

PREDICCIÓN DE VARIABLES METEOROLÓGICAS POR MEDIO DE MODELOS ARIMA

METEOROLOGICAL VARIABLES PREDICTION THROUGH ARIMA MODELS

G. Javier **Aguado-Rodríguez**^{1*}, Abel **Quevedo-Nolasco**¹, Martiniano **Castro-Popoca**¹,
Ramón **Arteaga-Ramírez**², M. Alberto **Vázquez-Peña**², B. Patricia **Zamora-Morales**³

¹Hidrociencias. Campus Montecillo. Colegio de Postgraduados. 56230. Montecillo, Estado de México. (aguado.graciano@colpos.mx), (anolasco@colpos.mx), (mcastro@colpos.mx). ²Irrigación. Universidad Autónoma Chapingo. 56230. Chapingo, Estado de México. (arteagar@correo.chapingo.mx), (mvazquezp@correo.chapingo.mx). ³Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias. Km. 13.5. Carretera Los Reyes-Texcoco. 56250. Texcoco, Estado de México (zamora.patricia@inifap.gob.mx).

RESUMEN

La predicción de las variables meteorológicas se aplica en la agricultura al predecir el consumo de agua de las plantas para planear la lámina de riego. En esta investigación se elaboró un programa para realizar la predicción de la temperatura, radiación solar, evapotranspiración de referencia y humedad relativa con modelos autorregresivos integrados de media móvil (ARIMA) y se probó la efectividad del programa para realizar la predicción en condiciones de alta y baja precipitación. Los periodos de predicción evaluados fueron en marzo y en junio de 2013 en tres estaciones meteorológicas automáticas (EMAS) del Servicio Meteorológico Nacional (SMN). El análisis de los resultados indicó que la predicción de las variables meteorológicas con modelos ARIMA fue mejor que con la predicción persistente en el periodo con condiciones de baja precipitación (marzo).

Palabras clave: Pronóstico, R Statistics, tiempo real.

INTRODUCCIÓN

Hay grandes progresos en el desarrollo y las aplicaciones de la predicción del clima a mediano plazo y su predicción estacional (Vitart *et al.* 2012). Los algoritmos de predicción automáticas más usados son con base en el suavizado exponencial o modelos autorregresivos integrados de media móvil (ARIMA) (Hyndman y Khandakar, 2008). Box y Jenkins (1976) desarrollaron la metodología clásica que emplea las series de tiempo para

ABSTRACT

Meteorological variables prediction is applied in agriculture to predict water uptake of plants for planning irrigation depths. In the present study a program was made for the prediction of temperature, solar radiation, reference evapotranspiration and relative humidity by means of autoregressive integrated mobile media models. The effectiveness of the program was tested for prediction under high and low rainfall conditions. The prediction periods evaluated were in March and in June, 2013, in three automatic meteorological stations (EMAS) of the National Meteorological Service (SMN). The analysis of results indicated that the prediction of meteorological variables with ARIMA models was better than with persistent prediction in the period with low rainfall conditions (March).

Key words: Prediction, R Statistics, real time.

INTRODUCTION

There is great progress in the development and applications of medium term weather prediction and seasonal climate (Vitart *et al.*, 2012). The most frequently used automatic prediction algorithms are based on the softened exponential or autoregressive integrated mobile media models (ARIMA) (Hyndman and Khandakar, 2008). Box and Jenkins (1976) developed the classic methodology that uses the time series for generating models such as the autoregressive mobile media model (ARMA) or also the ARIMA model for obtaining predictions.

Karl *et al.* (2000) found an increment in the global warming rate using the time series of global mean

* Autor responsable ♦ Author for correspondence.

Recibido: septiembre, 2014. Aprobado: agosto, 2015.

Publicado como ARTÍCULO en *Agrociencia* 50: xxx-xxx. 2016.

generar modelos como el autoregresivo de media móvil (ARMA) o también el modelo ARIMA para obtener predicciones.

Karl *et al.* (2000) reportaron un aumento en la tasa de calentamiento global usando la serie de tiempo de la temperatura media global indicada por Quayle *et al.* (1999), por medio del análisis de valores mensuales de temperatura y con modelos ARMA. Reikard (2009) investigó la predicción de la radiación solar en intervalos de tiempos de 5 min hasta varias horas y aunque los datos exhibieron variabilidad no lineal debido a la nubosidad, en la mayoría de las pruebas se obtuvieron los mejores resultados usando los modelos ARIMA. Pulido (2002) propuso estimar la demanda de agua en las próximas 24 h en un sistema de distribución de agua para riego usando modelos ARIMA y otros modelos. Para predecir la lluvia del monzón de verano en la India, Chattopadhyay y Chattopadhyay (2010) identificaron un modelo ARIMA como adecuado, pero el modelo de redes neuronales autorregresivas (ARNN) proporcionó mejores predicciones, mientras que Narayanan *et al.* (2013) usaron modelos ARIMA para predecir las lluvias antes del monzón en el oeste de la India.

Debido a que los modelos ARIMA son una herramienta para realizar predicción de series de tiempo univariadas, en esta investigación se propuso elaborar un programa de cómputo que calcule la predicción en tiempo real de variables meteorológicas usando modelos ARIMA y probar su efectividad en condiciones de baja y alta precipitación.

MATERIALES Y MÉTODOS

Para esta investigación se usó una computadora con procesador de 2.2 GHz, 2 GB de memoria RAM y sistema operativo Windows 7°. En la computadora se instaló: el programa de cómputo MySQL Server®, que es un gestor de bases de datos para almacenar información (Korhonen *et al.*, 2008); Microsoft Visual Studio 2010° que es un conjunto completo de herramientas de desarrollo para la generación de aplicaciones Web ASP.NET, Servicios Web XML, aplicaciones de escritorio y aplicaciones móviles (Randolph *et al.*, 2010); MySQL Conector Net 6.3.5° que es un conector del programa Microsoft Visual Studio 2010° con MySQL Server (Kofler, 2005); R Statistics 2.15.3°, un paquete de cómputo estadístico (Dalgaard, 2008); librerías 'rcom' y 'rscproxy' del programa R Statistics 2.15.3 (conectores del programa R Statistics 2.15.3 con Microsoft Visual Studio 2010); y la librería 'forecast' del programa R Statistics 2.15.3, se usó para la estimación y predicción de los modelos ARIMA.

temperature indicated by Quayle *et al.* (1999), using the analysis of monthly values of temperature and with ARMA models. Reikard (2009) investigated the prediction of solar radiation in 5 min time intervals for various hours, and although the data exhibited non-linear variability due to cloudiness, in most of the tests best results were obtained using the RIMA models. Pulido (2002) proposed the estimation of water demand in the next 24 h in a water distribution system for irrigation using ARIMA and other models. To predict rainfall of the summer monsoon in India, Chattopadhyay and Chattopadhyay (2010) identified an ARIMA model as adequate, but the autoregressive neuronal network model (ARNN) provided better predictions, while Narayanan *et al.* (2013) used ARIMA models to predict rainfall prior to the monsoon in western India.

Because the ARIMA models are a tool used for univariate weather prediction, the present investigation was made with the purpose of elaborating a computer program that calculates prediction in real time of meteorological variables using ARIMA models and testing its effectiveness under low and high rainfall conditions.

MATERIALS AND METHODS

The present investigation used a computer with a processor of 2.2 GHz, 2 GB of RAM memory and Windows 7° operative system. The following programs were installed: MySQL Server®, which is an administrator of data bases for storing information (Korhonen *et al.*, 2008); Microsoft Visual Studio 2010°, which is a complete set of development tools for the generation of applications of Web ASP.NET, XML Web Services, desktop and mobile applications (Randolph *et al.*, 2010); MySQL Connector Net 6.3.5° which is a connector of the program Microsoft Visual Studio 2010° with MySQL Server (Kofler, 2005); R Statistics 2.15.3°, computer statistical package (Dalgaard, 2008); 'rcom' and 'rscproxy' libraries of the program R Statistics 2.15.3 (connectors of the program R Statistics 2.15.3 with Microsoft Visual Studio 2010); and the 'forecast' library of the program R Statistics 2.15.3, which was used for the estimation and prediction of the ARIMA models.

To store meteorological information, a data base was made integrated with two data tables, in the program MySQL Server (Figure 1). The first data table was called 'station' and was used to store the information of each meteorological station, and for each station an identifier is required of station, latitude, longitude, altitude and name, and the primary key is the station identifier. The second data table, called 'elemhoraria' was used

Para almacenar información meteorológica se elaboró una base de datos integrada con dos tablas de datos, en el programa MySQL Server (Figura 1). La primera tabla de datos se denominó 'estación' y fue usada para guardar la información de cada estación meteorológica, y por cada estación se requiere un identificador de estación, latitud, longitud, altitud y nombre, y la llave primaria es el identificador de estación. La segunda tabla de datos, denominada 'elemhoraria', se usó para almacenar la información de los datos meteorológicos a nivel horario de estaciones meteorológicas; los datos almacenados en esta tabla son: fecha y hora, evapotranspiración (ET_0 en mm), velocidad del viento (VELS en m/s), precipitación (mm), radiación solar (RAD SOL en W/m^2), temperatura media (TEMP en $^{\circ}C$), humedad relativa (HR en %), y un identificador de estación de la cual provienen los datos; la llave primaria es la unión de los datos de fecha e identificador de estación.

En la Figura 1 se observa que una estación puede tener muchos registros a nivel horario y muchas estaciones pueden tener datos meteorológicos para una hora en particular.

Datos meteorológicos

Para comprobar la bondad predictiva de los modelos ARIMA, se usaron datos de tres estaciones meteorológicas automáticas (EMAS) del Servicio Meteorológico Nacional, México, para el 2013. Las EMAS fueron: ENCB. II del IPN, ubicada en $19^{\circ} 29' 55'' N$, $99^{\circ} 08' 43'' O$ y altitud de 2240 m; Acolman, ubicada en $19^{\circ} 38' 05'' N$, $98^{\circ} 54' 42'' O$ y altitud de 2269 m; Chapingo, ubicada en $19^{\circ} 29' 39'' N$, $98^{\circ} 53' 19'' O$ y altitud de 2260 m.

En las EMAS para este estudio hay datos continuos a nivel horario de cinco variables meteorológicas en dos periodos: el primero es del 7 de marzo de 2013 a las 16:00 h y el 17 de marzo de 2013 a las 15:00 h; el segundo es del 16 de junio de 2013 a las 16:00 h y 26 de junio de 2013 a las 15:00 h. Las variables meteorológicas obtenidas de las EMAS fueron: velocidad del viento (m/s), precipitación (mm), radiación solar (W/m^2), temperatura media ($^{\circ}C$), humedad relativa (%). Además se calculó la evapotranspiración de referencia (ET_0) por el método de Penman Monteith (Allen, 2006) con los datos anteriores.

Modelos ARIMA

Según Pankratz (1983), los modelos ARIMA sirven para predecir series simples (de una sola variable), en los que las predicciones de los modelos ARIMA están basadas sólo en valores pasados de la variable a predecir. Los modelos ARIMA se pueden usar para hacer predicciones a corto plazo porque la mayoría de ellos ponen mayor énfasis en el pasado reciente que en el pasado distante; se aplican a variables discretas o continuas, aunque el tiempo debe ser igualmente espaciado y en intervalos discretos;




Figura 1. Base de datos.

Figure 1. Data base

to store the information of the meteorological data at the time level of meteorological stations; the data stored in this table are: date and time, evapotranspiration (ET_0 in mm), wind velocity (VELS in m/s), rainfall (mm), solar radiation (SOLRAD in W/m^2), mean temperature (TEMP in $^{\circ}C$), relative humidity (RH in %), and an identifier of the station from which the data is from: the primary key is joining the data of date and station identifier.

In Figure 1, it is observed that a station can have many records at the hourly level and many stations can have meteorological data for a particular hour.

Meteorological data

To test the predictive goodness of the ARIMA models, data were used from three automatic meteorological stations (EMAS) of the National Meteorological Service, Mexico, for 2013. The EMAS considered were as follows: ENCB. II of the IPN, located at $19^{\circ} 29' 55'' N$, $99^{\circ} 08' 43'' W$ and altitude of 2240 m; Acolman, located at $19^{\circ} 38' 05'' N$, $98^{\circ} 54' 42'' W$ and altitude of 2269 m; Chapingo, located at $19^{\circ} 29' 39'' N$, $98^{\circ} 53' 19'' W$ and altitude of 2260 m.

In the EMAS for this study there are continuous data at the hourly level of five meteorological variables in two periods: the first is of March 7, 2013 at 16:00 h and March 17, 2013 at 15:00 h; the second is of June 16, 2013 at 16:00 h and June 26, 2013 at 15:00 h. The meteorological variables obtained from the EMAS were as follows: wind velocity (m/s), rainfall (mm), solar radiation (W/m^2), mean temperature ($^{\circ}C$), relative humidity (%). In addition, reference evapotranspiration (ET_0) was calculated by the Penman Monteith method (Allen, 2006) with the above data.

ARIMA Models

According to Pankratz (1983), the ARIMA models serve to predict simple series (of a single variable), in which the

son útiles para predecir series de datos que contienen variación estacional (u otras variaciones periódicas), incluyendo aquellas con patrones estacionales cambiantes; requieren como mínimo alrededor de 50 observaciones; se aplican sólo a series de datos estacionarios, y una serie de tiempo estacionaria tiene una media, varianza y función de autocorrelación constantes a través del tiempo (Pankratz, 1983).

El requisito de una serie de tiempo estacionaria puede parecer enteramente restrictiva, pero la mayoría de las series no estacionarias en la práctica se pueden transformar a una serie estacionaria a través de una transformación llamada “diferenciar”, la cual es una operación relativamente simple que envuelve el cálculo de cambios sucesivos en los valores de las series de datos. Los cambios en la serie de datos se conocen como (ω_t) y se obtienen con la ecuación $\omega_t = z_t - z_{t-1}$, donde z representa los valores de la serie de datos. Con las diferencias se construye una nueva serie diferente de la serie original, y una “diferencia” es cuando la media de una serie de datos cambia con el tiempo. Es posible “diferenciar” más de una sola vez para obtener una serie estacionaria. Al ya tener una serie estacionaria, se realiza la búsqueda por un buen modelo ARIMA y consiste en: identificación, estimación, diagnóstico del modelo; y si el modelo es adecuado se realiza la predicción (Pankratz, 1983).

Descripción del procedimiento de la librería Forecast para estimar el modelo ARIMA

Según Hyndman *et al.* (2013), un obstáculo común al usar modelos ARIMA para predecir es que el proceso de selección del orden es generalmente considerado subjetivo y difícil de aplicar. Por tanto, se elaboró la librería Forecast para elegir el orden del modelo de manera automática, y donde los algoritmos son aplicables a ambos, datos estacionales y no-estacionales.

Para Hyndman *et al.* (2013) un proceso ARIMA(p,d,q) no-estacional está dado por:

$$(1-B^d)y_t = c + \phi(B)y_t + \phi(B)\varepsilon_t$$

donde $\{\varepsilon_t\}$ es un proceso de ruido blanco con media cero y varianza σ^2 , B es el operador de retraso, y $\phi(z)$ y $\phi(z)$ son polinomios de orden p y q , respectivamente. Para asegurar causalidad e invertibilidad se asume que $\phi(z)$ y $\phi(z)$ no tienen raíces para $|z| < 1$. Si $c \neq 0$, hay un polinomio implícito de orden d en la función de predicción. El proceso estacional ARIMA (p,d,q) (P,D,Q)_m está dado por

$$(1-B^m)^D(1-B)^d y_t = c + \phi(B^m)\phi(B)y_t + \Theta(B^m)\theta(B)\varepsilon_t$$

predictions of the ARIMA models are based only on past values of the variable for prediction. The ARIMA models can be used to make short term predictions because most of them place more emphasis on the recent past than on the distant past; they are applied to discrete or continuous variables, although time should be equally spaced and in discrete intervals; they are useful for predicting data series that contain seasonal variation (or other periodic variations), including those with changing seasonal patterns; they require a minimum of 50 observations; it is applied only to series of stationary data, and a series of stationary time has a mean, variance and function of autocorrelation that are constant through time (Pankratz, 1983).

The requirement of a stationary time series may seem totally restrictive, but most of the non-stationary series in practice can be transformed into a stationary series through a process called “differentiation”, which is a relatively simple operation that involves the calculation of successive changes in the values of the data series. The changes in the data series are known as (ω_t) and are obtained with the equation $\omega_t = z_t - z_{t-1}$, where z represents the values of the data series. With the differences a new series is constructed, different from the original, and a “difference” is when the mean of a series of data changes with time. It is possible to “differentiate” more than just once to obtain a stationary series. When a stationary series is obtained, a good ARIMA model is sought and consists of: identification, estimation, diagnostic of the model, and if the model is adequate the prediction is made (Pankratz, 1983).

Description of the procedure of the Forecast library for estimating the ARIMA model

According to Hyndman *et al.* (2013), a common obstacle when using ARIMA models for prediction is that the selection process of the order is generally considered subjective and difficult to apply. Therefore, the Forecast library was made to select the order of the model automatically, and where the algorithms are applicable to both stationary and non-stationary data.

For Hyndman *et al.* (2013), a non-stationary ARIMA process (p,d,q) is obtained by:

$$(1-B^d)y_t = c + \phi(B)y_t + \phi(B)\varepsilon_t$$

where $\{\varepsilon_t\}$ is a white noise process with mean zero and variance σ^2 , B is the delay operator, and $\phi(z)$ and $\phi(z)$ are polynomials of order p and q , respectively. To insure causality and invertibility, it is assumed that $\phi(z)$ and $\phi(z)$ do not have roots for $|z| < 1$. If $c \neq 0$, there is an implicit polynomial of d order in the prediction function. The seasonal process ARIMA(p,d,q)(P,D,Q)_m is obtained as follows:

donde $\phi(z)$ y $\phi(z)$ son polinomios de orden P y Q respectivamente, cada uno no conteniendo raíces dentro del círculo unitario. Si $c \neq 0$, hay un polinomio implícito de orden $d+D$ en la función de predicción.

La tarea principal de la librería Forecast que Hyndman *et al.* (2013) realizan en la predicción automática del modelo ARIMA, es seleccionar un apropiado orden de modelo y son los valores de p, q, P, Q, D, d . Si D y d conocidos. Los órdenes p, q, P y Q se pueden seleccionar por medio de un criterio de información como el Criterio de Información de Akaike (AIC):

$$AIC = -2 \log(L) + 2 (p+q+P+Q+k)$$

donde $k=1$ si $c \neq 0$ y 0 de otra manera, y L es la probabilidad maximizada del modelo ajustado a los datos diferenciados $(1-B)^D (1-B)^d y_t$.

Para propósitos de predicción Hyndman *et al.* (2013) indican que es mejor hacer tan pocas diferencias como sea posible. Para datos no estacionales Hyndman *et al.* (2013) consideran modelos ARIMA(p, d, q) donde d es seleccionada basándose en el test de raíces unitarias sucesivas KPSS (Kwiatkowski *et al.*, 1992). El método prueba los datos para una raíz unitaria; si el resultado de la prueba es significativa, se prueban los datos diferenciados para una raíz unitaria; y así sucesivamente.

Para datos estacionales, en la librería Forecast se consideran modelos ARIMA(p, d, q) (P, D, Q)_m donde m es la frecuencia estacional y $D=0$ o $D=1$, dependiendo de una prueba extendida de Canova-Hansen (Canova and Hansen, 1995). Después de seleccionar D se elige d aplicando el test de raíces unitarias sucesivas KPSS a los datos estacionales diferenciados (si $D=1$) o a los datos originales (si $D=0$).

Estimación de la predicción

Con Microsoft Visual Studio 2010 se desarrolló una aplicación ejecutable (.exe), con la cual se realizan funciones para la predicción de las variables meteorológicas. Sin embargo, antes de describir dichas funciones es importante remarcar que la mayoría de las EMAS tienen la opción de descargar la información que registran y guardarla en archivos de texto. Por lo anterior, se realizó la primera función para extraer los datos de las variables meteorológicas almacenados en archivos de texto (de cada EMAS) y guardarlos en la base de datos. En la base de datos se almacenan los datos meteorológicos a nivel horario de distintas EMAS y se organizan por fecha y por identificador de EMA; los datos obtenidos se guardan en la tabla de datos 'elemhoraria'. Con esta función también se calcula la evapotranspiración de referencia

$$(1-B^m)^D (1-B)^d y_t = c + \phi(B^m) \phi(B) y_t + \Theta(B^m) \theta(B) \varepsilon_t$$

where $\phi(z)$ and $\phi(z)$ are polynomials of order P and Q , respectively, neither one containing roots within the unitary circle. If $c \neq 0$, there is an implicit polynomial of order $d+D$ in the prediction function.

The principal task of the Forecast library that Hyndman *et al.* (2013) carry out in the automatic prediction of the ARIMA model is to select an appropriate order of model and they are the known values of p, q, P, Q, d . If D and d are known. The orders p, q, P and Q can be selected by means of a criterion of information such as the Akaike Information Criterion (AIC):

$$AIC = -2 \log(L) + 2 (p+q+P+Q+k)$$

where $k=1$ if $c \neq 0$ and 0 otherwise, and L is the maximized probability of the model fitted to the differentiated data $(1-B)^D (1-B)^d y_t$.

For purposes of prediction, Hyndman *et al.* (2013) point out that it is better to make the fewest differences possible. For non-seasonal data, Hyndman *et al.* (2013) consider ARIMA(p, d, q) models where d is selected based on the test of successive unitary roots KPSS (Kwiatkowski *et al.*, 1992). The method tests the data for a unitary root; if the result of the test is significant, differentiated data are tested for a unitary root; and so on.

For seasonal data, in the Forecast library ARIMA(p, d, q) (P, D, Q)_m models are considered where m is the seasonal frequency and $D = 0$ or $D = 1$, depending on an extended test of Canova-Hansen (Canova and Hansen, 1995). After selecting D , d is selected applying the test of successive unitary roots KPSS to the differentiated seasonal data (if $D = 1$) or to the original data (if $D=0$).

Estimation of the prediction

With Microsoft Visual Studio 2010 a usable application was developed (.exe), with which functions are made for the prediction of the meteorological variables. However, before describing these functions it is important to emphasize that most of the EMAS have the option of downloading the information they record and saving it in text files. Therefore, a first function was made for extracting the data of the meteorological variables stored in text files (of each EMAS) and storing them in the data base. The meteorological data are stored in the data base at the schedule level of different EMAS and are organized by date and identifier of EMA; the data obtained are stored in the data table 'elemhoraria'. Its function is also used to calculate reference

por el método de Penman Monteith (Allen, 2006) y el resultado se almacena en la misma tabla de datos.

Cuando termina la primera función se tienen los promedios de las variables meteorológicas a nivel horario en la base de datos. Con la segunda función se genera una serie de tiempo por cada variable meteorológica de las tres EMAS, y la serie de tiempo así generada tiene 60 datos. Cada dato de la serie de tiempo consiste en el promedio de dos horas; por ejemplo, si para el día 16/06/2013 a las 16:00, 17:00, 18:00 y 19:00 h el promedio de temperatura fue 22, 23.7, 24.7 y 24.8 °C respectivamente, y el día 21 de junio de 2013 a las 14:00 y 15:00 h el promedio de temperatura fue 16.2 y 15.6 °C, respectivamente, entonces la serie de tiempo tendrá los valores 22.85, 24.75, ..., 15.9 °C, con un total de 60 datos. Las series de tiempo generadas se almacenan en un archivo de texto creado automáticamente con extensión '.txt' para cada EMA (Figura 2); el archivo tiene seis columnas (una columna por cada variable meteorológica) y 61 filas. La primera fila contiene los nombres de las variables meteorológicas; sin embargo, sólo se analizaron cuatro variables. La primera variable está en la primera columna y tiene los datos de evapotranspiración de referencia (mm), en la cuarta columna están los datos de radiación solar (W/m²), en la quinta columna están los datos de la temperatura (°C), y en la sexta columna están los datos de humedad relativa (%).

Al terminar la segunda función se tienen las series de tiempo para cada variable meteorológica necesaria para realizar la predicción. Con la tercera función se realiza la predicción. En el primer paso de la tercera función se establece una conexión entre el programa R Statistics 2.15.3 con Microsoft Visual Studio 2010; el lenguaje de programación fue C#. Después se envía un comando al programa R Statistics 2.15.3 para hacer el ajuste de las series de tiempo, de cada variable meteorológica, a un modelo ARIMA usando la función "auto.arima" de la librería Forecast (Hyndman *et al.*, 2013); después de lo anterior, ya con el modelo ARIMA estimado automáticamente, se envía un comando al programa


evapotranspiration by the Penman Monteith method (Allen, 2006) and the result is stored in the same data table.

When the first function is completed, the averages of the meteorological variables are obtained at the hour level in the data base. The second function is used to generate a time series for each meteorological variable of the three EMAS, and the resulting time series contains 60 data. Each data of the time series consists of the average of two hours. For example, if for day 16/06/2013 at 16:00, 17:00, 18:00 and 19:00 the average temperature was 22, 23.7, 24.7 and 24.8 °C, respectively, and on June 21 of 2013 at 14:00 and 15:00 h the average temperature was 16.2 and 15.6 °C, respectively, then the time series will have the values 22.85, 24.75, ..., 15.9 °C, with a total of 60 data. The generated time series are stored in a text file created automatically with extension '.txt' for each EMA (Figure 2). The file has six columns (one column for each meteorological variable) and 61 days. The first row contains the names of the meteorological variables; however, only four variables are analyzed. The first variable is in the first column and has the data of reference evapotranspiration (mm), the fourth column has the data of solar radiation (W/m²), the fifth column contains the data of temperature (°C) and the sixth column includes the data of relative humidity (%).

When the second function is finished, we have obtained the time series for each meteorological variable necessary for carrying out the prediction. The prediction is obtained with the third function. In the first step of the third function a connection is established between the program R Statistics 2.15.3 and Microsoft Visual Studio 2010; the programming language was C#. Then a command is sent to the program R Statistics 2.15.3 to fit the time series of each meteorological variable to an ARIMA model using the function "auto.arima" of the Forecast library (Hyndman *et al.*, 2013). Next, using the automatically estimated ARIMA model, a command is sent to the program R Statistics 2.15 to make the prediction of the next 60 elements in the time series.

The function "auto.arima" of the Forecast library (Hyndman *et al.*, 2013) gives back the best ARIMA model. However, the function "auto.arima" requires arguments such as a univariate time series, the order of the first difference "d" (if it is not put in, the function "auto.arima" selects a value according to the KPSS test), the order of the first seasonal difference "D" (if it is not put in, the function "auto.arima" calculates it), the maximum value for p , q , P , Q , the initial value of p , q , P , Q (optional), if the time series is stationary, if the time series is seasonal, among other optional data.

For the function "auto.arima" the options were specified of maximum value of p equal to 5, maximum value of q equal to 5, and the seasonal option equal to "TRUE", because otherwise the search for non-seasonal models is restricted. The last function consists of saving the predictions obtained with the function



ETO	VEL	PREC	RADSOL	TEMP	HR
0.4260808	4.175	0	770.65	22.85	62.5
0.62526245	6.965	0	721.25	24.75	54
0.8027181	6.72	0	763.8	27	42.5
0.53648805	12.085	0	423	26.65	48

Figura 2. Contenido del archivo de texto con series de tiempo de variables meteorológicas para la EMA ENCBI para el periodo de junio.

Figure 2. Content of the text file with time series of meteorological variables for the EMA ENCBI for the period of June.

R Statistics 2.15 para hacer la predicción de los 60 elementos siguientes en la serie de tiempo.

La función “auto.arima” de la librería Forecast (Hyndman *et al.*, 2013) regresa el mejor modelo ARIMA. No obstante, la función “auto.arima” requiere argumentos como una serie de tiempo univariada, el orden de la primera diferencia “d” (si no se coloca, la función “auto.arima” elige un valor de acuerdo con la prueba KPSS), el orden de la primera diferencia estacional “D” (si no se coloca, la función “auto.arima” lo calcula), el máximo valor para p , q , P , Q , el valor inicial de p , q , P , Q (opcional), si la serie de tiempo estacionaria, si la serie de tiempo es estacional, entre otros datos opcionales.

Para la función “auto.arima” se especificaron las opciones valor máximo de p igual a 5, valor máximo de q igual a 5, y la opción estacional igual a “TRUE” porque de lo contrario se restringe la búsqueda para modelos no-estacionales. La última función consiste en guardar las predicciones obtenidas con la función “auto.arima”. Para lo anterior, se crean archivos de texto con extensión ‘.txt’ y en estos se almacenan las predicciones; el nombre del archivo se crea con la unión del nombre de la EMA, el nombre de la variable y la palabra PRED al final (para indicar que es predicción). En la Figura 3 se muestra el archivo generado de la estación ENCBII para la variable temperatura del aire.

En el archivo texto generado por la predicción (Figura 3), en la primera línea, la predicción del promedio de la variable entre las 16:00 y 17:00 h el 21 de junio de 2013, en la segunda línea está la predicción del promedio de la variable entre las 18:00 y 19:00 h el 21 de junio de 2013, y en la última fila del archivo está la predicción del promedio de la variable entre las 14:00 y 15:00 h del día 26 de junio de 2013.

RESULTADOS Y DISCUSIÓN

La precisión de la predicción en los dos periodos fue evaluada. En el primero, los datos observados entre 7 de marzo de 2013 a las 16:00 h hasta el 12 de marzo de 2013 a las 15:00 h, se usaron para generar la serie de tiempo, y los datos observados entre 12 de marzo de 2013 a las 16:00 y 17 de marzo de 2013 a las 15:00 h se usaron para compararlos con los datos estimados con el modelo de predicción. Después se evaluó la precisión de la predicción en el segundo periodo. Los datos observados entre el 16 de junio de 2013 a las 16:00 h y el 21 de junio de 2013 a las 15:00 h se usaron para generar la serie de tiempo. Los datos observados entre 21 de junio de 2013 a las 16:00 h y el 26 de junio de 2013 a las 15:00 h se usaron para compararlos con los datos de las predicciones estimadas.

“auto.arima”. To carry this out, text files are created with extension ‘.txt’ where the predictions are stored. The name of the file is created with the combination of the name of the EMA, the name of the variable and the word PRED at the end (to indicate that it is prediction). Figure 3 shows the name of the file generated of the station ENCBII for the variable air temperature.

In the text file generated by the prediction (Figure 3), in the first line, the prediction of the average of the variable between 16:00 and 17:00 h on June 21 of 2013, in the second line is the prediction of the average of the variable between 18:00 and 19:00 h on June 21 of 2013, and in the last row of the file is the prediction of the average of the variable between 14:00 and 15:00 h of June 26 of 2013.

RESULTS AND DISCUSSION

The precision of the prediction in the two periods was evaluated. In the first, the data observed between March 7 of 2013 at 16:00 h until March 12 of 2013 at 15:00 h were used to generate the time series, and the data observed between March 12 of 2013 at 16:00 and March 17 of 2013 at 15:00 h were used to be compared with the data estimated with the prediction model. Next, the precision of the prediction in the second period was evaluated. The data observed between June 16 of 2013 at 16:00 h and June 21 of 2013 at 15:00 were used to generate the time series. The data observed between June 21 of 2013 at 16:00 h and June 26 of 2013 at 15:00 h were used to compare with the data of the estimated predictions.




Figura 3. Archivo generado con datos de la predicción estimada con la función “auto.arima” para la EMA ENCBII en el periodo de junio y la variable meteorológica temperatura del aire (°C).

Figure 3. File generated with data of the prediction estimated with the function “auto.arima” for the EMA ENCBII in the period of June and the meteorological variable air temperature (°C).

En las Figuras 4 y 5 se graficaron los datos observados con los datos estimados de las variables meteorológicas: humedad relativa (%), temperatura del aire ($^{\circ}\text{C}$), radiación solar (W/m^2) y evapotranspiración de referencia (mm). Los datos tomados como observados de evapotranspiración de referencia fueron calculados con el método de Penman Monteith (Allen, 2006) y usando los datos observados de las demás variables meteorológicas.

In Figures 4 and 5 the observed data were graphed with the estimated data of the meteorological variables: relative humidity (%), air temperature ($^{\circ}\text{C}$), solar radiation (W/m^2) and reference evapotranspiration (mm). The data obtained as observed from reference evapotranspiration were calculated with the method of Penman Monteith (Allen, 2006) and using the observed data of the other meteorological variables.




Figura 4. Predicción y variables observadas 60 h hacia adelante para la EMA Acolman (A), Chapingo (B), y ENCB. II del IPN en el primer periodo (marzo).

Figure 4. Prediction and variables observed 60 h ahead for the EMA Acolman (A), Chapingo (B), and ENCB. II of the IPN in the first period (March).




Figura 5. Predicción y variables observadas 60 h hacia adelante para la EMA Acolman (A), Chapingo (B), y ENCB. II del IPN (C) en el segundo periodo (junio).

Figure 5. Prediction and variables observed 60 h forward for the EMA Acolman (A), Chapingo (B), and ENCB II of the IPN (C) in the second period (June).

Los modelos ARIMA obtenidos para cada estación y variable meteorológica están en el Cuadro 1.

Para una serie de tiempo dada $\{y_n\}$, la predicción persistente se obtiene al colocar $y(n+1)=y(n)$, que implica que el promedio de la variable para la siguiente hora es igual al promedio de la variable en la hora actual (Kavasseri *et al.*, 2009).

Para comparar la bondad predictiva de los modelos ARIMA con la predicción persistente se calcularon

The ARIMA models obtained for each station and meteorological variable are found in Table 1.

For a given time series $\{y_n\}$, the persistent prediction is obtained by placing $y(n+1)=y(n)$, which implies that the average of the variable for the next hour is equal to the average of the variable in the present hour (Kavasseri *et al.*, 2009).

To compare the predictive goodness of the ARIMA models with the persistent prediction,

Cuadro 1. Modelos ARIMA para las series de tiempo de las variables meteorológicas evapotranspiración (ET0), humedad relativa (HR), radiación solar (RAD SOL) y temperatura del aire (TEMP).**Table 1. ARIMA models for the time series of the meteorological variables evapotranspiration (ET0), relative humidity (RH), solar radiation (SOLRAD) and air temperature (TEMP).**

Estación	Variable	ϕ_1	ϕ_2	θ_1	θ_2	θ_3	Φ_1	Θ_1	ARIMA (p, d, q)(P, D, Q) ₁₂
Periodo de marzo									
Acolman	ET0	0.38					-0.58		(1, 0, 0)(1, 1, 0)
Chapingo	ET0	0.68							(1, 0, 0)(0, 1, 0)
ENCBII	ET0								Sin ajuste
Acolman	HR			0.86	0.69	0.45	-0.67		(0, 0, 3)(1, 1, 0)
Chapingo	HR	1.11	-0.35				-0.28		(2, 0, 0)(1, 1, 0)
ENCBII	HR			-0.44				-0.45	(0, 1, 1)(0, 1, 1)
Acolman	RADSOL	0.81	-0.26				-0.72		(2, 0, 0)(1, 1, 0)
Chapingo	RADSOL	0.40	-0.25				-0.67		(2, 0, 0)(1, 1, 0)
ENCBII	RADSOL			-0.27					(0, 0, 1)(0, 1, 0)
Acolman	TEMP							-0.61	(0, 1, 0)(0, 1, 1)
Chapingo	TEMP	1.45	-0.62	-0.43			0.97	-0.50	(2, 0, 1)(1, 0, 1)
ENCBII	TEMP			0.76					(0, 0, 1)(0, 1, 0)
Periodo de junio									
Acolman	ET0	1.63	-0.87	-1.68	0.78		0.73		(2, 1, 2)(1, 0, 0)
Chapingo	ET0	1.19	-0.51	-0.96			0.57		(2, 1, 1)(1, 0, 0)
ENCBII	ET0			0.22			0.60		(0, 1, 1)(1, 0, 0)
Acolman	HR	0.34					0.68		(1, 1, 0)(1, 0, 0)
Chapingo	HR	0.35					0.38		(1, 1, 0)(1, 0, 0)
ENCBII	HR	0.72		-0.50	-0.42		0.36		(1, 1, 2)(1, 0, 0)
Acolman	RADSOL	1.23	-0.55				0.83		(2, 0, 0)(1, 0, 0)
Chapingo	RADSOL	0.62		0.52			0.89	-0.39	(1, 0, 1)(1, 0, 1)
ENCBII	RADSOL			1.02	0.50		0.80	-0.37	(0, 0, 2)(1, 0, 1)
Acolman	TEMP	1.38	-0.63				0.64		(2, 0, 0)(1, 0, 0)
Chapingo	TEMP	1.66	-0.91	-1.67	0.72		0.29		(2, 1, 2)(1, 0, 0)
ENCBII	TEMP	0.41		0.04	-0.35	-0.56	0.95	-0.75	(1, 1, 3)(1, 0, 1)

mediciones del error y del cuadrado medio del error (MSE). Cadenas y Rivera (2007) mencionan que si el valor observado en el tiempo t es y_t y F_t es la predicción para el mismo tiempo, entonces el error se define como $e_t = y_t - F_t$, y el cuadrado medio del error es:

$$MSE = \frac{1}{n} \sum_{t=1}^n e_t^2$$

En nuestro estudio el valor observado del promedio de la temperatura del aire entre las 16:00 y 17:00 del 12 de marzo, 2013, fue 20.7 °C y el valor obtenido con la predicción del modelo ARIMA para el mismo tiempo fue 19.96 °C, por lo cual el MSE del modelo ARIMA, de ese tiempo fue de 0.547. El valor de la predicción persistente de ese mismo tiempo fue

measurements of the error and of the mean square of the error (MSE) were calculated. Cadenas and Rivera (2007) point out that is the value observed in the time t is y_t and F_t is the prediction for the same time, then the error is defined as $e_t = y_t - F_t$, and the mean square of the error is:

$$MSE = \frac{1}{n} \sum_{t=1}^n e_t^2$$

In our study the observed value of the average of air temperature between 16:00 and 17:00 of March 12, 2013, was 20.7 °C and the value obtained with the prediction of the ARIMA model for the same time was 19.96 °C, thus the MSE of the ARIMA model of that time was 0.547. The value of the persistent

14.95 (el valor observado del promedio de la temperatura del aire entre las 14:00 y 15:00 h del 12 de marzo de 2013); por lo tanto, el valor del MSE del modelo persistente, de ese tiempo fue de 33.06. La misma operación se realizó para las 40 h hacia adelante (20 tiempos hacia adelante).

El valor MSE se calculó en tiempos de 5 en 5 hacia adelante para todas las variables (5, 10, 15, 20, etc.) hasta que el valor del MSE obtenido con la predicción de los modelos ARIMA (MSE_A) fuera mayor que el valor del MSE obtenido con la predicción del modelo de persistencia (MSE_B). En la variable temperatura del aire del periodo de marzo de la estación Acolman se encontró que hasta 15 tiempos hacia adelante el valor del MSE_A (2.531) fue menor que el del MSE_B (10.309); y a los 20 tiempos el valor del MSE_A (11.204) fue mayor que el del MSE_B (10.422). Para comparar los errores se calculó un porcentaje de mejoría de la predicción del modelo ARIMA con respecto a la predicción con el modelo persistente.

El porcentaje de mejoría de la predicción del modelo ARIMA con respecto a la predicción con el modelo persistente (PM) se calculó como sigue:

$$PM = 100 - \frac{MSE_A * 100}{MSE_P}$$

donde MSE_A es el MSE del modelo ARIMA, MSE_P es el MSE del modelo persistente.

En la variable temperatura del aire del periodo de marzo de la estación Acolman y 15 tiempos hacia adelante, se encontró que el valor del PM fue 75.4 %, lo cual indica que el modelo ARIMA se desempeña 75.4 % mejor que el modelo persistente hasta los 15 tiempos hacia adelante (30 h). De la misma manera se realizó el cálculo del PM para todas las variables meteorológicas en ambos periodos (marzo y junio) y para las tres EMAS (Cuadro 2).

Dos aspectos importantes en un esquema de predicción son: 1) que tan bien un modelo retiene su precisión sobre el horizonte de predicción y, 2) que tan robusto es el esquema para la elección del horizonte de predicción (Kavasseri *et al.*, 2009). Para observar el primer aspecto se realizaron predicciones de los valores de las variables meteorológicas hacia adelante hasta que el PM fuera menor que cero. Cuando

prediction of this same time was 14.95 (the observed value of the average of the air temperature between 14:00 and 15:00 h of March 12, 2013); therefore, the value of the MSE of the persistent model of this time was 33.06. The same operation was carried out for the 40 h ahead (20 times ahead).

The MSE value MSE was calculated from 5 in 5 times ahead for all of the variables (5, 10, 15, 20, etc) until the value of the MSE obtained with the prediction of the ARIMA models (MSE_A) was higher than the value of the MSE obtained with the prediction of the persistence model (MSE_B). In the air temperature variable of the period of March of the Acolman station, it was found that up to 15 times ahead the value of MSE_A (2.531) was lower than that of the MSE_B (10.309); and at 20 times the value of MSE_A (11.204) was higher than that of MSE_B (10.422). To compare the errors, a percentage of improvement of prediction was calculated of the ARIMA model with respect to the prediction with the persistent model.

The percentage of improvement of the prediction of the ARIMA model with respect to the prediction with the persistent model (PM) was calculated as follows:

$$PM = 100 - \frac{MSE_A * 100}{MSE_P}$$

where MSE_A is the MSE of the ARIMA model, MSE_P is the MSE of the persistent model.

In the variable of air temperature of the period of March at the Acolman station and 15 times ahead, it was found that the value of PM was 75.4 %, which indicates that the ARIMA model performs 75.4 % better than the persistent model as far as 15 times ahead (30 h). Thus, the calculation of the PM was made for all of the meteorological variables in both periods (March and June) and for the three EMAS (Table 2).

Two important aspects in a prediction plan are: 1) how well a model retains its precision over the prediction horizon, and 2) how robust is the plan for the selection of the prediction horizon (Kavasseri *et al.*, 2009). To observe the first aspect, predictions were made of the values of the meteorological variables ahead until the PM was less than zero. When the values of PM are less than zero, it indicates that

Cuadro 2. Porcentaje de mejoría de la predicción del modelo ARIMA con respecto a la predicción con el modelo persistente (PM) para las estaciones meteorológicas Acolman (A), Chapingo (B), y ENCBII (C), los tiempos hacia adelante (T) y en los periodos de marzo y junio.

Table 2. Percentage of improvement of the prediction of the ARIMA model with respect to the prediction with the persistent model (PM) for meteorological stations Acolman (A), Chapingo (B), and ENCBII (C), the times ahead (T) and in the periods of March and June.

Variable	T	PM (%)							
		Marzo			Junio			Promedio	
		A	B	C	A	B	C	Marzo	Junio
ET0	20	51.4	55.7	----	-153.3	-42.6	-56.1	53.6	-84.0
HR	15	65.7	27.7	49.5	-408.8	-425.3	-135.3	46.7	-323.1
RADSOL	30	83.3	64.9	65.0	19.1	13.1	23.8	71.0	18.7
TEMP	15	75.4	33.0	21.7	-42.0	-140.8	4.9	43.4	-59.3

los valores de PM son menores que cero, indica que el MSE_p fue mejor que el MSE_A (la predicción con el modelo persistente fue mejor que con el modelo ARIMA). Para observar el segundo aspecto se eligieron dos periodos: el periodo de marzo con muy poca precipitación (menos de tres eventos de precipitación y menos de 1 mm en total), y el periodo de junio en donde se presentan más de 20 eventos de precipitación (más de 8 mm en total).

El modelo ARIMA predice mejor que el persistente más de 15 tiempos hacia adelante para las variables ET0, HR, RADSOL y TEMP en el periodo de marzo (Cuadro 2). Para el periodo de junio se encontró que el modelo persistente fue mejor que el ARIMA para las variables ET0, HR y TEMP. Una probable razón de esto es que la precipitación afecta las demás variables meteorológicas y puede cambiar el comportamiento de una serie temporal.

CONCLUSIONES

El uso de software de computadora y modelos ARIMA permite al investigador estimar la predicción de variables meteorológicas automáticamente y en tiempo real. Sin embargo, los resultados indican que, en promedio, en el periodo de marzo con muy poca precipitación (menos 1 mm), la predicción con los modelos ARIMA fue mejor que la predicción con el modelo persistente en: 53.6 % en evapotranspiración de referencia hasta 20 tiempos hacia adelante (40 h); 46.7 % en humedad relativa hasta 15 tiempos hacia adelante (30 h); 71 % en radiación solar hasta 30 tiempos hacia adelante (60 h); 43.4% en temperatura

the MSE_p was better than the MSE_A (the prediction with the persistent model was better than with the ARIMA model). To observe the second aspect, two periods were selected: the period of March with very little precipitation (less than three rainfall events and less than 1 mm total) and the period of June in which more than 20 rainfall events occurred (more than 8 mm total).

The ARIMA model predicts better than the persistent model more than 15 times ahead for the variables ET0, RH, SOLRAD and TEMP in the period of March (Table 2). For the period of June it was found that the persistent model was better than the ARIMA model for the variables ET0, RH and TEMP. A possible reason for this is that rainfall affects the other meteorological variables and can change the behavior of a time series.

CONCLUSIONS

The use of computer software and ARIMA models allows the investigator to estimate the prediction of meteorological variables automatically and in real time. However, the results indicate that on the average, in the period of March with very little rainfall (less than 1 mm), prediction with the ARIMA models was better than prediction with the persistent model with: 53.6 % in reference evapotranspiration by as much as 20 times ahead (40 h); 46.7 % in relative humidity up to 15 times ahead (30 h); 71 % in solar radiation up to 30 times ahead (60 h); 43.4 % in air temperature as much as 15 times ahead (30 h). In the period of June, the predictions obtained with the

del aire hasta 15 tiempos hacia adelante (30 h). En el periodo de junio, las predicciones obtenidas con el modelo persistente fueron mejores que con el modelo ARIMA.

persistent model were better than with the ARIMA model.

—End of the English version—

LITERATURA CITADA



- Allen, R. G. 2006. Evapotranspiración del cultivo: guías para la determinación de los requerimientos de agua de los cultivos. FAO 56: 89-173
- Box, G. E. and G. M. Jenkins. 1976. Time Series Analysis: Forecasting and Control. Revised Ed., Holden-Day, San Francisco. pp: 469-471
- Cadenas, E., and W. Rivera. 2007. Wind speed forecasting in the south coast of Oaxaca, Mexico. *Renew. Energy* 32: 2116-2128.
- Canova, F. and B. E. Hansen. 1995. Are seasonal patterns constant over time? a test for seasonal stability. *J. Bus. Econ. Stat.* 13: 237-252.
- Chattopadhyay, S., and G. Chattopadhyay. 2010. Univariate modelling of summer-monsoon rainfall time series: comparison between ARIMA and ARNN. *C. R. Geoscience* 342: 100-107.
- Dalgaard, P. 2008. *Introductory Statistics with R*. Second Edition. Springer Science Business Media, LLC. New York, NY, USA. 364 p.
- Hyndman, R. J. and Y. Khandakar. 2008. Automatic time series forecasting: The forecast package for R. *J. Stat. Software* 27: 1-22.
- Hyndman R. J., G. Athanasopoulos, S. Razbash, D. Schmidt, Z. Zhou, Y. Khan and C. Bergmeir. 2013. Forecasting functions for time series and linear models. R package version 4.06. <http://cran.r-project.org/web/packages/forecast>. (Accessed: June 2013).
- Karl, T. R., R. W. Knight, and B. Baker. 2000. The record breaking global temperatures of 1997 and 1998: Evidence for an increase in the rate of global warming?. *Geophys. Res. Lett.* 27: 719-722.
- Kavasseri, R. G., and K. Seetharaman. 2009. Day-ahead wind speed forecasting using f-ARIMA models. *Renew. Energy* 34(5): 1388-1393.
- Kofler, M. 2005. *The Definitive Guide to MySQL 5*. David Kramer. Third edition. APRESS. New York, NY, USA. 172 p.
- Korhonen, K., F. Donadini, P. Riisager, and L. J. Pesonen. 2008. GEOMAGIA50: an archeointensity database with PHP and MySQL. *Geochem. Geophys. Geosyst.* 9: 1-14.
- Kwiatkowski, D., P. C. Phillips, P. Schmidt, and Y. Shin. 1992. Testing the null hypothesis of stationarity against the alternative of a unit root. *J. Econom.* 54: 159-178.
- Narayanan, P., A. Basistha, S. Sarkar, and S. Kamna. 2013. Trend analysis and ARIMA modelling of pre-monsoon rainfall data for western India. *C. R. Geoscience* 345: 22-27.
- Pankratz, A. 1983. *Forecasting With Univariate Box-Jenkins Models Concepts and Cases*. Ed., John Wiley & Sons. United States. pp. 3-19.
- Pulido-Calvo, I., J. Roldán, R. López-Luque, and J. C. Gutiérrez-Estrada. 2002. Técnicas de predicción a corto plazo de la demanda de agua. *Aplicación al uso agrícola*. *Ing. del Agua* 9: 319-331.
- Quayle, R. G., T. C. Peterson, A. N. Basist, and C. S. Godfrey. 1999. An operational near-real-time global temperature index. *Geophys. Res. Lett.* 26: 333-335.
- Randolph, N., D. Gardner, M. Minutillo, and C. Anderson. 2010. *Professional Visual Studio 2010*. Wrox. Wiley Publishing, Inc, Indianapolis, Indiana. 1177 p.
- Reikard, G. 2009. Predicting solar radiation at high resolutions: A comparison of time series forecasts. *Sol. Energy* 83: 342-349.
- Vitart, F., A. W. Robertson, and D. L. Anderson. 2012. Proyecto de predicción subestacional a estacional: tendiendo un puente entre el tiempo y el clima. *Boletín de la OMM* 61: 23-28.