual es el comportamiento por ciudad o región, acceso a servicios básicos (agua y luz) y condiciones climáticas. En Chile cerca de 13,9% de la población no tiene acceso a agua potable y 14,6% vive en hogares hacinados, por tanto, sería relevante estudiar cómo influye la aparición de coliformes fecales en el abastecimiento de agua no convencional (Chile, 2020). Además, condiciones como temperaturas y contaminantes ambientales serían interesantes de analizar en el contexto de la crisis climática y el comportamiento de brotes de ETA. Además de considerar el aumento de venta de alimentos en vía pública. Respecto a las variables individualizadas, el estudio no reporta datos según sexo, edad o motivo de consulta. En futuras investigaciones se podría incluir para realizar un análisis multivariado con estos regresores y evaluar su correlación con la variable dependiente.

CONCLUSIONES.

El estudio de Enfermedades Transmitidas por Alimentos (ETA) es relevante como apoyo para la planificación, implementación, y evaluación de las acciones en Salud Pública en la Vigilancia Epidemiológica, el estudio de brotes, la promoción de medidas de autocuidado en la población, además de poner en alerta a los establecimientos asistenciales. Las ETA, generalmente, tienen un comportamiento estacionario que permite utilizar métodos predictivos robustos y confiables para resolver necesidades en la planificación asistencial

y fortalecimiento de las capacidades sanitarias , con el fin de mitigar los riesgos en la población.

Salmonella spp. es uno de los principales agentes causantes de ETA. Los resultados de este estudio concluyen que el diagnóstico de la bacteria en Chile tiene un comportamiento estacional y con tendencia al alza en el análisis de descomposición de casos a partir del año 2018 en la serie anual. El modelo ARIMA resultó ser altamente confiable para la predicción del diagnóstico 16 meses adelante desde (2021-2022). Los modelos predictivos pueden ser útiles para prevenir brotes epidémicos en épocas del año donde aumentan las temperaturas que favorecerían la proliferación bacteriana en alimentos, producción de enterotoxinas, facilitando el contagio y la morbilidad en la poblacional.

LISTA DE REFERENCIAS.

- Akil, L., & Ahmad, H. A. (2016). Salmonella infections modelling in Mississippi using neural network and geographical information system (GIS). *BMJ Open*, 6(3), e009255. <https://doi.org/10.1136/BMJOPEN-2015-009255>
- Benedick, P. lou, Robert, J., & Traon, Y. le. (2021). A Systematic Approach for Evaluating Artificial Intelligence Models in Industrial Settings. *Sensors (Basel, Switzerland)*, 21(18). <https://doi.org/10.3390/S21186195>
- Calle, A., Carrascal, A. K., Patiño, C., Carpio, C., Echeverry, A., & Brashears, M. (2021). Seasonal effect on Salmonella, Shiga toxin-producing E. coli O157:H7 and non-O157 in the beef industry in Colombia, South America. *Heliyon*, 7(7), e07547. <https://doi.org/10.1016/J.HELIYON.2021.E07547>
- Chao, D. L., Roose, A., Roh, M., Kotloff, K. L., & Proctor, J. L. (2019). The seasonality of diarrheal pathogens: A retrospective study of seven sites over three years. *PLOS Neglected Tropical Diseases*, 13(8), e0007211. <https://doi.org/10.1371/JOURNAL.PNTD.0007211>
- Chile, BCN. B. del C. N. de. (2020). *Reportes Estadísticos Biblioteca del Congreso Nacional de Chile*. <https://www.bcn.cl/siit/reportescomunales/>
- Delahoy, M. J., Cárcamo, C., Huerta, A., Lavado, W., Escajadillo, Y., Ordoñez, L., Vasquez, V., Lopman, B., Clasen, T., Gonzales, G. F., Steenland, K., & Levy, K. (2021). Meteorological factors and childhood diarrhea in Peru, 2005–2015: a time series analysis of historic associations, with implications for climate change.

- Environmental Health: A Global Access Science Source*, 20(1), 1–10.
<https://doi.org/10.1186/S12940-021-00703-4/TABLES/3>
- Du, Y., Wang, H., Cui, W., Zhu, H., Guo, Y., Dharejo, F. A., & Zhou, Y. (2021). Foodborne Disease Risk Prediction Using Multigraph Structural Long Short-term Memory Networks: Algorithm Design and Validation Study. *JMIR Medical Informatics*, 9(8). <https://doi.org/10.2196/29433>
- Flores Monter, Y. M., Chaves, A., Arellano-Reynoso, B., López-Pérez, A. M., Suzán-Azpiri, H., & Suzán, G. (2021). Edaphoclimatic seasonal trends and variations of the *Salmonella* spp. infection in Northwestern Mexico. *Infectious Disease Modelling*, 6, 805. <https://doi.org/10.1016/J.IDM.2021.05.002>
- Fong, K., & Wang, S. (2016). Heat resistance of *Salmonella enterica* is increased by pre-adaptation to peanut oil or sub-lethal heat exposure. *Food Microbiology*, 58, 139–147. <https://doi.org/10.1016/J.FM.2016.04.004>
- Gut, A. M., Vasiljevic, T., Yeager, T., & Donkor, O. N. (2018). *Salmonella* infection – Prevention and treatment by antibiotics and probiotic yeasts: A review. *Microbiology (United Kingdom)*, 164(11), 1327–1344. <https://doi.org/10.1099/MIC.0.000709/CITE/REFWORKS>
- Huang, L. (2004). Thermal Resistance of *Listeria monocytogenes*, *Salmonella* Heidelberg, and *Escherichia coli* O157:H7 at Elevated Temperatures. *Journal of Food Protection*, 67(8), 1666–1670. <https://doi.org/10.4315/0362-028X-67.8.1666>
- Lamas, A., Miranda, J. M., Regal, P., Vázquez, B., Franco, C. M., & Cepeda, A. (2018). A comprehensive review of non-enterica subspecies of *Salmonella enterica*. *Microbiological Research*, 206, 60–73. <https://doi.org/10.1016/J.MICRES.2017.09.010>
- Li, X., Singh, N., Beshearse, E., Blanton, J. L., DeMent, J., & Havelaar, A. H. (2021). Spatial Epidemiology of Salmonellosis in Florida, 2009–2018. *Frontiers in Public Health*, 8, 1001. <https://doi.org/10.3389/FPUBH.2020.603005/BIBTEX>
- Martin-Moreno, J. M., Alegre-Martinez, A., Martin-Gorgojo, V., Alfonso-Sanchez, J. L., Torres, F., & Pallares-Carratala, V. (2022). Predictive Models for Forecasting Public Health Scenarios: Practical Experiences Applied during the First Wave of the COVID-19 Pandemic. *International Journal of Environmental Research and Public Health*, 19(9), 5546. <https://doi.org/10.3390/IJERPH19095546>

- Naumova, E. N., Jagai, J. S., Matyas, B., DeMaria, A., MacNeill, I. B., & Griffiths, J. K. (2007). Seasonality in six enterically transmitted diseases and ambient temperature. *Epidemiology and Infection*, 135(2), 281. <https://doi.org/10.1017/S0950268806006698>
- Odeyemi, O. A. (2016). Public health implications of microbial food safety and foodborne diseases in developing countries. *Food & Nutrition Research*, 60(1). <https://doi.org/10.3402/FNR.V60.29819>
- Payedimarri, A. B., Concina, D., Portinale, L., Canonico, M., Seys, D., Vanhaecht, K., & Panella, M. (2021). Prediction models for public health containment measures on covid-19 using artificial intelligence and machine learning: A systematic review. *International Journal of Environmental Research and Public Health*, 18(9), 4499. <https://doi.org/10.3390/IJERPH18094499/S1>
- Popa, G. L., & Popa, M. I. (2021). Salmonella spp. infection - a continuous threat worldwide. *Germs*, 11(1), 88. <https://doi.org/10.18683/GERMS.2021.1244>
- Pública, I. de S. (2019). Boletín Epidemiológico Trimestral. Brotes de Enfermedades Transmitidas por Alimentos (ETA). *Ministerio de Salud, Chile*, 1(1), 12. http://epi.minsal.cl/wp-content/uploads/2020/02/BET_ETA_2019.pdf
- Sánchez-Vargas, F. M., Abu-El-Haija, M. A., & Gómez-Duarte, O. G. (2011). Salmonella infections: An update on epidemiology, management, and prevention. *Travel Medicine and Infectious Disease*, 9(6), 263–277. <https://doi.org/10.1016/J.TMAID.2011.11.001>
- Thomas, J. L., Slawson, R. M., & Taylor, W. D. (2013). Salmonella serotype diversity and seasonality in urban and rural streams. *Journal of Applied Microbiology*, 114(3), 907–922. <https://doi.org/10.1111/JAM.12079>
- Vereen, E., Lowrance, R. R., Jenkins, M. B., Adams, P., Rajeev, S., & Lipp, E. K. (2013). Landscape and seasonal factors influence Salmonella and Campylobacter prevalence in a rural mixed use watershed. *Water Research*, 47(16), 6075–6085. <https://doi.org/10.1016/J.WATRES.2013.07.028>
- Wang, H., Cui, W., Guo, Y., Du, Y., & Zhou, Y. (2021). Machine Learning Prediction of Foodborne Disease Pathogens: Algorithm Development and Validation Study. *JMIR Medical Informatics*, 9(1). <https://doi.org/10.2196/24924>

- Weller, D. L., Love, T. M. T., Belias, A., & Wiedmann, M. (2020). Predictive Models May Complement or Provide an Alternative to Existing Strategies for Assessing the Enteric Pathogen Contamination Status of Northeastern Streams Used to Provide Water for Produce Production. *Frontiers in Sustainable Food Systems*, 4, 151. <https://doi.org/10.3389/FSUFS.2020.561517/BIBTEX>
- Xu, Z., Hu, W., Zhang, Y., Wang, X., Zhou, M., Su, H., Huang, C., Tong, S., & Guo, Q. (2015). Exploration of diarrhoea seasonality and its drivers in China. *Scientific Reports*, 5. <https://doi.org/10.1038/SREP08241>
- Yang, C. C. (2022). Explainable Artificial Intelligence for Predictive Modeling in Healthcare. *Journal of Healthcare Informatics Research*, 6(2), 228. <https://doi.org/10.1007/S41666-022-00114-1>
- Yang, Y., Khoo, W. J., Zheng, Q., Chung, H. J., & Yuk, H. G. (2014). Growth temperature alters Salmonella Enteritidis heat/acid resistance, membrane lipid composition and stress/virulence related gene expression. *International Journal of Food Microbiology*, 172, 102–109. <https://doi.org/10.1016/J.IJFOODMICRO.2013.12.006>