

Análisis de series de tiempo de casos de dengue en la región de la Huasteca Time series analysis of dengue cases in the Huasteca region

A. Pontón-Gallardo-Rodríguez ^a, Roberto Ávila-Pozos ^b

^aMaestría en Física y Tecnología Avanzada, Área Académica de Matemáticas y Física, Universidad Autónoma del Estado de Hidalgo, 42184, Pachuca, Hidalgo, México.

^bÁrea Académica de Matemáticas y Física, Universidad Autónoma del Estado de Hidalgo, 42184, Pachuca, Hidalgo, México.

Resumen

En este trabajo se presenta un análisis de las series de tiempo de los casos registrados de dengue en tres estados de la República Mexicana en donde se encuentra la región conocida como la Huasteca. Se comparan los modelos que se obtienen empleando los datos anuales, mensuales y semanales de estos tres estados. Se obtiene un modelo vectorial autoregresivo, que da cuenta de la relación entre los datos de estos tres estados que comparten características ambientales y sociodemográficas en la región de la Huasteca. Al final, se presentan pronósticos que se obtienen empleando modelos autorregresivos integrados de medias móviles, que proyectan el número de posibles casos de dengue en cada uno de los estados bajo estudio.

Palabras Clave: Series de tiempo, pronóstico, dengue, modelos estadísticos

Abstract

This paper presents an analysis of the time series of registered cases of dengue fever in three states of the Mexican Republic where the region known as the Huasteca is located. The models obtained using annual, monthly and weekly data from these three states are compared. An autoregressive vector model is obtained, which shows the relationship between the data of these three states that share environmental and sociodemographic characteristics in the Huasteca region. Finally, forecasts are presented using autoregressive integrated moving average models, which project the number of possible dengue cases in each of the states under study.

Keywords: Time series, forecast, dengue, statistical models.

1. Introducción

En el ámbito de la salud pública el dengue se ha convertido en un importante desafío en los últimos años, debido a su rápida expansión y a la gravedad en los brotes que causa. Esta enfermedad, transmitida por mosquitos, ha afectado a millones de personas alrededor del mundo, provocando un alto número de hospitalizaciones e incluso la muerte. El número de infectados por esta enfermedad ha aumentado a nivel mundial en las últimas décadas, pasando de afectar a 505,430 personas en el año 2000 a más de 3,312,040 casos en 2015 (Naher et al., 2022), afectando principalmente a regiones tropicales y subtropicales, pues su prevalencia se ve influenciada por factores climáticos como la humedad, la temperatura y las precipitaciones, así como por la densidad de población y los movimientos humanos (Cortes et al., 2018). La falta de una vacuna específica y trata-

mientos eficaces dificulta aún más la gestión de esta enfermedad (Polwiang, 2020). Por eso, es importante abordar el dengue como un desafío de salud pública e implementar estrategias de prevención efectivas y desarrollar métodos de control para reducir el impacto del dengue en la población.

En 1963 el dengue en México había sido erradicado gracias a distintas medidas de control, (control físico, control biológico y control químico) como la aplicación de insecticida a ultra bajo volumen y el control epidemiológico, así como el incremento en los servicios de agua potable y drenaje (Narro and Gómez, 1995). Sin embargo, algunas de estas medidas fueron retiradas, provocando el resurgimiento de la enfermedad en 1978. Para 1984 se reportaron 5000 casos, dando inicio a una nueva era de desafíos en la lucha contra el dengue en México. Entre los años 2000 y 2012, la enfermedad del dengue creció abruptamente en México, donde se reportaron un total de 502,804 casos de fiebre

*Autor para correspondencia: ravila@uaeh.edu.mx

Correo electrónico: po295884@uaeh.edu.mx (A. Pontón-Gallardo-Rodríguez), ravila@uaeh.edu.mx (Roberto Ávila-Pozos)

Historial del manuscrito: recibido el 27/09/2024, última versión-revisada recibida el 16/01/2025, aceptado el 04/02/2025, publicado el 26/04/2025. DOI: <https://doi.org/10.29057/icbi.v13iEspecial.13860>



del dengue, y 75,000 casos de fiebre hemorrágica del dengue, DF y DHF por sus siglas en inglés, en todo el país. Las regiones ubicadas en zonas tropicales y subtropicales fueron las más afectadas, pues las condiciones ambientales originaron un entorno idóneo para la proliferación del mosquito vector y la transmisión del virus del dengue (Danis-Lozano et al., 2019).

Actualmente, el dengue es un tema importante de salud pública en los estados de San Luis Potosí, Hidalgo y Veracruz, pues estos estados comparten características climatológicas, estando ubicados en regiones subtropicales de México, experimentan un clima cálido durante gran parte del año y son áreas propensas a recibir altos niveles de precipitación en épocas de lluvia. En las figuras 1, 2, y 3, mostramos los casos registrados de dengue en estos tres estados, desde el año 2003. La diferencia en estas tres gráficas, es que en la primera, la información está reportada por años; en la segunda por mes, y en la última, por semana. Cada una de estas gráficas es una serie de tiempo distinta. En las gráficas se aprecia que Veracruz lidera con una mayor escala, seguido por San Luis Potosí y, por último, Hidalgo, lo cual podría reflejar diferencias en la densidad poblacional de los estados. Sin embargo, note que en el año 2019, las tres entidades registraron un pico en el número de casos. Observe que en los casos de Veracruz e Hidalgo, las variaciones en el número de casos son muy similares en los registros mensuales y semanales, mientras que los casos registrados en San Luis Potosí muestran una variación de menor magnitud en la ventana de tiempo que estamos analizando.

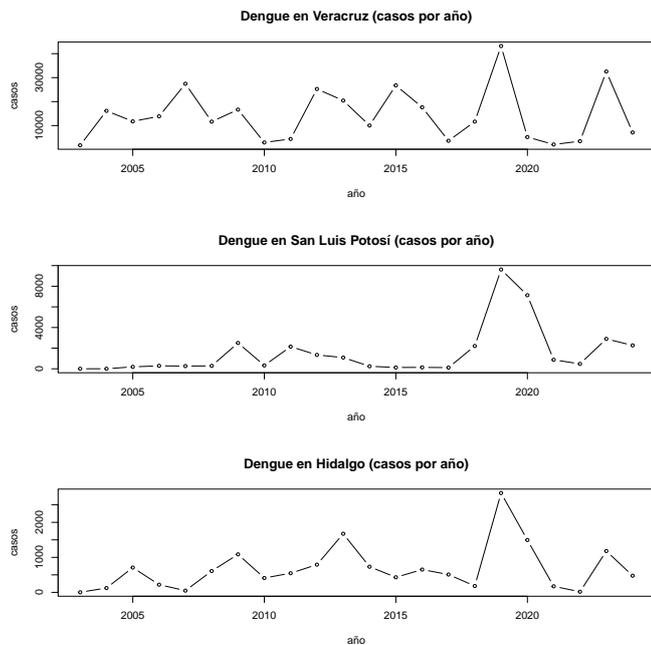


Figura 1: Casos registrados de dengue, por año, para los estados de Veracruz, San Luis Potosí e Hidalgo, desde 2003. Fuente: Dirección General de Epidemiología (DGE)

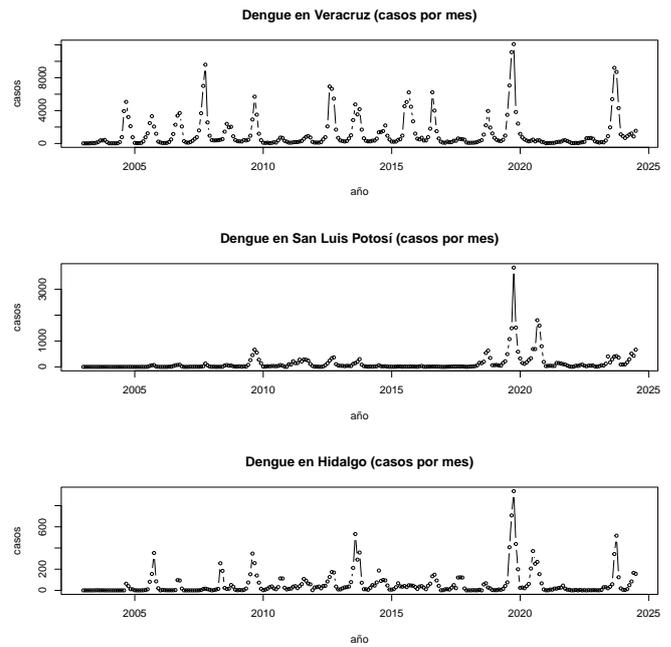


Figura 2: Casos registrados de dengue, por mes, para los estados de Veracruz, San Luis Potosí e Hidalgo, desde 2003. Fuente: DGE

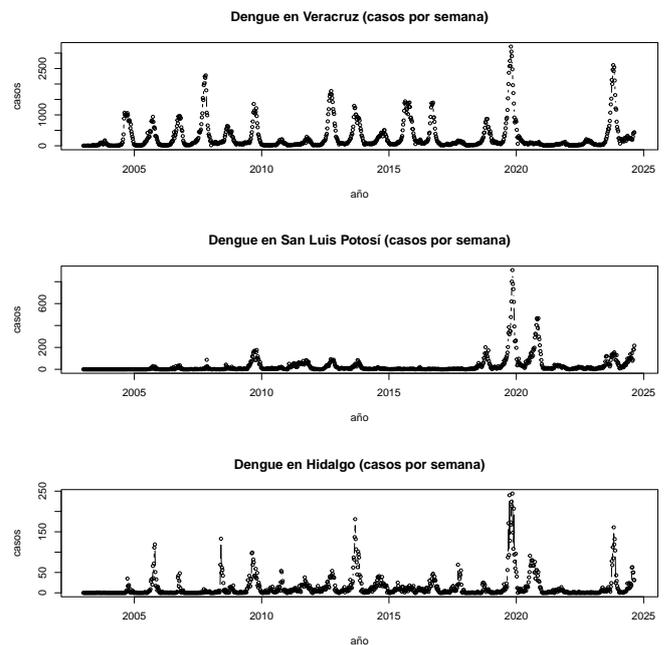


Figura 3: Casos registrados de dengue, por semana, para los estados de Veracruz, San Luis Potosí e Hidalgo, desde 2003. Fuente: DGE

Ante esta problemática, se ha intensificado la investigación en modelos estadísticos especialmente en el estudio de la epidemiología de enfermedades infecciosas. Es fundamental comprender la evolución temporal del dengue para implementar estrategias efectivas de prevención y control. El análisis de series de tiempo nos permite analizar la dinámica de propagación

de esta enfermedad y prever posibles brotes. El análisis de series de tiempo se ha utilizado para estudiar enfermedades como el sarampión, infecciones intestinales (Allard, 1998), influenza (Reintjes et al., 2016) y, recientemente, la COVID 19 (Kumar and Susan, 2020). El uso de técnicas de análisis de series de tiempo como los modelos ARMA (Autorregresivo de Medias Móviles), ARIMA (Autorregresivo Integrado de Medias Móviles) y SARIMA (Autorregresivo Integrado de Medias Móviles Estacional), son herramientas necesarias en la predicción de la propagación del dengue, permitiendo anticipar la frecuencia y gravedad de posibles epidemias. Los modelos ARIMA y SARIMA, son casos particulares de los modelos ARMA.

Estos modelos, ofrecen herramientas poderosas para mejorar la preparación y respuesta ante brotes de dengue ya que permiten analizar la tendencia y la estacionalidad de los datos de incidencia de esta enfermedad (Naher et al., 2022). Dado el carácter cambiante en el tiempo y la presencia de patrones estacionales, es viable el uso de series de tiempo para facilitar el análisis del comportamiento del dengue (Othman et al., 2022). El modelo ARMA se destaca como una técnica popular en la investigación de ciencias de la salud para este propósito.

El objetivo principal de este artículo es realizar un estudio sobre la evolución del dengue en los estados de Hidalgo, San Luis Potosí y Veracruz. Con el fin de comprender mejor la dinámica de esta enfermedad infecciosa en estas regiones, se aplicará el modelo ARIMA para analizar y predecir los patrones de incidencia del dengue a lo largo del tiempo. Este modelo combina dos componentes principales: la autorregresión (AR), que captura la relación entre una observación y un número determinado de observaciones anteriores, y la media móvil (MA), que modela la relación entre una observación y los errores residuales de predicciones anteriores.

Esta investigación busca proporcionar información valiosa que pueda contribuir a la mejora de las estrategias de control y prevención del dengue en áreas geográficas específicas, así como a la implementación de medidas más efectivas para mitigar su impacto en la salud pública. El modelo ARMA es aplicado para analizar la incidencia de la enfermedad a lo largo del tiempo. Al utilizar datos históricos de casos de dengue, este modelo permite identificar patrones estacionales, tendencias a largo plazo y variaciones aleatorias en la evolución de la enfermedad. Una vez ajustado el modelo ARMA a los datos disponibles, se pueden realizar predicciones sobre el comportamiento futuro del dengue.

2. Material y Métodos

Una secuencia de variables aleatorias $\{Y_t : t = 0, \pm 1, \pm 2, \dots\}$ se conoce como proceso estocástico, y sirve como un modelo para una serie de tiempo. Se sabe que la estructura probabilística completa de tal proceso está determinada por el conjunto de distribuciones de toda la colección finita de Y 's. Afortunadamente, no se requiere tratar explícitamente con esas distribuciones multivariadas. Gran parte de la información en esas distribuciones conjuntas pueden describirse en términos de medias, varianzas y covarianzas.

Consideremos la situación más sencilla, donde asumimos una función media μ_t . El modelo puede escribirse como

$$Y_t = \mu_t + X_t \tag{1}$$

donde $E[X_t] = 0$, siendo $\mu_t = E[Y_t]$, el valor esperado del proceso estocástico Y_t , y $E[X_t]$ el valor esperado del proceso estocástico X_t .

Considere la tendencia determinista expresada como

$$\mu_t = \beta_0 + \beta_1 t. \tag{2}$$

La suposición más general si los datos tienen un comportamiento estacional es que se propongan parámetros constantes $(\beta_1, \beta_2, \dots, \beta_{12})$. En este caso, la tendencia estacional se puede escribir como

$$\mu_t = \begin{cases} \beta_1 & \text{para } t = 1, 13, 25, \dots \\ \beta_2 & \text{para } t = 2, 14, 26, \dots \\ \vdots & \vdots \\ \beta_{12} & \text{para } t = 12, 24, 36, \dots \end{cases} \tag{3}$$

La componente estocástica X_t se puede estimar mediante el residual $\hat{X}_t = Y_t - \hat{\mu}_t$. Si la tendencia del modelo es razonablemente correcta, los residuales deberían tener el comportamiento del verdadero componente estocástico.

Una herramienta de diagnóstico muy importante para examinar la dependencia es la función de autocorrelación. Si suponemos que la serie de tiempo es estacionaria, es decir, se tiene una media y varianza común para la serie, se puede definir la función de autocorrelación muestral como

$$r_k = \frac{\sum_{t=k+1}^n (Y_t - \bar{Y})(Y_{t-k} - \bar{Y})}{\sum_{t=1}^n (Y_t - \bar{Y})^2} \tag{4}$$

Decimos que un proceso $\{Y_t\}$ es un proceso lineal, si puede ser representado como una combinación lineal, ponderada, de términos de ruido blanco presentes y pasados

$$Y_t = e_t + \psi_1 e_{t-1} + \psi_2 e_{t-2} + \dots \tag{5}$$

con la condición de que

$$\sum_{i=1}^{\infty} \psi_i^2 < \infty \quad \text{con} \quad \psi_j = \phi^j, \quad \phi \in [0, 1]$$

donde e_1, e_2, \dots, e_t es una secuencia de variables aleatorias independientes, idénticamente distribuidas, con media cero y varianza σ_e^2 .

Para este caso,

$$E[Y_t] = 0, \quad \gamma_k = Cov(Y_t, Y_{t-k}) = \sigma_e^2 \sum_{i=0}^{\infty} \psi_i \psi_{i+k} \quad k \geq 0$$

Es importante notar que un proceso estocástico definido de esta manera, es un proceso estacionario, donde la estructura de autocovarianza depende sólo del desfase temporal y no del tiempo absoluto (Shumway et al., 2000).

2.1. *Proceso de medias móviles*

En el caso en el que sólo un número finito de pesos ψ sean distintos de cero, tenemos lo que es llamado proceso de media móvil. En este caso escribimos

$$Y_t = e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} + \dots - \theta_q e_{t-q} \quad (6)$$

A esta serie le llamamos proceso de media móvil de orden q , y la denotamos por $MA(q)$. Los modelos de medias móviles fueron introducidos por Slutsky en 1927 y por Wold en 1938 (Cryer and Chan, 2008).

Para el proceso general $MA(q)$, presentado en la ecuación 6, se puede mostrar que

$$\gamma_0 = (1 + \theta_1^2 + \theta_2^2 + \dots + \theta_q^2)\sigma_e^2$$

y

$$\rho_k = \begin{cases} \frac{-\theta_k + \theta_1\theta_{k+1} + \theta_2\theta_{k+2} + \dots + \theta_{q-k}\theta_q}{1 + \theta_1^2 + \theta_2^2 + \dots + \theta_q^2} & \text{para } k = 1, \dots, q \\ 0 & \text{para } k > q \end{cases}$$

La función de autocorrelación corta después del retardo q , puesto que a partir del siguiente retardo, la función vale cero.

2.2. *Proceso autorregresivo*

El proceso autorregresivo de orden p satisface la ecuación

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + e_t \quad (7)$$

El valor actual de la serie Y_t es una combinación lineal de los p valores más recientes. Para cada t , se asume que e_t es independiente de $Y_{t-1}, Y_{t-2}, Y_{t-3}, \dots$. El trabajo original de Yule, publicado en 1926 es el primer modelo autorregresivo (Cryer and Chan, 2008).

Consideremos el polinomio característico el modelo dado en la ecuación 7

$$\phi(x) = 1 - \phi_1 x - \phi_2 x^2 + \dots - \phi_p x^p$$

Decimos que una serie de tiempo $\{Y_t\}$ se puede representar mediante una modelo integrado autorregresivo de medias móviles (ARIMA), si la d -ésima diferencia $W_t = \nabla^d Y_t$ es un proceso estacionario autorregresivo de medias móviles (ARMA). Si $\{W_t\}$ se representa con un modelo $ARMA(p, q)$, se dice que el proceso $\{Y_t\}$ es un proceso $ARIMA(p, d, q)$.

Los modelos $ARIMA(p, q, d)$ pueden operar en series de tiempo tanto estacionarias como no estacionarias, ya que incluyen el proceso de estabilización de la serie por medio del parámetro d , que representa el grado de diferenciación aplicado a la serie. Los órdenes (p, q) , corresponden al modelo autorregresivo AR y al modelo de medias móviles MA, respectivamente.

Dado que se requiere determinar el orden de los modelos autorregresivos, se introduce una función definida como la correlación entre Y_t y Y_{t-k} , después de remover el efecto de las variables $Y_{t-1}, Y_{t-2}, \dots, Y_{t-k+1}$. Este coeficiente se conoce como autocorrelación parcial al retardo k , y se denota por ϕ_{kk} .

La función de autocorrelación parcial, definida como

$$\phi_{kk} = \frac{\rho_k - \sum_{j=1}^{k-1} \phi_{k-1,j} \rho_{k-j}}{1 - \sum_{j=1}^{k-1} \phi_{k-1,j} \rho_j}, \quad (8)$$

donde $\phi_{k,j} = \phi_{k-1,j} - \phi_{kk} \phi_{k-1,k-j}$, para $j = 1, 2, \dots, k-1$.

3. **Resultados**

En la figura 4 se muestra la descomposición de la serie de tiempo anual para el estado de Veracruz, suponiendo que tiene una forma como la que se describe en la ecuación 1 (Lütkepohl, 2005). La descomposición se realiza usando la función VARselect de R (Pfaff, 2008). Esta función estima un modelo vectorial autorregresivo por mínimos cuadrados ordinarios (MCO). El modelo es de la siguiente forma:

$$Y_t = A_1 Y_{t-1} + A_2 Y_{t-2} + \dots + A_p Y_{t-p} + CD_t + u_t \quad (9)$$

donde Y_t es el vector de variables endógenas y u_t es el término aleatorio. En este caso, las variables endógenas son el número de casos confirmados y reportados de dengue.

En la parte superior de la gráfica se encuentran los datos de la serie de tiempo original (línea negra) y el ajuste con el modelo resultante (línea punteada azul). En la parte inferior de la gráfica se presentan la función de autocorrelación y la función de autocorrelación parcial (Hamilton, 2020). Los datos aquí mostrados son los mismos que se presentaron en la figura 1.

Estas gráficas son de gran relevancia, puesto que están relacionadas con el orden del modelo.

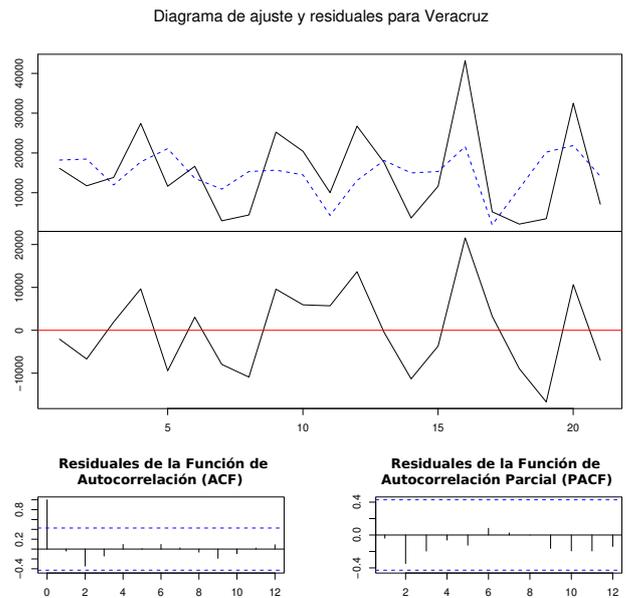


Figura 4: Ajuste del modelo según los datos anuales del estado de Veracruz.

	ar1	ar2	ma1
Parámetro	-0.2997	-0.4433	-1.0000
Error	0.2027	0.2091	0.1521

	ar1	ar2	ma1
Parámetro	0.0774	-0.3089	-0.8301
Error	0.2573	0.2319	0.2572

Tabla 1: Parámetros del modelo SARIMA para la serie temporal anual de Veracruz.

En la figura 5 se muestra la descomposición de la serie de tiempo anual para el estado de San Luis Potosí. La gráfica se obtiene al emplear la función VARselect de R (Pfaff, 2008).

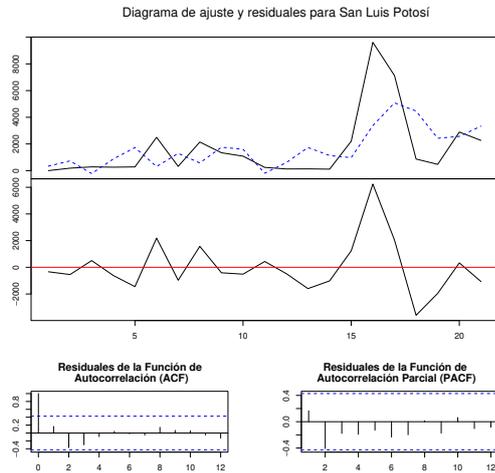


Figura 5: Ajuste del modelo según los datos anuales del estado de San Luis Potosí.

	ar1	ar2	ma1
Parámetro	0.6169	-0.3363	-0.8877
Error	0.2357	0.2093	0.2078

Tabla 2: Parámetros del modelo SARIMA para la serie temporal anual de San Luis Potosí.

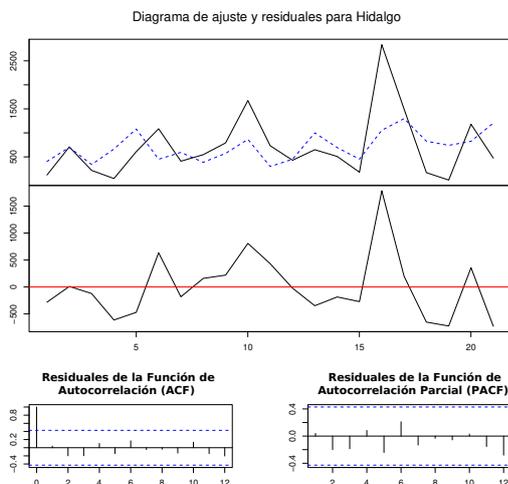


Figura 6: Ajuste del modelo según los datos anuales del estado de Hidalgo.

Tabla 3: Parámetros del modelo SARIMA para la serie temporal anual de Hidalgo.

De manera similar, en la figura 6 se muestra la descomposición de la serie de tiempo anual para el estado de Hidalgo. La gráfica se obtiene al emplear la función VARselect de R (Pfaff, 2008).

Note las similitudes en estas tres gráficas en las funciones de autocorrelación y autocorrelación parcial (Hyndman, 2014).

En la figura 7 se presenta la descomposición de la serie de tiempo mensual para el estado de Veracruz. La gráfica se obtiene al emplear la función VARselect de R (Pfaff, 2008). Note que la serie de tiempo consta de más valores, si se compara con el caso anual. Observe también la diferencia en las gráficas de la función de autocorrelación y la función de autocorrelación parcial. Este incremento en el número de datos se refleja en un mejor ajuste del modelo, con su correspondiente serie de tiempo. Para los casos de San Luis Potosí e Hidalgo, los resultados son similares.

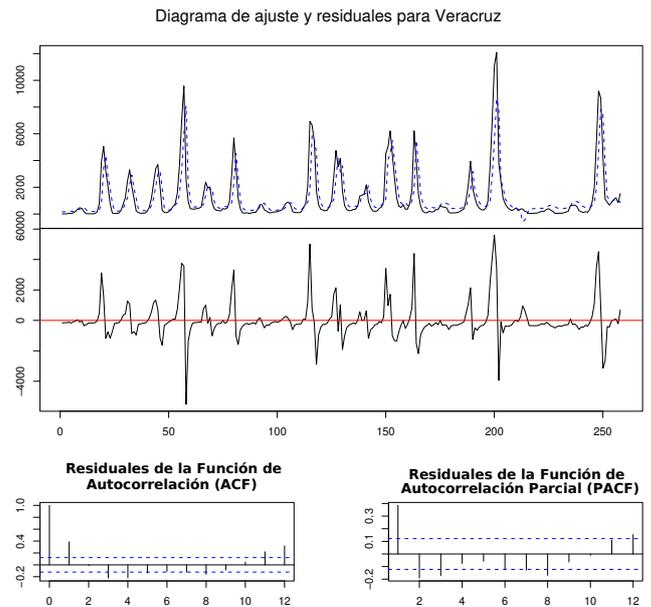


Figura 7: Ajuste del modelo según los datos mensuales del estado de Veracruz.

	ar1	ar2	ma1	sar1	sma1
Parámetro	1.0066	-0.2857	-1.0000	0.0024	-1.0000
Error	0.0621	0.0620	0.0206	0.0696	0.0450

Tabla 4: Parámetros del modelo SARIMA para la serie temporal mensual de Veracruz

Si observamos los resultados para las series de tiempo con información semanal, el número de datos también se incremen-

ta, por lo que el modelo resulta ser un mejor ajuste que el mostrado en el caso anual. La figura 8 presenta el resultado de usar la función VARselect con los datos semanales del estado de Hidalgo.

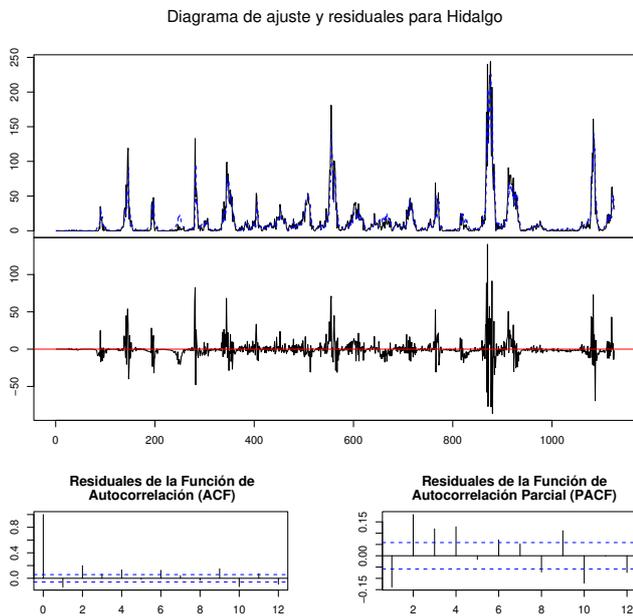


Figura 8: Ajuste del modelo según los datos semanales del estado de Hidalgo.

Parámetro	ar1	ar2	ma1	sar1	sma1
Parámetro	-0.2997	-0.4433	-1.0000	0.0669	-1.0000
Error	0.2027	0.2091	0.1521	0.0330	0.0386

Tabla 5: Parámetros del modelo SARIMA para la serie temporal semanal de Hidalgo.

Las tablas 1, 2, y 3 presentan los parámetros estimados de los modelos SARIMA (2,1,1) ajustados a diferentes series de tiempo. En cada tabla, ar1, ar2, ma1, representan los coeficientes del modelo autoregresivo de primer y segundo orden, y el coeficiente de media móvil de primer orden, respectivamente. Adicionalmente, en las tablas 4 y 5, sar1 y sma1 se refieren a los coeficientes estacionales de los componentes autoregresivo y de media móvil. En cada tabla se indican los coeficientes estimados para cada término, así como los errores asociados a estas estimaciones.

Las figuras 9, 10 y 11, muestran los datos anuales, mensuales y semanales, respectivamente, para los tres estados en donde se encuentra la región de la Huasteca. Además, en la parte final de la gráfica se presenta un pronóstico que se obtiene al emplear la función forecast de R (Hyndman, 2018). Esta función recibe como argumento un modelo (que puede ser ARIMA o SARIMA).

La región sombreada corresponde al intervalo de confianza del pronóstico. Observe cómo este intervalo de confianza disminuye cuando se incrementa el número de datos con el que se

estiman los parámetros del modelo empleado para el pronóstico.

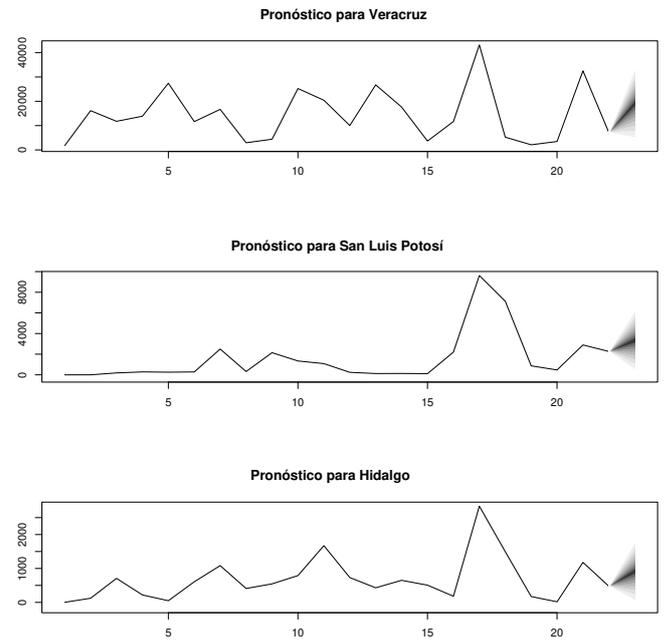


Figura 9: Pronósticos utilizando los datos anuales de los estados de Veracruz, San Luis Potosí e Hidalgo.

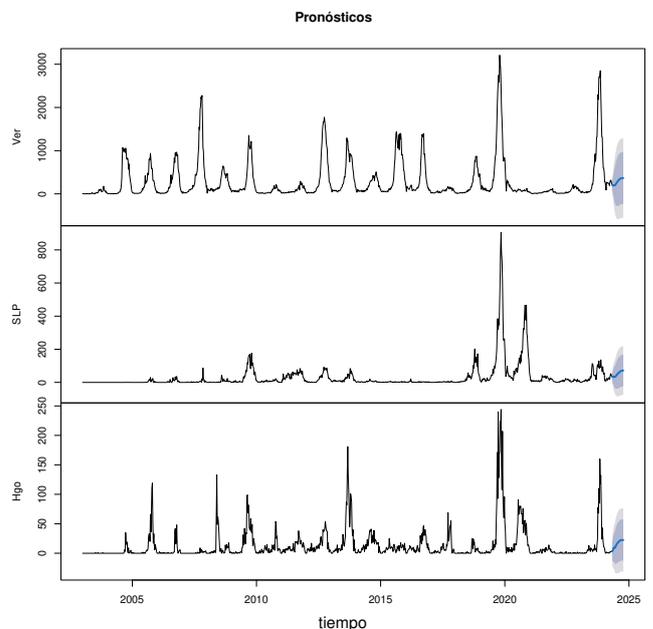


Figura 10: Pronósticos basados en la información mensual de los estados de Veracruz, San Luis Potosí e Hidalgo.

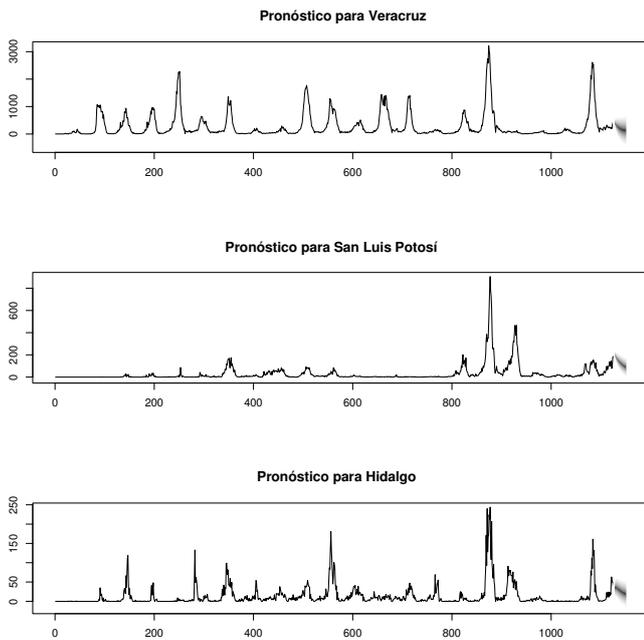


Figura 11: Pronósticos empleando los datos semanales de los estados de Veracruz, San Luis Potosí e Hidalgo.

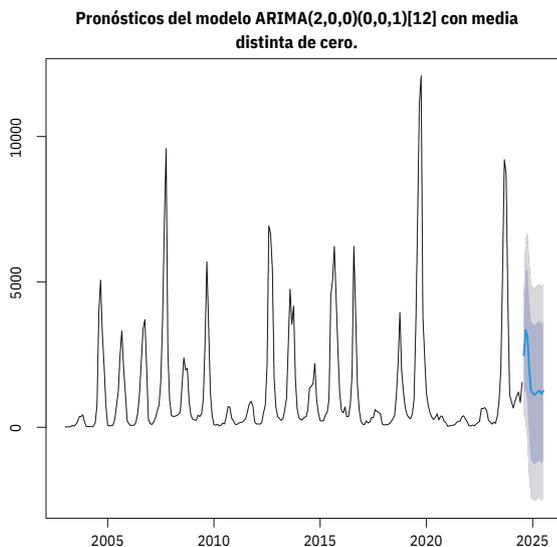


Figura 12: Pronóstico generado por el modelo $ARIMA(2,0,0)(0,0,1)$.

Finalmente, usando la función `auto.arima` de R (Hyndman and Khandakar, 2008; Shumway et al., 2000) se obtienen las gráficas de la figura 12. Esta función estima el mejor modelo ARIMA para un conjunto de datos, empleando dos criterios de información: Akaike y Bayesiano (Shmueli and Polak, 2024). El criterio de información de Akaike (AIC) es una medida de la calidad relativa de un modelo estadístico, mientras que el criterio de información Bayesiano (BIC) es un criterio para la selección de modelos entre un conjunto finito de modelos. La gráfica

de la figura 12 es un modelo autorregresivo de orden 2, integrado con un modelo de medias móviles de orden 1, por ello la notación $ARIMA(2,0,0)(0,0,1)$.

4. Discusión y conclusiones

Los resultados mostrados destacan la relevancia de llevar un registro sistemático de la información, para formar series de tiempo robustas que proporcionan información de la dependencia temporal de los casos de dengue. Debe destacarse la diferencia en los modelos que se obtienen para la información presentada por año, por mes o por semana epidemiológica. El modelo vectorial autorregresivo aquí presentado, relaciona la información de los casos registrados en tres estados que comparten características ambientales y sociodemográficas en una región particular (Sánchez-Hernández et al., 2021). Se puede observar que la ocurrencia de los picos de mayor número de casos en los tres estados, se presenta en el mismo año, y las variaciones observadas en el número de casos en otros años, es similar en las tres entidades, por lo que plantear un modelo vectorial para describir el número de casos en esta región resulta de utilidad para estudiar la ocurrencia de picos en la incidencia del dengue en la Huasteca.

Referencias

- Allard, R. (1998). Use of time-series analysis in infectious disease surveillance. *Bulletin of the World Health Organization*, 76(4):327.
- Cortes, F., Martelli, C. M. T., de Alencar Ximenes, R. A., Montarroyos, U. R., Junior, J. B. S., Cruz, O. G., Alexander, N., and de Souza, W. V. (2018). Time series analysis of dengue surveillance data in two brazilian cities. *Acta tropica*, 182:190–197.
- Cryer, J. and Chan, K.-S. (2008). *Time Series Analysis with Applications in R*. Springer, New York.
- Danis-Lozano, R., Díaz-González, E. E., Malo-García, I. R., Rodríguez, M. H., Ramos-Castañeda, J., Juárez-Palma, L., Ramos, C., López-Ordóñez, T., Mosso-González, C., and Fernández-Salas, I. (2019). Vertical transmission of dengue virus in aedes aegypti and its role in the epidemiological persistence of dengue in central and southern mexico. *Tropical Medicine & International Health*, 24:1311–1319.
- Hamilton, J. D. (2020). *Time series analysis*. Princeton university press.
- Hyndman, R. (2014). Better acf and pacf plots, but no optimal linear prediction. *Electronic Journal of Statistics [E]*, 8(2):2296–2300.
- Hyndman, R. (2018). *Forecasting: principles and practice*. OTexts.
- Hyndman, R. J. and Khandakar, Y. (2008). Automatic time series forecasting: the forecast package for r. *Journal of statistical software*, 27:1–22.
- Kumar, N. and Susan, S. (2020). Covid-19 pandemic prediction using time series forecasting models. In *2020 11th international conference on computing, communication and networking technologies (ICCCNT)*, pages 1–7. IEEE.
- Lütkepohl, H. (2005). *New introduction to multiple time series analysis*. Springer Science & Business Media.
- Naher, S., Rabbi, F., Hossain, M., Banik, R., Pervez, S., and Boitchi, A. (2022). Forecasting the incidence of dengue in bangladesh—application of time series model. *Health Science Reports*, 5:e666.
- Narro, J. and Gómez, H. (1995). El dengue en México: un problema prioritario de salud pública. *Salud Pública de México*, 37(Su1):12–20.
- Othman, M., Indawati, R., Suleiman, A. A., Qomaruddin, M. B., and Sokkalingam, R. (2022). Model forecasting development for dengue fever incidence in surabaya city using time series analysis. *Processes*, 10(11).
- Pfaff, B. (2008). Var, svar and svec models: Implementation within r package vars. *Journal of statistical software*, 27:1–32.
- Polwiang, S. (2020). The time series seasonal patterns of dengue fever and associated weather variables in Bangkok (2003-2017). *BMC Infectious Diseases*, 20.
- Reintjes, R., Das, E., Klemm, C., Richardus, J. H., Keßler, V., and Ahmad, A. (2016). “pandemic public health paradox”: time series analysis of the

- 2009/10 influenza a/h1n1 epidemiology, media attention, risk perception and public reactions in 5 european countries. *PloS one*, 11(3):e0151258.
- Sánchez-Hernández, D., Aguirre-Salado, C. A., Sánchez-Díaz, G., Aguirre-Salado, A. I., Soubervielle-Montalvo, C., Reyes-Cárdenas, O., Reyes-Hernández, H., and Santana-Juárez, M. V. (2021). Modeling spatial pattern of dengue in north central mexico using survey data and logistic regression. *International Journal of Environmental Health Research*, 31(7):872–888.
- Shmueli, G. and Polak, J. (2024). *Practical time series forecasting with r: A hands-on guide*. Axelrod schnall publishers.
- Shumway, R. H., Stoffer, D. S., and Stoffer, D. S. (2000). *Time series analysis and its applications*, volume 3. Springer.