

PREDICCIÓN DE CAUDALES DIARIOS DE LA ESTACIÓN HIDROMÉTRICA TUMILACA APLICANDO MODELOS ESTOCÁSTICOS AUTOREGRESIVOS

PREDICTING DAILY FLOWS FROM THE TUMILACA HYDROMETRIC STATION USING STOCHASTIC MODELS

¹ Eduardo Luis Flores Quispe, ² Carlos Alberto Silva Delgado, ³ Eduardo Flores Condori

RESUMEN

Los modelos estocásticos se han aplicado comúnmente para gestionar los recursos hídricos a escala de tiempo diario. El río Tumilaca es una de las principales fuentes de agua de Moquegua. Los objetivos fueron predecir los caudales diarios aplicando modelos estocásticos, determinar si el modelo estocástico autoregresivo de primer orden AR(1) es adecuado para caudales diarios con autocorrelogramas y validar el modelo con pruebas de bondad de ajuste. Se utilizó datos del Servicio Nacional de Meteorología e Hidrología, desde el 01 junio del 2006 hasta el 31 de diciembre del 2011. Se calibró y validó el modelo AR(1) y el modelo autoregresivo con tendencia no lineal es representada por la serie Gaussiana. En la validación, el modelo más apropiado fue AR(1) pues al componente aleatorio independiente le sigue la distribución Log logística de 3 parámetros. El modelo AR(1) es adecuado para los caudales diarios porque los autocorrelogramas de la variable estandarizada muestran altos valores de coeficiente de autocorrelación y los autocorrelogramas de las variables aleatorias independientes muestran valores de autocorrelación bajos, dentro de los límites del 95 por ciento de confianza. Las pruebas de bondad de ajuste validaron a AR(1) al 5 por ciento de nivel de significancia, el coeficiente de correlación entre los caudales observados y generados fue estadísticamente significativo ($p < 0,05$). La prueba t muestra que las medias de los caudales observados y generados son estadísticamente iguales ($p < 0,05$) ambos en la validación. El modelo AR(1) supera al modelo autoregresivo con tendencia no lineal por su ajuste a los caudales diarios. Se recomienda aplicar el modelo AR(1), en todo caso, aplicar modelos estocásticos que incluyan variables exógenas, tales como precipitación, infiltración, evaporación y derivaciones de agua. Probar modelos de precipitación-escorrentía e investigar las causas de bajo sostenimiento del caudal del río Tumilaca.

Palabras clave: Predicción, modelos estocásticos, modelos autoregresivos, caudal diario, río Tumilaca.

ABSTRACT

Stochastic models are commonly applied to manage water resources at daily time scale. The Tumilaca River is one of the main water sources of Moquegua. The objectives were to predict daily flows using stochastic models, stochastic model to determine whether the first-order autoregressive AR (1) is suitable for daily flows with autocorrelograms, validate the model goodness of fit tests and determine if it is adequately predicted daily flows. Data from the National Service of Meteorology and Hydrology was used, from 1 June 2006 until 31 December 2011. It was calibrated and validated two models: AR (1) and an autoregressive model with non-linear trend. The AR (1) model is sufficient as autocorrelograms. The autoregressive model with non-linear trend by a Gaussian series is represented. In validating the most appropriate model is AR (1) with independent random component continues Log 3-parameter logistic distribution. The AR (1) model is suitable for daily flows because of the standardized variable autocorrelograms show high values of autocorrelation coefficient and autocorrelograms of independent random variables show low values of autocorrelation within the limits of the 95 percent confidence. The goodness of fit tests validated AR (1) 5 percent significance level, the correlation coefficient between observed and generated flow rates was statistically significant ($p < 0,05$), the t-test shows that the mean flows observed and generated are statistically equal ($p < 0,05$) both in the validation. The AR (1) model outperforms the autoregressive model with non-linear trend for its fit to the observed daily flows in the validation. We recommend applying the AR model (1), applied stochastic models that include exogenous variables as precipitation, infiltration, evaporation, and water diversions, rainfall-runoff models to test and investigate the causes of low Tumilaca sustaining river flow.

Keywords: Prediction, stochastic models, autoregressive models, daily flow, Tumilaca stream.

INTRODUCCIÓN

Para garantizar la oferta de agua en la gestión de recursos hídricos, es necesario realizar estudios de predic-

ción de caudales. Los modelos estocásticos son modelos de variables aleatorias que no tienen valor fijo en un punto particular del espacio y del tiempo, pero están descritas a través de distribuciones de probabilidad. Estos modelos

¹ Doctoris Scientiae en Ciencia, Tecnología y Medio Ambiente, Magister Scientiae Recursos Hídricos, Ingeniero Agrícola. Docente de la Carrera Profesional de Ingeniería de Sistemas de la Universidad Nacional de Moquegua. Perú

² Ingeniero en Informática y Sistemas. Docente de la Carrera Profesional de Ingeniería de Sistemas de la Universidad Nacional de Moquegua. Perú.

³ Doctor en Medio Ambiente y Desarrollo Sostenible, Ingeniero Agrónomo. Docente de la Universidad Nacional del Altiplano. Puno – Perú.

hacen predicciones (Chow *et al.*, 1994).

Un modelo estocástico describe todas las características de la serie hidrológica y permite realizar la simulación en situaciones en las cuales la experimentación directa es imposible. Si los procesos simulados contienen algún elemento aleatorio, a estas técnicas se les conoce con el nombre de métodos de simulación estocástica de Monte Carlo (Miller *et al.*, 1992).

La predicción de caudales es importante, por sus múltiples aplicaciones en generación de energía eléctrica, en agricultura, etc. La literatura publicada en ese contexto incluye los trabajos de Poveda y Mesa (1993), Mesa *et al.* (1994), Carvajal *et al.* (1994), Poveda (1994); Poveda y Penland (1994), Poveda y Mesa (1996); Poveda (1998); Poveda y Jaramillo (2000); Poveda *et al.* (1999). En cuanto a modelos estadísticos, se ha trabajado con técnicas de regresión múltiple, análisis espectral singular (Carvajal *et al.*, 1994), Modelo Lineal Inverso, redes neuronales (Carvajal *et al.*, 1994; Poveda *et al.*, 2002), regresión múltiple adaptiva por tramos (Poveda *et al.*, 2002), modelos autorregresivos dependientes del régimen (Salazar *et al.*, 1994), etc.

La dinámica de los fenómenos es aleatoria y puede fluctuar indistintamente alrededor de varios estados estables. Esto justifica el uso de variables predictoras para la determinación óptima de los caudales (Poveda, 2004). En hidrología se han utilizado tradicionalmente modelos lineales determinísticos y estocásticos univariados y multivariados en la predicción.

El pronóstico de caudal de ríos es útil para reducir esta incertidumbre del clima asociada a la gestión y conservación del recurso agua. Dichos pronósticos pueden ser de corto plazo, períodos de unas pocas horas o días, y de largo plazo, con tiempos de antelación de hasta nueve meses (Georgakakos y Krzysztofowicz, 2001).

La predicción representa los valores estimados de la variable respuesta para datos no empleados en el ajuste de un modelo. Existen varios métodos estadísticos de predicción que son apropiados para estudios de caudales. Uno de ellos corresponde a los mínimos cuadrados generalizados (GLS) con una estructura de correlación no nula; otro a los modelos de efectos mixtos (ME) que tienen parámetros fijos y efectos aleatorios al definir el modelo estadístico, lo cual permite acomodar la correlación de los datos (Salas *et al.*, 2010).

Los fenómenos relacionados a la generación y distribución de la lluvia en nuestro planeta, y todas sus consecuencias directas como el escurrimiento superficial, la infiltración del suelo y de manera especial el caudal de los ríos, son procesos aleatorios (García, 2010).

Los modelos Markovianos y los modelos Autorregresivos (AR) han sido usados extensamente en hidrología, desde principios de los años 1960, para el modelamiento de series de tiempo periódicas (mensual, semanal y diaria) y anuales. Principalmente porque la forma autorregresiva tiene un tipo intuitivo de dependencia en el tiempo, y son modelos simples de usar (Villon, 1983). Pueden tener parámetros constantes (datos anuales) o periódicos (datos estacionales: mensuales, semanales o diarios) que varían con el tiempo o una combinación de ambos.

El modelo Markoviano es aplicable a series que no

son normales. Este modelamiento se realiza con los datos originales (sin normalizarlos) y determina la distribución de probabilidad de los residuos (Salas, 1979).

Un proceso de series de tiempo tiene características estadísticas: media, desviación estándar, coeficiente de variación, coeficiente de sesgo, correlación estación a estación, autocorrelación, correlación cruzada, y estadísticas relativas a almacenamiento, a sequías y a excesos (Salas, 2000).

Las series de tiempo hidrológicas estacionales como los caudales diarios, pueden describirse mejor por considerar las estadísticas en una base estacional (Salas, 2007). Las estadísticas relacionadas al almacenamiento son particularmente importantes en el modelamiento para estudios de simulación de sistemas de reservorios. Tales características son generalmente funciones de la estructura de la varianza y autocovarianza de las series de tiempo. Las estadísticas relacionadas a sequías son también importantes en el modelamiento (Salas, 2000). Las estadísticas relacionadas a exceso son simplemente lo opuesto de las estadísticas relacionadas a sequía (Sveinsson *et al.*, 2007).

El modelo Markoviano de series no anuales (mensuales, semanales, diarias), presentan periodicidades en sus diferentes parámetros, a diferencia de las series anuales que no las presentan, lo que hace un poco más complicado su análisis (Yevjevich, 1972).

Los pasos del modelamiento estocástico de series hidrológicas son: Definición del enfoque de modelamiento, selección del tipo de modelo, identificación del orden del modelo, estimación de sus parámetros, prueba y verificación (Salas, 2008).

Se ha realizado el modelamiento y pronóstico de caudales usando una red neuronal RBF (red neuronal de base radial), la cual ha sido utilizada para estimar el pronóstico diario de caudal, obteniendo resultados satisfactorios frente a otras técnicas como el modelo autorregresivo de media móvil integrado ARIMA (Fajardo *et al.*, 2008). En el modelamiento la calidad del ajuste se puede verificar comparando la serie simulada de caudales y el registro respectivo, las curvas de duración de caudales, así como utilizando criterios de eficiencia (Carvajal y Roldán, 2007). También se utilizaron redes neuronales artificiales de retropropagación para modelar caudales medios mensuales en función de caudales, precipitación y evaporación. Estos modelos mostraron un excelente comportamiento frente a un modelo autorregresivo periódico de primer orden PAR(1) (Laquí, 2010). Se modeló y predijo las fluctuaciones de caudales diarios mediante redes neuronales artificiales (ANN) de tres capas, presentando un mejor desempeño que el modelo autorregresivo (AR), después de su comparación (Pierini *et al.*, 2012).

Predecir los caudales medios diarios permite simular series futuras de oferta de agua a corto plazo, garantizar la cobertura de la demanda de agua y evitar la insatisfacción de la demanda, como parte de la gestión de recursos hídricos. El objetivo fue predecir los caudales diarios de la estación hidrométrica Tumilaca aplicando modelos estocásticos, determinando el orden y validando el modelo autorregresivo. Finalmente, con la pruebas de bondad de ajuste, predecir los caudales aplicando el modelo validado.

MATERIALES Y MÉTODOS

El río Tumilaca es afluente del río Osmore en la región Moquegua. Sus aguas irrigan los estrechos valles de Pocata, Tumilaca y Samegua. Su cuenca posee 4 regiones geomorfológicas: Costa, Zona Altoandina, Zona Inferior andina y Zona Meso andina. Presenta 3 tipos de clima: semi-cálido muy seco (desértico o árido subtropical), templado sub-húmedo (Estepa y valles interandinos bajos) y frío o boreal (Valles mesoandinos). Ofrece 13 zonas de vida según Holdridge, desde Desierto árido montano subtropical en la parte baja hasta Tundra muy húmeda alpino subtropical en la parte alta. Las formaciones geológicas que tiene son del Triásico al Cuaternario reciente.

Se utilizó información de caudales diarios de la estación Tumilaca, del Servicio Nacional de Meteorología e Hidrología (SENAMHI). Los caudales diarios se midieron limnimétricamente a las 06:00, 10:00, 14:00 y 18:00 horas en un día.

Para representar la dependencia de la componente estocástica ha sido necesario modelar la serie de tiempo, aplicando el método de Salas (2008). Este método toma en cuenta muchos aspectos como características estadísticas y físicas del sistema modelado, a parte de los aspectos de calibración y validación. Se utilizó Excel, Minitab 16 y MatLab R2010a. Se eligió el modelo autoregresivo de primer orden AR(1) por la dependencia en el tiempo de los caudales y por ser componente del modelo ARIMA (Fajardo *et al.*, 2008). El modelo autoregresivo con parámetros periódicos PAR(1) también fue utilizado por Laquí (2010) y Pierini *et al.* (2012) comparándolo con redes neuronales artificiales. Se decidió aplicar además un modelo autoregresivo con tendencia no lineal, porque los caudales diarios presentan parámetros periódicos.

El período total utilizado comprendió del 01 de junio del 2006 hasta el 31 de julio del 2011 (tamaño de muestra 1887 datos). Los datos se dividieron en dos series y dos momentos: calibración, del 01 de junio del 2006 al 31 de diciembre del 2009 (1310 datos) y validación, del 01 de enero del 2010 al 31 de julio del 2011 (577 datos). Para conocer la independencia de la serie, se calculó el autocorrelograma. Con los datos de calibración, se realizó la descomposición de la serie realizando la estandarización.

$$z_t = \frac{x - \bar{x}}{s}$$

El modelo autoregresivo de primer orden AR(1) utilizado fue:

$$z_t = r_1 z_{t-1} + \varepsilon_t$$

Se obtuvo el valor de la variable aleatoria independiente ε_t .

Se determinó el autocorrelograma de la variable aleatoria ε_t y se buscó su distribución de probabilidad, en base a las pruebas de bondad de ajuste de Anderson-Darling. Las distribuciones probadas admiten valores negativos: Normal, Lognormal 3 parámetros, Gamma 3 parámetros, Exponencial 2 parámetros, Valor extremo inferior, Weibull 3 parámetros, Valor extremo superior, Logística, Log logística 3 parámetros.

El mismo procedimiento de calibración se realizó para determinar un modelo autoregresivo con tendencia no lineal. La tendencia se ajustó a los modelos: serie de Fourier, serie Gaussiana y suma de senos; escogiéndose por el mayor coeficiente de determinación (r^2). Se obtuvo una variable estándar z_t .

$$z_t = \frac{x_t - \text{tendencia}}{s_x}$$

Dónde: x_t = caudal diario, tendencia = modelo ajustado a la tendencia, s_x = desviación estándar.

Una vez determinado el autocorrelograma de esta variable estandarizada z_t , se determinó la variable aleatoria independiente ε_t y se buscó su función de distribución de probabilidad entre las distribuciones anteriormente mencionadas.

Para validar los modelos se generó una serie sintética para el período de validación y esta se comparó con la serie de caudales observados para ese mismo período. El valor de z_{t-1} se calculó a partir del valor del último caudal diario del período de calibración. Al generar los números aleatorios ε_t se procedió con los caudales medios diarios, resultando 577 números aleatorios.

Para el ajuste de los caudales observados y generados fue necesario el coeficiente de correlación, un gráfico de dispersión y la prueba t. El mismo procedimiento se realizó para validar el modelo autoregresivo con tendencia no lineal.

RESULTADOS Y DISCUSIÓN

La serie completa de caudales diarios presenta: media de 0,771 m³/s, desviación estándar de 0,258 m³/s, valor mínimo de 0,29 m³/s y máximo de 2,663 m³/s, mediana de 0,784 m³/s, coeficiente de asimetría de 0,915 que nos muestra un sesgo positivo, habiendo mayor cantidad de valores bajos.

La prueba de normalidad de Anderson-Darling rechaza la normalidad de los datos al 0,05 de significancia. El coeficiente de variación obtenido es de 0,334, el cual es alto por ser mayor de 0,30. La no normalidad de los caudales diarios se atribuye a la no linealidad de sus causas y a la escala de tiempo diaria utilizada. Muchas variables hidrológicas no son normales porque los fenómenos que los producen dependen de varios factores multiplicativos que interactúan entre sí, no son simplemente causadas por efectos aditivos. Los caudales provienen de factores como: área de la cuenca, intensidad de precipitación y coeficiente de escorrentía, siendo cada una de estas variables también producto de otros factores. Para caudales mensuales promedios es de esperar que estos sigan una distribución normal debido a que se pone de manifiesto el teorema del límite central.

Los valores atípicos se mantuvieron en la serie. Se obtuvo un coeficiente de autocorrelación de primer orden de caudales medios diarios $r_1 = 0,969825$. Los coeficientes de autocorrelación son altos para los primeros 40 retardos, estando fuera de los límites de confianza, siendo la serie completamente dependiente para ajustar un modelo estocástico autoregresivo.

En el período de calibración la media obtenida fue

0,828 m³/s y la desviación estándar 0,239. Los valores de autocorrelación de la variable aleatoria ϵ_t son bajos y están dentro de los límites de confianza, se consideran como independientes.

Los valores del estadístico de Anderson-Darling obtenidos para las distribuciones fueron: Normal (67,891), Lognormal 3 parámetros (62,822), Gamma 3 parámetros (63,637), Exponencial 2 parámetros (467,353), Valor extremo inferior (276,534), Weibull 3 parámetros (157,792), Valor extremo superior (142,172), Logística (26,928), Log logística 3 parámetros (26,487). La distribución Log logística presenta el menor valor, considerándose como la distribución que más se ajusta a los valores de la variable independiente ϵ_t . El modelo autoregresivo AR(1) es el siguiente:

$$x = 0,828 + 0,239z_t$$

$$z_t = 0,969825z_{t-1} + \epsilon_t$$

Donde ϵ_t sigue una distribución Log logística con 3 parámetros: Localización = 1,585, escala = 0,02073, Umbral = -4,889. En la figura 1 se presenta la comparación entre las series observadas y generadas.

El coeficiente de correlación entre los caudales observados y generados con el modelo AR(1) fue de $r = 0,157$, el cual es estadísticamente significativo ($r \neq 0$) al 95 por ciento de confianza. El gráfico de dispersión entre los caudales observados y generados se presenta en la figura 2.

Los resultados de la prueba t para comparar las medias de los caudales observados y generados fueron: media del caudal observado = 0,644, media del caudal generado = 0,651, desviación estándar del caudal observado =

0,253, desviación estándar del caudal generado = 0,142, $t_c = -0,55$, $p = 0,580$, g.l. = 905. Según los resultados de la prueba t, las medias son iguales al 0,05 de significancia, mostrando que el modelo predice adecuadamente la media de los caudales.

El ajuste de la tendencia de los datos en el período de calibración obtuvo los siguientes resultados de coeficientes de determinación (r^2): Serie de Fourier (0,7916), Serie Gaussiana (0,8193), Suma de funciones seno (0,8190). El modelo de tendencia elegido es la serie Gaussiana con $r^2 = 0,8193$. El ajuste a la serie Gaussiana se presenta en la siguiente figura.




Figura 3. Ajuste de la tendencia a la serie Gaussiana.

El modelo general de serie Gaussiana es el siguiente:

$$\text{tendencia}(x) = a1 * \exp(-((x-b1)/c1)^2) + a2 * \exp(-((x-b2)/c2)^2) + a3 * \exp(-((x-b3)/c3)^2) + a4 * \exp(-((x-b4)/c4)^2) + a5 * \exp(-((x-b5)/c5)^2) + a6 * \exp(-((x-b6)/c6)^2) + a7 * \exp(-((x-b7)/c7)^2) + a8 * \exp(-((x-b8)/c8)^2).$$

Los coeficientes del modelo y sus límites de confianza al 95 por ciento (en paréntesis) son:

$a1 = 0,558$ (0,5245; 0,5915), $b1 = 1040$ (1038; 1043), $c1 = 55,88$ (51,61; 60,16), $a2 = 0,4508$ (0,3931; 0,5084), $b2 = 601,3$ (598,8; 603,8), $c2 = 37,15$ (31,6; 42,71), $a3 = 0,1193$ (0,06322; 0,1753), $b3 = 262,2$ (256,1; 268,3), $c3 = 16,21$ (7,047; 25,38), $a4 = 0,4576$ (0,3903; 0,5248), $b4 = 683,9$ (682,2; 685,5), $c4 = 16,62$ (13,77; 19,48), $a5 = 0,1561$ (0,09274; 0,2194), $b5 = 503$ (498,7; 507,3), $c5 = 13,72$ (6,834; 20,61), $a6 = 0,2501$ (0,1727; 0,3275), $b6 = 412,2$ (374,2; 450,1), $c6 = 280,6$ (186,3; 374,9), $a7 = 0,2857$ (0,2419; 0,3294), $b7 = 784,7$ (780,2; 789,2), $c7 = 40,36$ (32,26; 48,46), $a8 = 1,461$ (-1,125; 4,046), $b8 = -2298$ (-9169; 4572), $c8 = 3231$ (-687,1; 7150).

La variable estándar z_t obtenida para el modelo autoregresivo con tendencia no lineal presenta un coeficiente de autocorrelación de orden 1 de 0,839. Se buscó la distribución de la variable aleatoria independiente ϵ_t .

Los estadísticos de Anderson - Darling obtenidos por distribución fueron: Normal (49,728), Lognormal 3

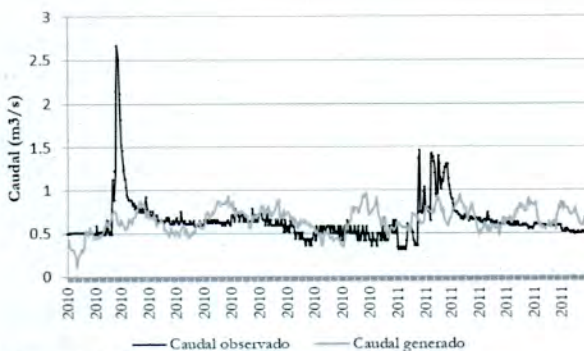


Figura 1. Validación del modelo estocástico.

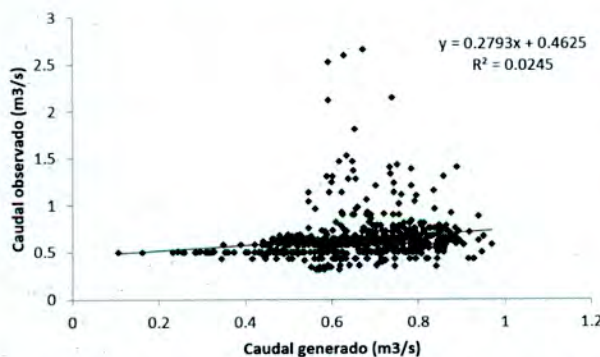


Figura 2. Gráfico de dispersión entre los caudales observados y generados con modelo AR(1).

parámetros (43,779), Gamma 3 parámetros (44,730), Exponencial 2 parámetros (451,442), Valor extremo inferior (260,417), Weibull 3 parámetros (133,173), Valor extremo superior (115,045), Logística (13,122), Log logística 3 parámetros (12,406); escogiéndose la distribución Log logística 3 parámetros como la que mejor se ajusta a la variable aleatoria independiente ϵ . El modelo autoregresivo que toma en cuenta la tendencia no lineal es el siguiente:

$$x = \text{tendencia} + 0,239z_t$$

$$z_t = 0,839 z_{t-1} + \epsilon_t$$

Donde ϵ , sigue la distribución Log logística de 3 parámetros Localización = 1,324, escala = 0,02681, Umbral = -3,767. La serie sintética generada y la serie de caudales observados para el período de validación se presentan en la figura 4.




Figura 4. Validación del modelo estocástico autoregresivo con tendencia no lineal.

El coeficiente de correlación $r = 0,104$ entre los caudales observados y generados en el período de validación es estadísticamente significativo ($r \neq 0$) al 95 por ciento de confianza. El gráfico de dispersión entre los caudales observados y generados se muestra en la figura 5.

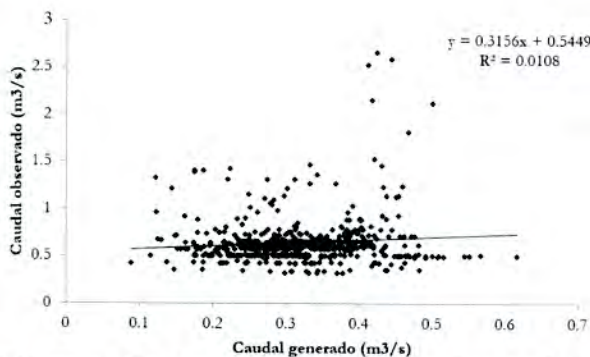


Figura 5. Gráfico de dispersión entre los caudales observados y generados con modelo AR(1).

La prueba t en la validación dio como resultado: media del caudal observado = 0,644, media del caudal generado = 0,3147, desviación estándar del caudal observado = 0,253, desviación estándar del caudal generado = 0,0832, $t_c = 29,70$, $p = 0,000$, g.l. = 699. Las medias no son iguales al

0,05 de significancia, mostrando que el modelo de tendencia no predice adecuadamente la media de los caudales. El modelo autoregresivo de orden 1 AR(1) predice mejor que el modelo autoregresivo con tendencia no lineal.

El modelo estocástico AR(1) genera una serie estacionaria. Los valores observados son extremadamente no estacionarios; sin embargo el modelo autoregresivo con tendencia no lineal no generó una media igual al caudal medio observado en el período de validación.

La serie observada no es estacionaria y tendría que modelarse incluyendo variables exógenas como precipitación, operación de embalses y derivaciones de caudales aguas arriba, para representar su disminución, lo cual no fue objetivo de la presente investigación.

Los caudales observados presentan eventos altamente aleatorios como los máximos extraordinarios que son impredecibles. Estos eventos máximos pueden ser causados por precipitaciones extremas, además la tendencia a la disminución puede explicarse por incremento de derivaciones de caudal arriba del sitio de medición.

CONCLUSIONES

El modelo autoregresivo de primer orden AR(1) es adecuado para los caudales diarios puesto que el autocorrelograma de la variable estandarizada muestra altos valores de coeficiente de autocorrelación y el autocorrelogramas de la variable aleatoria independiente muestra valores de autocorrelación bajos, dentro de los límites al 95 por ciento de confianza. El componente independiente aleatorio del modelo AR(1) se ajusta de mejor forma a una distribución Log logística. AR(1) predice mejor los caudales diarios que un modelo autoregresivo con tendencia no lineal.

Las pruebas de bondad de ajuste validaron el modelo autoregresivo de primer orden AR(1) al 0,05 de significancia. En la validación el coeficiente de correlación entre los caudales observados y generados con AR(1) fue estadísticamente significativo ($p < 0,05$) y la prueba t muestra que las medias de los caudales observados y generados con AR(1) son estadísticamente iguales a 0,05 de significancia.

REFERENCIAS BIBLIOGRÁFICAS

Carvajal, L.F., Roldan, E. (2007). Calibración del modelo lluvia-escurrentía agregado GR4J. Aplicación: cuenca del río Aburrá. *Dyna*, Año 74, Nro. 152, pp 73-87. Medellín, Julio.

Carvajal, L.F., Salazar J.E., Mesa, O.J., y Poveda, G. (1994). *Aplicación del Análisis Espectral Singular a series hidrológicas en Colombia*. Memorias del XVI Congreso Latinoamericano de Hidráulica e Hidrología, IAHS, Santiago de Chile, Vol.3, 97-108.

Chow, V., Maidment, D., Mays, L. (1994). *Hidrología Aplicada*. Santafé de Bogotá. Colombia: Mc Graw-Hill Interamericana. Pag. 8, Pag. 9, Pag. 495.

Fajardo, C. H., Peña, D., Soto, B., Fernandez-Riverola, F. (2008). Water flows modelling and forecasting using a RBF neural network. *Sistemas & Telemática*: 13-31.

García, F. P. (2010). *Modelación hidrológica estocástica: desarrollo de un modelo de generación sintética de series temporales*.

- Georgakakos y Krzysztofowicz. (2001). Probabilistic & Ensemble Forecasting. *Journal of hydrology*. 249.1
- Laqui, W. F. (2010). Aplicación de redes neuronales artificiales a la modelización y previsión de caudales medios mensuales del río Huancané. *Revista Peruana Geo-Atmosférica RPGA* (2), 30-44.
- Mesa, O. J., Poveda, G., Carvajal, L.F y Salazar, J.E. (1994). Predicción hidrológica usando redes neuronales. *Memorias del XVI Congreso Latinoamericano de Hidráulica e Hidrología*, IAHR, Santiago de Chile, Vol. 3, 385-396.
- Miller, I., Freund, J., Jonson, R. (1992). *Probabilidad y Estadística para Ingenieros*. Primera Edición. México: Prentice-Hall Hispanoamericana, S.A.
- Pierini, J. O., Gomez, E. A., Telesca, L. (2012). Prediction of water flows in Colorado River, Argentina. *Lat. Am. J. Aquat. Res.*, 40(4): 872-880.
- Poveda, G. (1994). *Funciones ortogonales empíricas en el análisis de la relación entre los caudales medios en Colombia y las temperaturas de los Océanos Pacífico y Atlántico*. Memorias del XVI Congreso Latinoamericano de Hidráulica e Hidrología, IAHR, Santiago de Chile.
- Poveda, G. (1998). *Retroalimentación Dinámica entre el Fenómeno El Niño-Oscilación del Sur y la Hidrología de Colombia*, Disertación Ph.D., Universidad Nacional de Colombia, Posgrado en Aprovechamiento de Recursos Hidráulicos, Medellín.
- Poveda, G. (2004). El clima de Colombia: Una síntesis desde la escala inter-decadal hasta la escala diaria. *Revista Academia Colombiana de Ciencias Exactas, Físicas y Naturales*, XXVIII (107), p. 201-222. En: <http://www.accefyn.org.co/PublicAcad/Periodicas/Volumen28/107/201-222.pdf>
- Poveda, G., & A. Jaramillo. (2000). ENSO-related variability of River Discharges and Soil Moisture in Colombia. *Biospheric Aspects of the Hydrologic Cycle*. 8:3-6, IGBP, diciembre.
- Poveda, G., & O. Mesa. (1993). Metodologías de predicción de la hidrología Colombiana considerando el evento El Niño-Oscilación del Sur (ENOS). *Revista Atmosfera*, 17. Sociedad Colombiana de Meteorología, Bogotá.
- Poveda, G., M. Gil & N. Quiceno. (1999). *The relationship between ENSO and the annual cycle of Colombia's hydro-climatology*. Proceedings 10th Symposium on Global Change Studies, American Meteorological Society, Dallas, Texas, 157-160, 10-15 enero.
- Poveda, G., Mesa, O., Carvajal, L., Hoyos, C., Mejía, J., Cuartas, A. & Pulgarin, A. (2002). Predicción de caudales medios mensuales en ríos colombianos usando métodos no lineales. *Meteorol. Colomb.* 6:1-8.
- Poveda, G., y Mesa, O.J. (1996). Las fases extremas del ENSO - El Niño y La Niña - y su influencia sobre la hidrología de Colombia. *Revista de Ingeniería Hidráulica en México*. Vol. XI, No. 1, 21-37.
- Poveda, G., y Penland, C. (1994). *Predicción de caudales medios en Colombia usando Modelación Lineal Inversa*. Memorias del XVI Congreso Latinoamericano de Hidráulica e Hidrología, IAHR, Santiago de Chile, Vol. 4, 119-129, 1994.
- Salas C., Ene L., Ojeda N. y Soto H. (2010). Métodos estadísticos paramétricos y no paramétricos para predecir variables de rodal basados en Landsat ETM+: una comparación en un bosque de Araucaria araucana en Chile. *Bosque* 31(3): 179-194.
- Salas, J. 2007. *Manual del SAMS* (2007). USA: Colorado State University, Colorado.
- Salas, J. D. (1979). Modelamiento estocástico de series hidrológicas. *PUBLIDRAT* Publicación N° 67, Lima, Perú: UNALM, 95 p.
- Salas, J. D. (2000). *Stochastic Analysis Modeling and Simulation (SAMS) version 2000. User's manual*. Colorado State University.
- Salas, J. D. (2008). Notas de clase del I Curso Internacional de Hidrología Estocástica. UNALM. Lima, Perú.
- Salazar, J., Mesa, O., Poveda, G., Carvajal, L. (1994). *Modelamiento del fenómeno ENOS en la hidrología Colombiana mediante procesos autoregresivos dependientes del régimen*. Memorias del XVI Congreso Latino Americano de Hidráulica e Hidrología, IAHR, Santiago de Chile, 4:181-191.
- Sveinsson, O., Salas, J. D., Lane, W. and Frevert, D. (2007). *Stochastic Analysis, Modeling, and Simulation (SAMS) Version 2007 - User's Manual*. Colorado, USA: Colorado State University, Fort Collins, 118 p.
- Villón B., M. G. (1983). *Diseño de capacidad de embalses por el método experimental - Teoría del Rango*. Tesis de Maestría, Universidad Nacional Agraria La Molina, Lima - Perú.
- Yevjevich, V. (1972). *Stochastic Proceses in Hydrology*. *Water Resources Publications*. Colorado, U.S.A.: Fort Collins.

Correspondencia:Eduardo Luis Flores Quispe: edu_fq@hotmail.comCarlos Alberto Silva Delgado: calbertosilvad@hotmail.com

Fecha de Recepción: 29/03/2015

Fecha de Aceptación: 01/06/2015