



Sexto
Congreso Nacional de
Riego, Drenaje y Biosistemas
COMEII- 2021 / Hermosillo, Sonora



Artículo: COMEII-21014

Hermosillo, Son., del 9 al 11 de junio de 2021

PRONÓSTICO DE TEMPERATURAS MÁXIMAS Y MÍNIMAS MENSUALES, CON SERIES DE TIEMPO PARA LA ESTACIÓN 09071, EN CDMX

**Rocio Cervantes-Osornio^{1*}; Ramón Arteaga Ramírez²; Lucía Victoria Carmona Mota;
Waldo Ojeda-Bustamante³; Osías Ruiz Álvarez¹**

¹ Instituto Nacional de Investigaciones Forestales Agrícolas y Pecuarias. Carretera México-Lechería, km 18.5 Chapingo, Estado de México C.P 56230 A.P.10, México.

rcervanteso@hotmail.com – 01 800 088 2222 85565 (*Autor de correspondencia)

² Departamento de Irrigación. Universidad Autónoma Chapingo, km 38.5 Carretera México-Texcoco, Chapingo, Estado de México. México.

³ Riego y Drenaje. Instituto Mexicano de Tecnología del Agua. Paseo Cuauhnáhuac 8532, Progreso, Jiutepec, Morelos, C.P. 62550. México.

Resumen

La variable temperatura resulta importante en diversas áreas, recientemente ha tomado importancia el conocer con cierto grado de anticipación su valor debido a los incrementos de esta, y su relación estrecha con el cambio climático. En el presente trabajo se desarrollaron dos modelos de series de tiempo para el pronóstico de promedios de temperaturas mensuales máximas y mínimas. Se analizaron datos de un periodo de 13 años de una estación en la alcaldía de Coyoacán, Ciudad de México y se realizó el pronóstico para 24 meses. De ambos modelos encontrados, el modelo de la temperatura mínima se ajustó mejor a los datos.

Palabras claves: pronóstico, series de tiempo, temperaturas



Introducción

Los pronósticos en series de tiempo tienen la tarea de conocer con anticipación algunos valores en el futuro, dada una secuencia de datos históricos de la misma señal o variable, y también se puede utilizar datos históricos de señales correlacionadas (Romeu *et al.*, 2013). Los datos de temperaturas mensuales siempre resultaran necesarios, tanto por los agricultores, como por el personal que toma decisiones: medioambientalistas, gobierno, etc. De igual manera la temperatura es importante porque influye en la tasa de respiración del suelo, en los cambios de fisiología de los cultivos y es una variable necesaria en el cálculo de la evapotranspiración de referencia (Ye *et al.*, 2013). Existen múltiples métodos de estimación y/o pronóstico de las temperaturas, desde los análisis de regresión múltiple (Flocas *et al.*, 1983), pasando por las series de Fourier y los modelos de series de tiempo, entre otros. En series de tiempo una variable es explicada por los valores anteriores de esa misma variable, siendo esta una particularidad de este tipo de modelación. Una característica de lo pronosticado, es que estos valores, van convergiendo a la media del proceso o de la serie.

El presente trabajo ajustó dos modelos ARMA de las respectivas variables de temperatura promedio mensuales máximas (T_{max}) y mínimas (T_{min}), con la finalidad de obtener un pronóstico de estas. Uno de los resultados obtenidos fue que el modelo encontrado con Stata para T_{min} ajustó mejor a la serie, con un RMSE de 0.927, a diferencia del ajuste para la T_{max} con un RMSE de 1.316.

Materiales y Métodos

Los datos analizados fueron obtenidos del Servicio Meteorológico Nacional de la estación 09071, ubicada en la alcaldía Coyoacán, de la CDMX, (latitud 19°20'02", longitud 099° 07' 36", altitud 2250 msnm).

Se utilizó un enfoque empírico para identificar el proceso estocástico que genera la serie de tiempo, a través del correlograma se identificó a cual proceso corresponde dicha serie, ya sea: AR(1), AR(2), ARMA(1,1), etc. Todos los procesos ARMA o ARIMA tienen un correlograma (Figura 1), y se utiliza éste para identificar qué proceso estocástico tuvieron las series, en este caso, de promedios mensuales de las temperaturas máximas y mínimas. Las series de datos presentaron datos faltantes, para solventarlo, dado que las series presentaban un comportamiento estacional cada doce meses, cíclico, se utilizó un modelo de regresión (con variables dummy), con este, se estimaron los datos faltantes de diciembre de 1988 a diciembre de 1989 (13 datos) y un dato de abril de 1990.

Fue necesario que las series, una vez rellenos los datos faltantes, cumplieran con el supuesto de estacionariedad, esto ayuda para que el número de parámetros del modelo del pronóstico sea el menor posible, es decir, se simplifique. Si la serie no es estacionaria, entonces hay que transformar esta (se aplica la operación de primeras diferencias o diferencia estacional). En el caso de la T_{min} resultó estacionaria, a diferencia de T_{max} . Para

probar estacionariedad se utilizaron las pruebas de raíces unitarias de Dickey-Fuller y Phillips-Perron (Becketti, 2013).

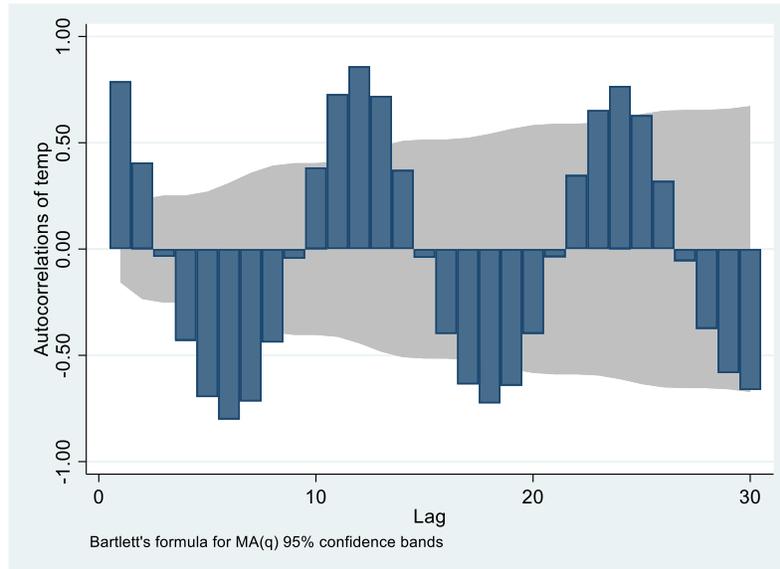


Figura 1. Correlograma para la serie de datos de temperatura mínima

Una vez las series rellenadas, se analizaron los datos de enero de 1982 a diciembre de 1994 para ambas temperaturas (máximas y mínimas), y se realizó el pronóstico para 24 meses a partir de enero de 1995, dado que la estación no presentaba datos para este año. Se utilizó Stata 16.0 para realizar el pronóstico. Cabe resaltar que entre más datos se pronostiquen hacia el futuro el modelo va perdiendo confiabilidad (Esparza, 2007).

El proceso seguido para obtener el modelo de serie de tiempo fue con la metodología de Box-Jenkins, con las siguientes etapas: 1ª) Identificación, 2ª) Estimación, 3ª) Verificación o diagnóstico, 4ª) Pronóstico. En la tercera etapa se realizó la predicción y se generaron los residuales, a estos se les realizaron las pruebas estadísticas de normalidad Shapiro-Wilk, Jarque-Bera y Liung Box. Si los residuales generados por la predicción del modelo no tienen una distribución normal (campana de Gauss) hay que regresar a la segunda etapa a reconstruir el modelo (lo cual no sucedió).

Se obtuvo la raíz cuadrada del cuadrado medio del error (*RMSE*), con la ecuación 1, cabe destacar que este valor se obtuvo de la siguiente forma, la *RMSE* se calculó de enero de 1983 a diciembre de 1996, faltando los datos de 1995 (resultados arrojados por Stata con la estimación ausente para 1982 y la ausencia de datos del año 1995):

$$RMSE = \left(\frac{\sum_{i=1}^n (a_i - t_i)^2}{n} \right)^{1/2} \quad (1)$$

donde a_i es el dato estimado por el modelo, t_i es el dato observado (medido), n es el número de observaciones o estimaciones.

Resultados y Discusión

Sample: Jan 1983 - Dec 1994						Number of obs = 144		Sample: Jan 1983 - Dec 1994						Number of obs = 144	
Log likelihood = 236.6335						Wald chi2(4) = 97.68		Log likelihood = 96.80187						Wald chi2(5) = 57.57	
						Prob > chi2 = 0.0000								Prob > chi2 = 0.0000	
d12ltemp	Coef.	OPG Std. Err.	z	P> z	[95% Conf. Interval]										
ARMA															
ar															
L1.	.379177	.1043986	3.63	0.000	.1745595	.5837945	L1.	.2740747	.085075	3.22	0.001	.1073307	.4408186		
L12.	-.1527957	.1024064	1.49	0.136	-.0479171	.3535085	L2.	.1696913	.0837122	2.03	0.043	.0056185	.3337641		
							L13.	.1287154	.0667783	1.93	0.054	-.0021677	.2595986		
ma															
L1.	-.1424335	.111009	-1.28	0.199	-.3600073	.0751402	L12.	-1.038124	.156253	-6.64	0.000	-1.344374	-.7318739		
L12.	-.8547243	.175354	-4.87	0.000	-1.198412	-.5110368	L35.	.2825276	.0806471	3.50	0.000	.1244623	.440593		
/sigma	.0445108	.0031543	14.11	0.000	.0383284	.0506932	/sigma	.1047398	.0095338	10.99	0.000	.0860538	.1234257		

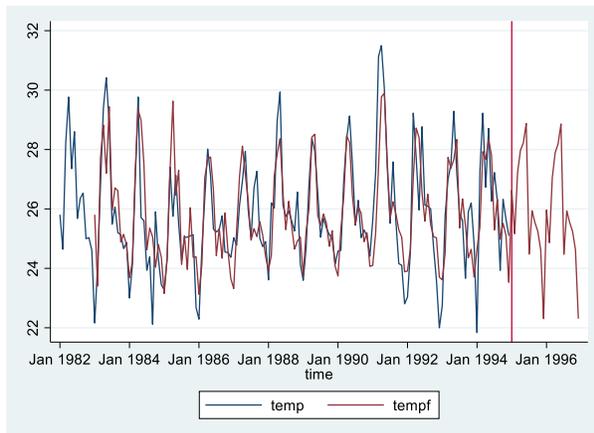
Note: The test of the variance against zero is one sided, and the two-sided confidence interval is truncated at zero.

a)

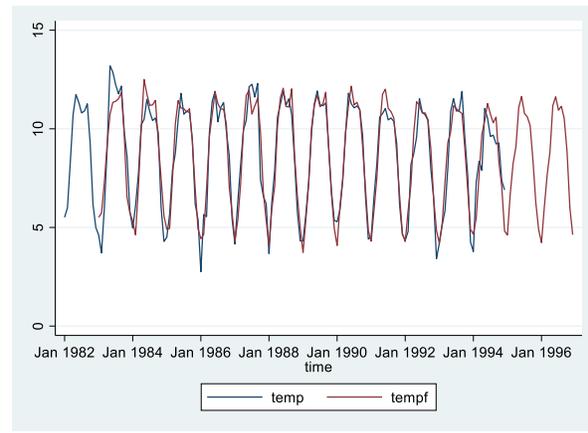
b)

Figura 2. Modelos ARMA con sus coeficientes respectivos para a) T_{max} y b) T_{min}

Se obtuvo un proceso ARMA, con un 10% de significancia se aceptaron ambos modelos, para T_{min} presentando tres términos para la parte autorregresiva (AR) y dos términos de media móvil (MA) (Figura 2b), y para T_{max} dos términos AR y dos MA (Figura 2a).



a)



b)

Figura 3. Pronóstico de 24 meses de las variables a) temperatura máxima y b) mínima, para la estación 09071 de la CDMX.

Se observa en la Figura 3 la estimación y/o pronóstico de ambos modelos ARMA obtenidos, para T_{min} el modelo tuvo un mejor ajuste, en comparación con T_{max} , lo corroboran los valores de RMSE obtenidos, el cual fue para T_{min} de 0.927 y para T_{max} 1.316.

Conclusiones

De ambos modelos encontrados, el que mejor aproximó a los datos observados fue el de T_{min} . Los modelos de series de tiempo muestran ser una herramienta robusta en la estimación y/o pronóstico de las temperaturas promedio mensuales.



Referencias Bibliográficas

- Beckett S. 2013. Introduction to time series using Stata. A Stata Press Publication, StataCorp LP, Texas, United States of America, 443 pp.
- Esparza C. C. 2007. Series temporales. 53 pp.
- Flocas A. A.; Giles B. D.; and Angouridakis V. E. 1983. On the estimation of annual and monthly means values of air temperature over Greece using stepwise multiple regression analysis. Arch. Met. Geoph. Biocl., Ser. B. 32:287-295.
- Meyer S. J.; Hubbard K. G. 1992. Nonfederal automated weather stations and networks in the United States and Canada: a preliminary survey. Bulletin of the American Meteorological Society. 73(4):449-457.
- Romeu P.; Zamora-Martínez F.; Botella-Rocamora P.; and Pardo J. 2013. V. Mladenov et al (Eds.): ICANN 2013, LNCS 8131, pp 451-458.
- Ye L.; Yang G.; Van Ranst E.; and Tang H. 2013. Time-series modeling and prediction of global monthly absolute temperature for environmental decision making. Advances in atmospheric sciences 30(2):382-396.