

CAUDALES DE RÍOS DE MENDOZA BAJO ENFOQUE DE BOX-JENKINS

Lic. Graciela PASCUCCI
Ayudante de Primera Econometría I y II
FCE - UNCUIYO

I. INTRODUCCIÓN

Mendoza está íntimamente ligada al uso del agua; su territorio está surcado por los ríos: Mendoza, Tunuyán, Diamante, Atuel, Malargüe y Colorado; este último y sus afluentes no han sido aprovechados económicamente hasta el presente. Cabe señalar que cada río tiene su correspondiente infraestructura hidráulica tanto para el almacenamiento del agua como para la derivación de sus caudales. Uno de los principales destinos es el riego agrícola, que en épocas de sequía o de bajos niveles de caudal, lleva a la extracción de aguas subterráneas por bombeo eléctrico; esto convierte a la variable caudales fluviales como un factor asociado a la demanda de energía eléctrica, y por ende se ve afectada la producción agrícola provincial. Desde hace varios años Mendoza, se encuentra bajo crisis hídrica, esperando que esta situación no cambie en el corto plazo, según lo afirma Dirección General de Irrigación. De allí, que el pronóstico del comportamiento futuro de los caudales sea relevante a la hora de establecer necesidades de inversión para satisfacer los diferentes consumos derivados de las necesidades de agua potable y actividades económicas.

La investigación tiene una visión distinta a la usual llevada adelante por los especialistas en temas hídricos, se trata de la metodología de Box-Jenkins¹ conocida popularmente así, se refiere al Método Autorregresivo Integrado de Medias Móviles (ARIMA). Esta adquiere relevancia internacionalmente a partir de su sencillez técnica para la predicción de corto plazo, dado que este método no se basa en la construcción de un modelo económico uniecuacional, sino en el análisis de las propiedades probabilísticas o estocásticas de las series de tiempo.

El trabajo se desarrolla en tres secciones, la primera es dedicada a trazar el marco teórico; la siguiente presenta los resultados de la aplicación de la metodología de Box-Jenkins y la última, las conclusiones a partir de la interpretación de las estimaciones obtenidas.

El presente proyecto de investigación plantea analizar el comportamiento de los caudales de los ríos de Mendoza, para lograr la predicción y simulación de caudales fluviales con el interés puesto en el uso de la energía eléctrica utilizada para sustituir el riego agrícola con agua de bombeo. El marco teórico de la investigación parte de la premisa que los procesos de series temporales involucran procesos no lineales y componentes estacionales, a ser abordados a través de técnicas estadísticas y econométricas.

La hipótesis de trabajo propuesta es la existencia de un ciclo anual con comportamiento sinusoidal factible de estimar bajo el Enfoque de Box-Jenkins.

A continuación, se consignan algunos trabajos de investigación, con los cuales se espera comparar las técnicas utilizadas a la luz de los métodos tipo Box-Jenkins. MILANA (2006) analizó la generación del caudal en los ríos de los Andes áridos de Argentina. Para estimar la producción de agua en los glaciares emplea un modelo que calcula el balance de energía en la interfase aire-hielo utilizando parámetros meteorológicos tradicionales. VICH, NORTE y LAURO (2014), determinan la magnitud del caudal anual y estacional, para periodos de retorno mucho mayores que los observados y obtener el cuantil correspondiente en sitios sin

¹ G.P.E. Box y G. M. Jenkins, Time Series Analysis: Forecasting and Control, edición revisada, Holden Day, San Francisco, 1978.

información, a partir del Análisis Regional de Frecuencias basadas en la estadística de momentos L (ARF – LM).

II. EL ENFOQUE DE BOX-JENKINS

El enfoque de Box-Jenkins es una técnica utilizada en los análisis de predicción, ya que permite la utilización de series de tiempo que pueden ser explicadas por los valores pasados o rezagados de sí misma y por los términos estocásticos de error. A diferencia de los modelos de regresión los que derivan de una construcción basada en la teoría económica e involucran el conocimiento de una mayor cantidad de variables. Este enfoque consta de cuatro pasos: Identificación, estimación, verificación de diagnóstico y predicción.

Es importante para la predicción identificar y estimar un modelo estadístico que pueda ser constante a través del tiempo, es decir que las variables a analizar deben tener características de estacionariedad.

1. Estacionariedad

Un proceso estocástico $\{y_t\}$ es estacionario en sentido estricto si para toda m-tupla $(t_1, t_2, t_3, \dots, t_m)$ y todo entero k, el vector de variables $\{y_{t_1}, y_{t_2}, y_{t_3}, \dots, y_{t_m}\}$ tiene la misma distribución de probabilidad conjunta que el vector $\{y_{t_1+k}, y_{t_2+k}, y_{t_3+k}, \dots, y_{t_m+k}\}$. Es decir, las variables aleatorias que componen un proceso estocástico estacionario están idénticamente distribuidas.

La estacionariedad en sentido débil o de segundo orden, se produce cuando todos los momentos de primer y segundo orden del proceso estocástico son invariantes en el tiempo. En particular, la esperanza matemática y la varianza de las variables y_t , pero también las covarianzas y correlaciones entre diversos retardos son independientes del tiempo.

- $\{y_t\}_1^T$, tienen todos la misma media: $E(y_t) = u \quad \forall t$
- $\{y_t\}_1^T$, tienen todos la misma varianza: $E[(y_t - u)^2] = \sigma_y^2 \quad \forall t$
- $\text{cov}(y_t, y_s) = \text{cov}(y_{t+k}, y_{s+k}) \quad \forall k$

El ruido blanco es un ejemplo de proceso estocástico estacionario de segundo orden.

El procedimiento de Box-Jenkins propone tres etapas para el estudio de las series univariantes: la identificación, la estimación y la contrastación (chequeo o diagnóstico).

2. Identificación

La identificación es el procedimiento seguido para obtener una idea aproximada de la estructura del modelo, es decir los órdenes (p,d,q) de un proceso ARIMA.

Los estadísticos fundamentales en la especificación de modelos univariantes son las funciones de autocovarianza, de autocorrelación simple y de autocorrelación parcial.

- La función de autocovarianza de un proceso estocástico $\{y_t\}$ es una función que para cada instante t y cada número entero k toma un valor, denotado por $\gamma_k(t)$, igual a la covarianza entre y_t e y_{t-k} , es decir:

$$\gamma_k(t) = \text{Cov}(y_t, y_{t-k})$$

- La función de autocorrelación simple (FAC) de un proceso estocástico $\{y_t\}$ es una función que para cada instante t y cada entero k toma un valor $\rho_k(t)$ igual a la correlación entre y_t e y_{t-k} :

$$\rho_k(t) = \frac{\text{Cov}(y_t, y_{t-k})}{\sqrt{\text{Var}.y_t} \sqrt{\text{Var}.y_{t-k}}} = \frac{\gamma_k(t)}{\sqrt{\text{Var}.y_t} \sqrt{\text{Var}.y_{t-k}}}$$

- La función de autocorrelación parcial (FACP) de un proceso estocástico $\{y_t\}$ es una función que para cada instante t y cada entero k toma un valor igual a la correlación entre y_t e y_{t-k} , ajustada por el efecto de los retardos intermedios $y_{t-1}, y_{t-2}, \dots, y_{t-k-1}$.

En un proceso estocástico estacionario, estas tres funciones son independientes del tiempo t , esta invarianza permite la estimación muestral de tales funciones. Algunas de sus propiedades son:

1. El primer valor de la FACP es la correlación entre y_t e y_{t-1} , sin que haya que corregir por ningún retardo intermedio. Por eso es que el primer valor de la FAS y la FAP de cualquier proceso estocástico coinciden.
2. El valor inicial de la FAC, p_0 , es igual a 1 en todo proceso estacionario por ser el cociente de la varianza del proceso (constante en el tiempo) por sí misma. Por tanto el valor inicial de la FACP es también igual a 1 en todo proceso estacionario.
3. Las FAC y FACP de un proceso de ruido blanco son iguales a cero, excepto en sus valores iniciales que como hemos visto son iguales a 1.
4. Las FAC y las FACP de todo proceso estocástico estacionario decrecen rápidamente hacia cero.

En síntesis, las funciones de autocorrelación (FAC) nos ayuda a identificar el tipo de proceso, AR, MA, ARMA o ARIMA, mientras que la autocorrelación parcial (FACP) ayuda a identificar el orden de los rezagos significativos.

Por ejemplo:

Para un proceso AR(1):

$$\begin{aligned} Y_t &= \delta + \phi_1 Y_{t-1} + \mu_t \\ E(Y_t) &= E(\delta + \phi_1 Y_{t-1} + \mu_t) \\ E(Y_t) &= \delta + \phi_1 E(Y_{t-1}) + E(\mu_t) \end{aligned} \quad \begin{cases} E(Y_{t-1}) = \mu \\ E(\mu_t) = 0 \end{cases}$$

$$\mu = \delta + \phi_1 \mu$$

$$\mu = \frac{\delta}{1 - \phi_1}$$

$$\phi_1 = 1 \Rightarrow \mu \rightarrow \infty$$

$$|\phi_1| < 1 \quad \text{condición de estacionariedad}$$

$$\text{Si } \delta = 0 \Rightarrow \mu = 0$$

$$\text{var}(Y_t) = \sigma_y^2 = E(Y_t - \mu)^2 = E(Y_t)^2$$

ya que $\mu = 0$

$$\sigma_y^2 = E(\phi_1 Y_{t-1} + \mu_t)$$

$$\sigma_y^2 = \phi_1^2 \text{var}(Y_{t-1}) + \text{var}(\mu_t) + 2 \text{cov}(Y_{t-1}, \mu_t)$$

siendo $2 \text{cov}(Y_{t-1}, \mu_t) = 0$

$$\sigma_y^2 = \phi_1^2 \sigma_y^2 + \sigma_\mu^2$$

$$\sigma_y^2 = \frac{\sigma_\mu^2}{1 - \phi_1^2}$$

$$\text{cov}(Y_t, Y_{t-1}) = E(Y_t Y_{t-1})$$

$$\text{cov}(Y_t, Y_{t-1}) = E[(\phi_1 Y_{t-1} + \mu_t) Y_{t-1}]$$

$$\text{cov}(Y_t, Y_{t-1}) = E[\phi_1 Y_{t-1}^2 + Y_{t-1} \mu_t]$$

$$\text{cov}(Y_t, Y_{t-1}) = \phi_1 E(Y_{t-1}^2) + E(Y_{t-1} \mu_t)$$

con $E(Y_{t-1} \mu_t) = 0$

$$\text{cov}(Y_t, Y_{t-1}) = \phi_1 \sigma_y^2$$

$$\text{cov}(Y_{t-1}, Y_{t-2}) = \phi_1 \sigma_y^2$$

$$\text{cov}(Y_t, Y_{t-2}) = \phi_1^2 \sigma_y^2$$

$$\text{cov}(Y_t, Y_{t-k}) = \phi_1^k \sigma_y^2$$

Notación

Cuando $k=0$

$$\gamma_0 = \phi_1^0 \sigma_y^2$$

$$\gamma_0 = \sigma_y^2$$

$$\gamma_k = \phi_1^k \sigma_y^2$$

siendo $\text{cov}(Y_t, Y_t) = \text{var}(Y_t) = \sigma_y^2$

$$\rho_k = \frac{\text{cov}(Y_t, Y_{t-k})}{\sqrt{\text{var}(Y_t)} \sqrt{\text{var}(Y_{t-k})}} = \frac{\gamma_k}{\gamma_0}$$

$$\rho_k = \frac{\gamma_k}{\gamma_0}$$

$$\rho_0 = \frac{\gamma_0}{\gamma_0} = 1$$

$$\rho_1 = \frac{\gamma_1}{\gamma_0} = \frac{\phi_1 \sigma_y^2}{\sigma_y^2} = \phi_1$$

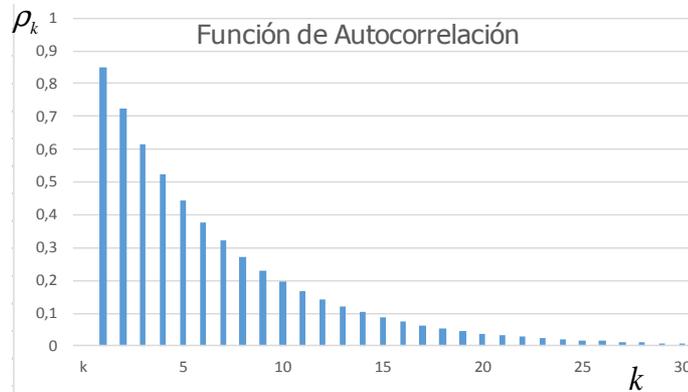
⋮

$$\rho_k = \frac{\gamma_k}{\gamma_0} = \frac{\phi_1^k \sigma_y^2}{\sigma_y^2} = \phi_1^k$$

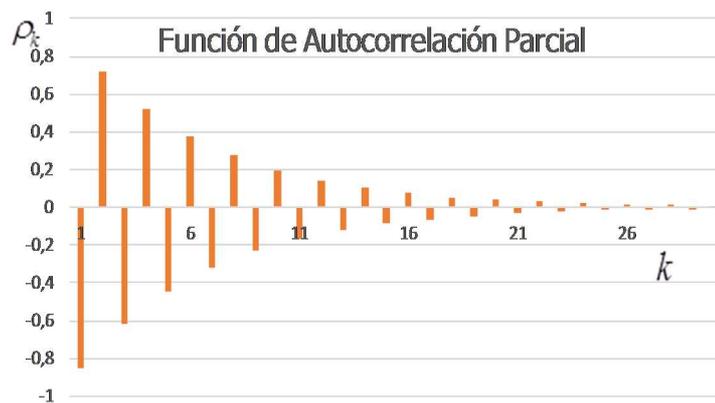
Función de Autocorrelación: Ayuda a identificar el tipo de proceso

Siendo $\rho_k = \phi_1^k$

Si $\phi_1 < 1 \wedge \phi_1 > 0$



Si $\phi_1 < 0$



Si $\phi_1 > 0$, **FAC** monotónicamente decreciente

Si $\phi_1 < 0$, **FAC** decreciente oscilatoria

FAC ayuda a identificar el tipo de proceso, si es AR, MA, ARMA, ect.

FACP es útil para reconocer el orden de los rezagos significativos.

$$\hat{\rho}_k = \frac{\hat{\gamma}_k}{\hat{\gamma}_0} \sim N\left(0, \frac{1}{T}\right)$$

Para un 95% de confianza el intervalo será: $\pm \frac{2}{\sqrt{T}}$

$$\left. \begin{array}{l} \text{FACP} \longrightarrow \phi_{11} = \rho_1 \\ \phi_{kk} = 0 \end{array} \right\} \text{ para } k \geq 2$$

Para un proceso MA(1):

FAC \longrightarrow Si $\alpha_1 > 0$, tengo un pico (+) para $k=1$, 0 para el resto

Si $\alpha_1 < 0$, tengo un pico (-) para $k=1$, 0 para el resto

FACP \longrightarrow Si $\alpha_1 > 0$, decreciente en modo oscilatorio

Si $\alpha_1 < 0$, monótonicamente decreciente

Para un proceso ARMA, las FAC y FACP poseen características de ambos procesos por lo tanto es esperable que presenten ambas una tendencia decreciente en sus coeficientes, sea monótonica o en forma oscilatoria. Si la FAC no decrece rápidamente sino muy lentamente, esto estaría indicando que el proceso es no estacionario

1. Estimación de un proceso AR(1) o AR(p) en general

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \mu_t$$

Si ρ es conocido

Son variables estocásticas no correlacionadas con μ_t

¿Cuándo aplico MCO en el proceso de estima de los parámetros?

- Si tengo regresores independientes de los errores, entonces la estima es insesgada y consistente.
- Si tengo regresores contemporáneamente no correlacionados con el error, entonces la estima es sesgada pero consistente.
- Si tengo regresores contemporáneamente correlacionados con el error, entonces la estimación es inconsistente y sesgada.

Si nos encontramos en el caso b. entonces podemos utilizar MCO.

Si ρ no es conocido

$$Y_t = f(Y_{t-k}) \quad \text{Suponiendo } \delta=0$$

$$k=1 \quad Y_t = \underbrace{\phi_1}_{\phi_{11}} Y_{t-1} + u_t$$

ϕ_{11} en la FACP este coef. debe ser estadísticamente significativo.

$$k=2 \quad Y_t = \underbrace{\phi_1 Y_{t-1} + \phi_2 Y_{t-2}}_{\phi_{22}} + u_t$$

ϕ_{22} en la FACP debe ser estadísticamente significativo.

$$\hat{\phi}_{kk} \underset{H_0}{\overset{a}{\sim}} N\left(0, \frac{1}{T}\right) \quad \text{para } k > p \quad H_0: \phi_k = 0$$

es decir, que para un 95% de confianza el intervalo será $\pm \frac{2}{\sqrt{T}}$

2. Verificación y contrastación

Una vez seleccionado el modelo ARMA y realizadas las estimaciones tratamos de ver si el modelo se ajusta a los datos en forma razonablemente buena. Una simple prueba del modelo

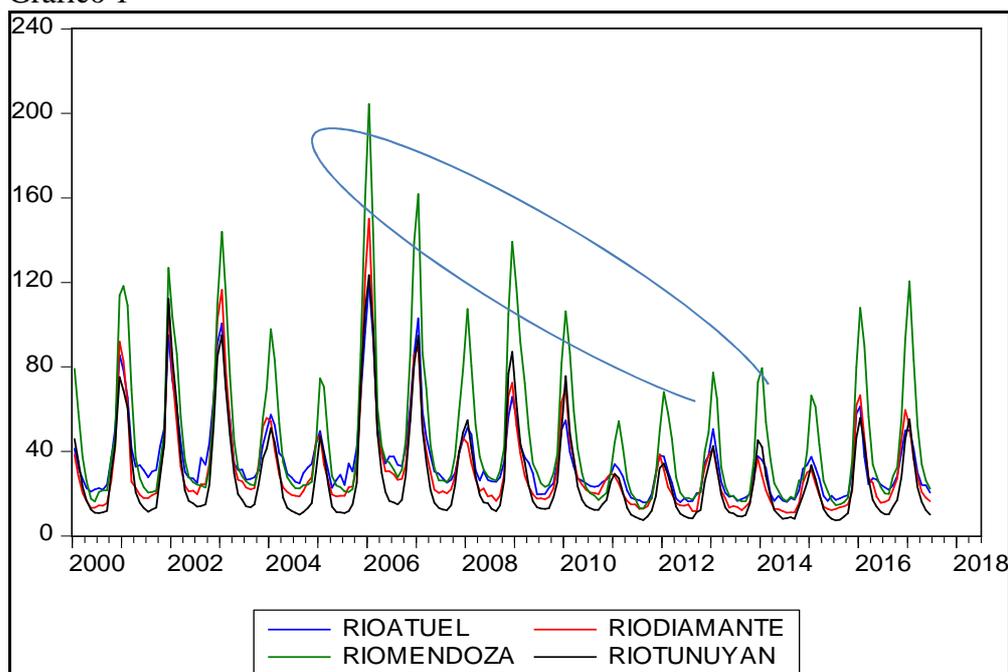
seleccionado es ver si los residuos estimados a partir de este modelo son de ruido blanco. Los residuos deben ser independientes el uno del otro, además, la media y la varianza deben ser constantes en el tiempo. Para realizar esta contrastación sobre los residuos se utiliza la prueba de Ljung-Box, es un tipo de prueba estadística de si un grupo cualquiera de autocorrelaciones de una serie de tiempo son diferentes de cero. En lugar de probar la aleatoriedad en cada retardo distinto, esta prueba la aleatoriedad "en general" basado en un número de retardos. Si la estimación es inadecuada, se tiene que volver al paso uno e intentar buscar un modelo mejor.

III. DESARROLLO

III.1. Evolución de los caudales de los principales ríos de Mendoza de los últimos 10 años

En función del desarrollo teórico presentado lo primero que se debe hacer es observar las series en nivel con las que se va a trabajar, es decir, no rezagadas. La fuente de datos utilizada son las mediciones de Caudal Medio Mensual provistas por la Red Hidrometeorológica Nacional, de la Estación Guido para el caso del Río Mendoza². Las mismas se presentan con una periodicidad mensual, es decir se mide el caudal medio mensual en m³ por segundo.

Grafico 1



Fuente: Elaboración propia con base en datos obtenidos de la red hidrometeorológica nacional.

Como se puede observar los caudales vienen disminuyendo desde hace 10 años, el último pico para el río Mendoza fue en enero del 2006 con 204 m³/ seg., la característica se repite para los otros 3 ríos analizados, por lo que el Departamento General de Irrigación habla del octavo año de crisis hídrica.

“Emergencia hídrica significa que el agua que escurre hacia los ríos de Mendoza transportan un volumen de agua que no superará la media histórica, debido a las escasas nevadas caídas durante los últimos años. Esto se traduce, según los técnicos de Irrigación, en un año hidrológico que variará entre “seco” y “pobre”. Considerándose “seco” a los valores de derrame por debajo del 65% del valor promedio histórico. En

² Para el caso del Río Atuel es la Estación: La Angostura; el Río Diamante Estación: La Jaula y el Tunuyán Estación: Valle de Uco.

cambio será “pobre” cuando el derrame esté entre el 65% y 85%, por debajo de la media histórica”³

III.2. Estimación y predicción

En la etapa de identificación del proceso de Box-Jenkins se observan cada una de las series de los caudales y sus correspondientes correlogramas⁴ para los cuatro ríos estudiados, los mismos se presentan en el ANEXO . Para el caso del Río Mendoza se puede identificar un proceso autorregresivo de orden 2, AR(2) con comportamiento estacional en los meses más cálidos como oct, nov, dic y enero donde el caudal se ve incrementado. Por lo tanto, se decide realizar la estimación presentada en la tabla 1. La estimación de los parámetros se realiza bajo el método de MCO⁵ dado que aun teniendo regresores estocásticos como la endógena rezagada, el residuo cumple hipótesis ideales de ruido blanco por lo cual no están contemporáneamente correlacionas con las regresoras⁶, por lo tanto la estimación es insesgada y consistente. Al observar el *output* de la estimación podemos afirmar que todos sus coeficientes son estadísticamente significativos, la bondad del ajuste con un R² de 86% es alta y los AIC y SIC⁷ son los más bajos de los modelos evaluados. Si se observa además el correlograma de los residuos en el ANEXO se puede verificar que los mismos presentan características de ruido blanco. Por lo que resulta un excelente modelo para realizar la proyección.

Tabla1

Dependent Variable: RIOMENDOZA				
Method: Least Squares				
Sample: 1971M01 2017M06				
Included observations: 558				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	6.132635	1.193425	5.138686	0.0000
ENE	30.88375	2.625409	11.76340	0.0000
OCT	7.454655	2.239203	3.329155	0.0009
NOV	22.72186	2.250123	10.09805	0.0000
DIC	44.44989	2.351304	18.90435	0.0000
RIOMENDOZA(-1)	0.938164	0.032484	28.88122	0.0000
RIOMENDOZA(-2)	-0.245115	0.031928	-7.677040	0.0000
R-squared	0.865438	Mean dependent var	48.55095	
Adjusted R-squared	0.863972	S.D. dependent var	37.38777	
S.E. of regression	13.78934	Akaike info criterion	8.098134	
Sum squared resid	104770.3	Schwarz criterion	8.152382	
Log likelihood	-2252.379	Hannan-Quinn criter.	8.119319	
F-statistic	590.6254	Durbin-Watson stat	1.975544	
Prob(F-statistic)	0.000000			

Por lo que la ecuación correspondiente es:

³ Lucero, J.M., Mendoza afronta su octavo año con crisis hídrica, extraído de vaconfirma.com el día 22/11/2017

http://vaconfirmamendoza.com.ar/?articulos_seccion_3539/id_4055/mendoza-afronta-su-octavo-ano-con-crisis-hidrica

⁴ Muestra la función de Autocorrelación y Autocorrelación Parcial para cada una de las series de tiempo seleccionadas.

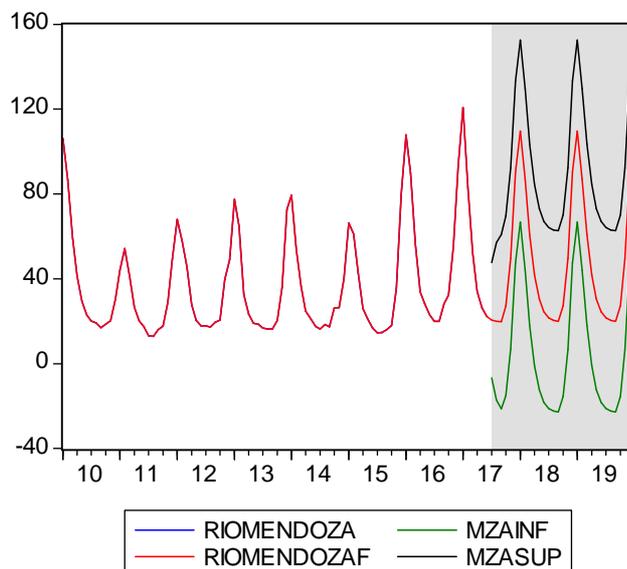
⁵ Mínimos Cuadrados Ordinarios

⁶ Es uno de los casos en los cuales se usa MCO dado que se tiene regresores independientes de los errores

⁷ Akaike Information Criterion y Schwarz Information Criteria, son los estadísticos usados para la comparación de modelos y se selecciona el de menor valor entre los modelos estimados.

$$\text{RIOMENDOZA} = 6.132635279 + 30.88374513 \cdot \text{ENE} + 7.454654952 \cdot \text{OCT} + 22.72186009 \cdot \text{NOV} + 44.44988578 \cdot \text{DIC} + 0.9381640836 \cdot \text{RIOMENDOZA}(-1) - 0.2451145078 \cdot \text{RIOMENDOZA}(-2)$$

Grafico 2



En el grafico 2, a partir de la ecuación estimada se realizan las predicciones mediante el uso del software Eviews. En la misma se observa que si bien la tendencia de la última década mostró una reducción en los caudales medios, los datos de los últimos 2 años reflejan un cambio de tendencia, y como éstos son los que por resultar el modelo un AR(2) los que más relevancia adquieren en el pronóstico, se corrige la tendencia de la caída y la predicción se mantiene aproximadamente en los valores de los últimos años. El pronóstico para el año 2019 y 2020 con esta metodología arroja valores promedio algo superiores a la media de la última década. Cabe destacar que estos resultados se aproximan a los modelos de pronóstico utilizados por el Departamento General de Irrigación⁸.

Para el caso del Rio Tunuyán, tabla 2, también se identificó un proceso ar(2) observando el correlograma que se encuentra en el Anexo, por lo que se procedió a realizar la correspondiente estimación. En la misma se observa también un buen ajuste dado por el 87% de su R² todos los coeficientes significativos, el AIC y el SIC menor de los modelos evaluados, por lo que se elige este modelo para realizar la predicción. También en este caso observando el correlograma de los residuos se ve que presentan características de ruido blanco.

⁸ Diario Los Andes, Artículo “Por la crisis hídrica, Irrigación restringe la distribución de agua” 20 de Noviembre 2017.

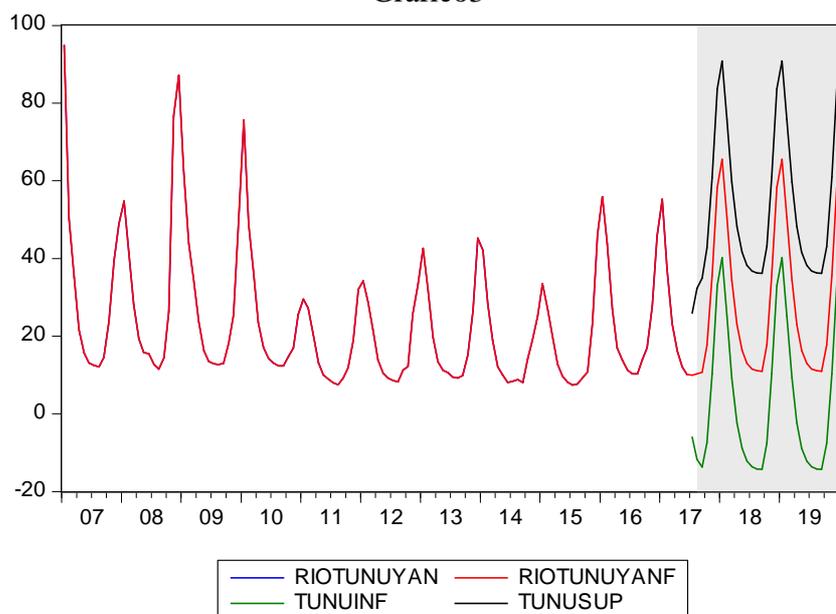
Tabla 2

Dependent Variable: RIOTUNUYAN				
Method: Least Squares				
Sample: 1971M01 2017M06				
Included observations: 558				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	3.457987	0.676075	5.114797	0.0000
ENE	15.85904	1.577451	10.05359	0.0000
OCT	6.773658	1.319080	5.135139	0.0000
NOV	18.06172	1.340780	13.47105	0.0000
DIC	25.68561	1.461363	17.57647	0.0000
RIOTUNUYAN(-1)	0.950967	0.033685	28.23081	0.0000
RIOTUNUYAN(-2)	-0.260858	0.032245	-8.089817	0.0000
R-squared	0.878201	Mean dependent var	28.98429	
Adjusted R-squared	0.876875	S.D. dependent var	23.10516	
S.E. of regression	8.107414	Akaike info criterion	7.035900	
Sum squared resid	36217.32	Schwarz criterion	7.090149	
Log likelihood	-1956.016	Hannan-Quinn criter.	7.057086	
F-statistic	662.1423	Durbin-Watson stat	1.933199	
Prob(F-statistic)	0.000000			

$$RIOTUNUYAN = 3.457987224 + 15.85903801*ENE + 6.773657736*OCT + 18.06172193*NOV + 25.68560782*DIC + 0.9509669248*RIOTUNUYAN(-1) - 0.260857892*RIOTUNUYAN(-2)$$

En el grafico 3 se observan las predicciones obtenidas con el modelo estimado para el Río Tunuyán, se puede ver que los últimos tres valores más altos corresponden a enero 2018, 2019 y 2020.

Grafico3



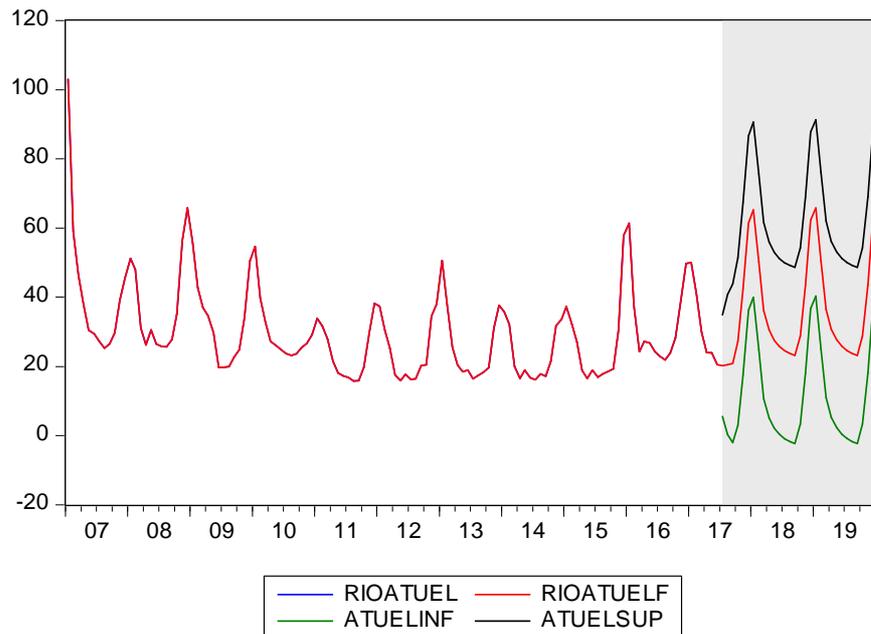
Con el Rio Atuel la identificación y estimación resulto la siguiente:

Tabla 3

Dependent Variable: RIOATUEL				
Method: Least Squares				
Sample: 1971M01 2017M06				
Included observations: 558				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	4.903903	0.814000	6.024452	0.0000
ENE	9.460462	1.611317	5.871260	0.0000
FEB	-5.968262	1.499078	-3.981288	0.0001
MAR	-4.975539	1.390897	-3.577218	0.0004
OCT	6.058994	1.213289	4.993859	0.0000
NOV	15.38447	1.246643	12.34072	0.0000
DIC	21.00511	1.416026	14.83385	0.0000
RIOATUEL(-1)	0.948767	0.041057	23.10855	0.0000
RIOATUEL(-2)	-0.173931	0.037417	-4.648508	0.0000
R-squared	0.862432	Mean dependent var	36.82534	
Adjusted R-squared	0.860428	S.D. dependent var	19.97746	
S.E. of regression	7.463451	Akaike info criterion	6.873910	
Sum squared resid	30581.00	Schwarz criterion	6.943658	
Log likelihood	-1908.821	Hannan-Quinn criter.	6.901149	
F-statistic	430.2209	Durbin-Watson stat	2.082532	
Prob(F-statistic)	0.000000			

$$\text{RIOATUEL} = 4.903902564 + 9.460461665 \cdot \text{ENE} - 5.968262144 \cdot \text{FEB} - 4.97553947 \cdot \text{MAR} + 6.058994281 \cdot \text{OCT} + 15.38447329 \cdot \text{NOV} + 21.00511399 \cdot \text{DIC} + 0.9487673268 \cdot \text{RIOATUEL}(-1) - 0.1739310573 \cdot \text{RIOATUEL}(-2)$$

Grafico 4



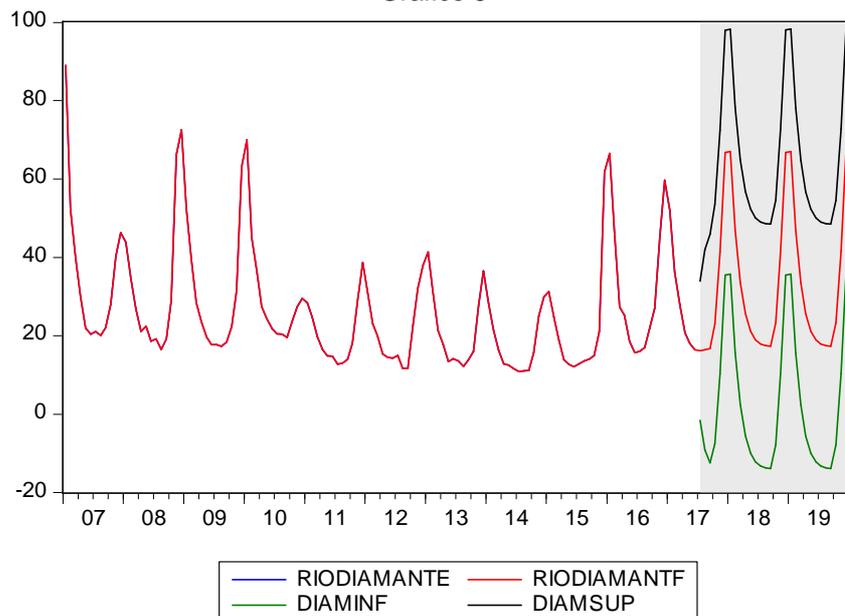
Para el Río Diamante se obtuvieron resultados similares respecto a la identificación y la estimación fue:

Tabla 4

Dependent Variable: RIODIAMANTE				
Method: Least Squares				
Sample (adjusted): 1971M03 2017M06				
Included observations: 556 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	4.463054	0.780062	5.721412	0.0000
ENE	5.652488	2.009509	2.812871	0.0051
FEB	-7.404258	1.712470	-4.323731	0.0000
OCT	6.009904	1.462025	4.110671	0.0000
NOV	18.01327	1.494656	12.05178	0.0000
DIC	26.20975	1.701239	15.40627	0.0000
RIODIAMANTE(-1)	1.031435	0.040174	25.67445	0.0000
RIODIAMANTE(-2)	-0.288107	0.034314	-8.396240	0.0000
R-squared	0.860565	Mean dependent var	33.02817	
Adjusted R-squared	0.858784	S.D. dependent var	24.09400	
S.E. of regression	9.054221	Akaike info criterion	7.258623	
Sum squared resid	44924.44	Schwarz criterion	7.320792	
Log likelihood	-2009.897	Hannan-Quinn criter.	7.282906	
F-statistic	483.1636	Durbin-Watson stat	2.002045	
Prob(F-statistic)	0.000000			

$$\text{RIODIAMANTE} = 4.463053849 + 5.652487734 \cdot \text{ENE} - 7.404257721 \cdot \text{FEB} + 6.009903746 \cdot \text{OCT} + 18.01326763 \cdot \text{NOV} + 26.20974745 \cdot \text{DIC} + 1.031434979 \cdot \text{RIODIAMANTE}(-1) - 0.2881073079 \cdot \text{RIODIAMANTE}(-2)$$

Grafico 5



III.3. Confrontación de la predicción

A efectos de realizar una comparación de los valores predichos por el método de Box-Jenkins con los valores observados por la Secretaría de Infraestructura y Política Hídrica de la Nación, para el aforo Guido del Río Mendoza, se considera una buena *performance* de los pronósticos según se pueden ver en el gráfico 6 y la tabla 5. El error de un pronóstico e_t se define como $e_t = A_t - F_t$ donde A_t es el caudal real u observado en el período t y F_t es el caudal pronosticado para el mismo período. Al aplicar el test t-Student para la comparación de lo real con lo pronosticado la probabilidad resultante es de 0,46134201, por lo cual el valor crítico cae en la zona de aceptación de hipótesis nula de que no hay diferencias estadísticas entre lo observado y lo predicho.

Grafico 6

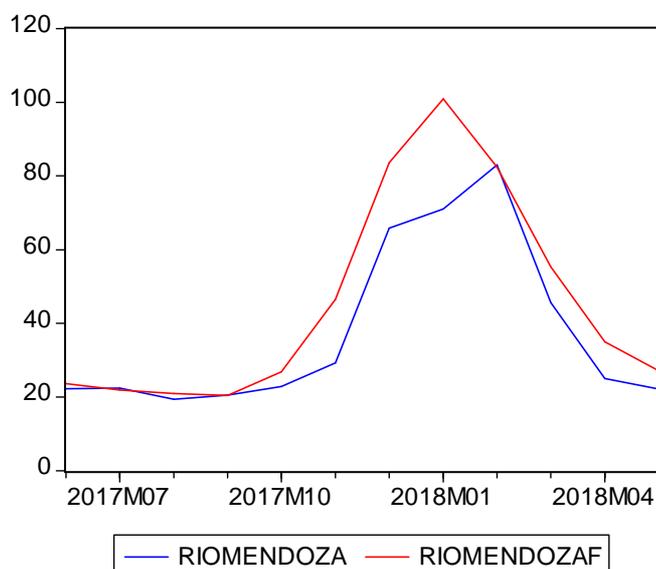


Tabla 5

obs	RIOMENDOZA	RIOMENDOZAF
2017M06	22.22600	23.62915
2017M07	22.37000	21.90507
2017M08	19.41000	20.96817
2017M09	20.47000	20.42827
2017M10	22.81500	26.83067
2017M11	29.25000	46.55687
2017M12	65.80000	83.56395
2018M01	71.00000	100.9375
2018M02	83.00000	82.37754
2018M03	45.66667	55.39098
2018M04	25.00000	35.01622
2018M05	22.17000	27.10697

IV. CONSIDERACIONES FINALES

La literatura dedicada al tratamiento de los caudales de los ríos se basa primordialmente en realizar pronósticos a partir de modelos teóricos que incluyen las precipitaciones y acumulación nívea. En esta investigación se ha centrado la atención en la evolución de la serie histórica caudales de los cuatro ríos más importantes de Mendoza para establecer una estimación de corto plazo, basada sólo en la información provista por las series y sus autocorrelaciones.

Dados los objetivos planteados inicialmente, se encontró que las cuatro series estudiadas reflejaron un comportamiento autorregresivo de orden dos; esto implica que en las proyecciones realizadas tengan una mayor relevancia los últimos dos años de datos observados. Por lo que en todos los casos pudimos observar que el pronóstico realizado con esta metodología refleja valores pobres para el año 2018, pero no así para el 2019 que visualiza un cambio de tendencia solo evidenciado por el comportamiento de sus datos.

Tal como fue indicado en el pronóstico para 2018, los Ríos Mendoza, Tunuyán, Diamante y Atuel permanecerán medianamente pobres cuyo caudal se ha visto disminuido en los últimos 10 años. Esto ha provocado entre otras cosas un retroceso de la superficie cultivada y por tanto, el abandono de terrenos aptos para cultivos presa fácil de los emprendimientos inmobiliarios que se multiplicaron por Luján, Guaymallén y el este provincial.

Para el caso del Río Mendoza, como los otros ríos analizados la predicción dinámica arroja valores promedio similares a los verificados por el DGI para el año 2018, pero también se observa un cambio de tendencia en el pronóstico de 2019, con respecto a la evolución de la última década. Si bien estos datos avizoran una mejora relativa, cabe destacar que es sólo una metodología práctica.

V. BIBLIOGRAFIA

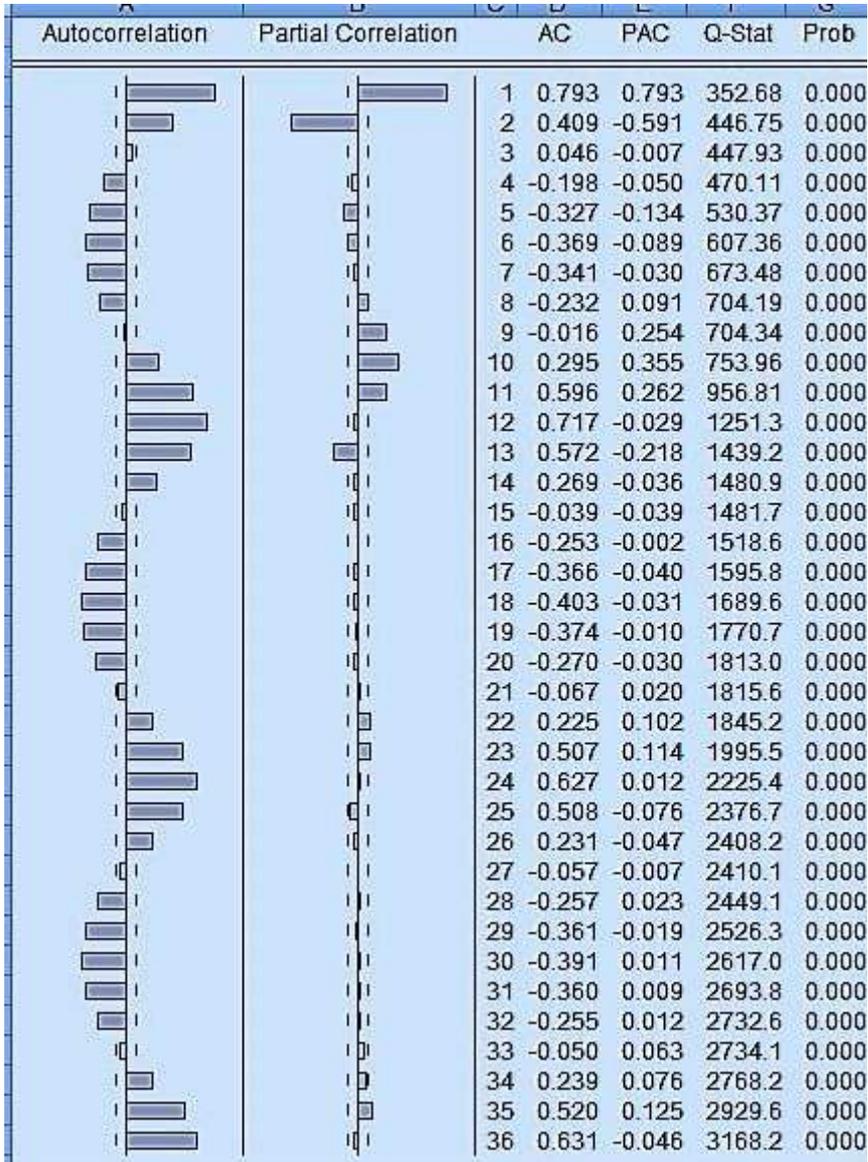
- Box, G. E. P., & Jenkins, G. M. (1973). Some comments on a paper by Chatfield and Prothero and on a review by Kendall. *Journal of the Royal Statistical Society. Series A (General)*, 136(3), 337-352.
- GUJARATI, D. y PORTER, D., *Econometría*, 5ta. Edición, Mc Graw-Hill, México, 2010.
- Harvey, A. C., & Todd, P. H. J. (1983). Forecasting economic time series with structural and Box-Jenkins models: A case study. *Journal of Business & Economic Statistics*, 1(4), 299-307.
- Milana, Juan Pablo. (1998). Predicción de caudales de ríos alimentados por deshielo mediante balances de energía: Aplicación en los Andes Centrales, Argentina. *Revista de la Asociación Argentina de Sedimentología*, 5(2), 53-69. Recuperado en 01 de noviembre de 2017, de http://www.scielo.org.ar/scielo.php?script=sci_arttext&pid=S1853-63601998000200001&lng=es&tlng=es.
- PINDYCK, R.S. and RUBINFELD, D.L., *Econometría modelos and pronósticos*, 4ta. edición, Mc Graw-Hill, 2001.
- VANDAELE, W. *Applied Time Series and Box-Jenkins Models*. Ed. Academic Press. Bibliografía indexada: Última modificación: 22/09/2005 SIN CLASIFICAR... www.uva.es/consultas/guia.php?menu=completo&ano_academico=0607&codigo_plan=247&codigo_asignatura=43595&grupo=1
- Vich, Alberto Ismael Juan, Norte, Federico Augusto, & Lauro, Carolina. (2014). Análisis regional de frecuencias de caudales de ríos pertenecientes a cuencas con nacientes en la cordillera de Los Andes. *Meteorologica*, 39(1), 3-26. Recuperado en 01 de noviembre de 2017, de http://www.scielo.org.ar/scielo.php?script=sci_arttext&pid=S1850-468X2014000100001&lng=es&tlng=es.

ANEXO

1. Correlograma del Río Mendoza

FAC

FACP



Correlograma de los residuos estimación Río Mendoza

Sample: 1971M01 2017M06

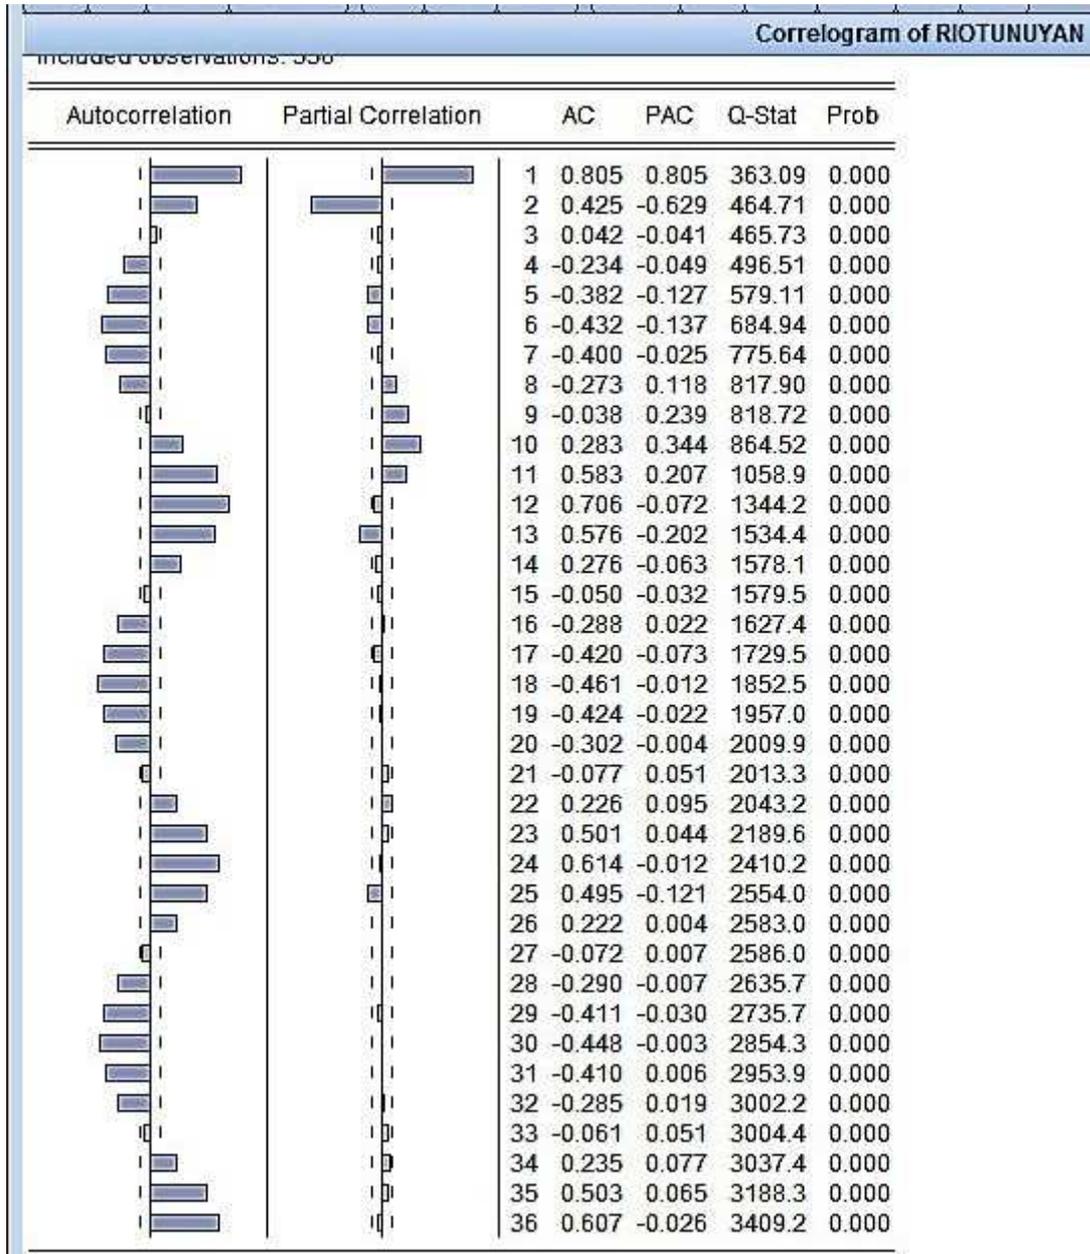
Included observations: 558

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
. .	. .	1	0.008	0.008	0.0374	0.847
. .	. .	2	0.055	0.055	1.7671	0.413
. .	. .	3	0.029	0.028	2.2357	0.525
. .	. .	4	0.061	0.058	4.3458	0.361
. .	. .	5	0.048	0.045	5.6688	0.340
. .	. .	6	0.049	0.041	7.0023	0.321
. .	. .	7	0.031	0.023	7.5597	0.373
. .	. .	8	0.023	0.013	7.8594	0.447
. .	. .	9	0.029	0.019	8.3305	0.501
. *	. *	10	0.081	0.072	12.111	0.278
. *	. *	11	0.113	0.105	19.406	0.054
. *	. *	12	0.103	0.092	25.447	0.013
. .	. .	13	-0.005	-0.023	25.462	0.020
. *	. .	14	0.074	0.051	28.606	0.012
. .	. .	15	0.019	-0.002	28.806	0.017
. .	. .	16	0.033	0.003	29.425	0.021
. .	. .	17	0.028	0.008	29.884	0.027
. .	. .	18	0.012	-0.009	29.963	0.038
. .	. .	19	0.012	-0.003	30.053	0.051
. .	. .	20	0.007	-0.012	30.083	0.069
. .	. .	21	0.011	-0.015	30.151	0.089
. .	. .	22	0.050	0.022	31.616	0.084
. .	. .	23	0.032	0.010	32.207	0.096
. .	. .	24	-0.031	-0.051	32.767	0.109
. .	. .	25	0.019	0.003	32.982	0.132
. *	. .	26	0.071	0.057	35.963	0.092
. .	. .	27	-0.000	-0.008	35.963	0.116
. .	. .	28	0.027	0.013	36.406	0.133
. .	. .	29	0.009	0.004	36.456	0.161
. .	. .	30	0.022	0.015	36.741	0.185
. .	. .	31	0.024	0.019	37.091	0.209
. .	. .	32	-0.012	-0.024	37.183	0.243
. .	. .	33	0.041	0.027	38.191	0.245
. .	. .	34	0.030	0.025	38.730	0.265
. *	. *	35	0.082	0.084	42.776	0.172
. .	. .	36	0.019	0.012	42.989	0.197

2. Correlograma del Río Tunuyán

FAC

FACP



Correlograma de los residuos estimación Río Tunuyán

Sample: 1971M01 2017M06

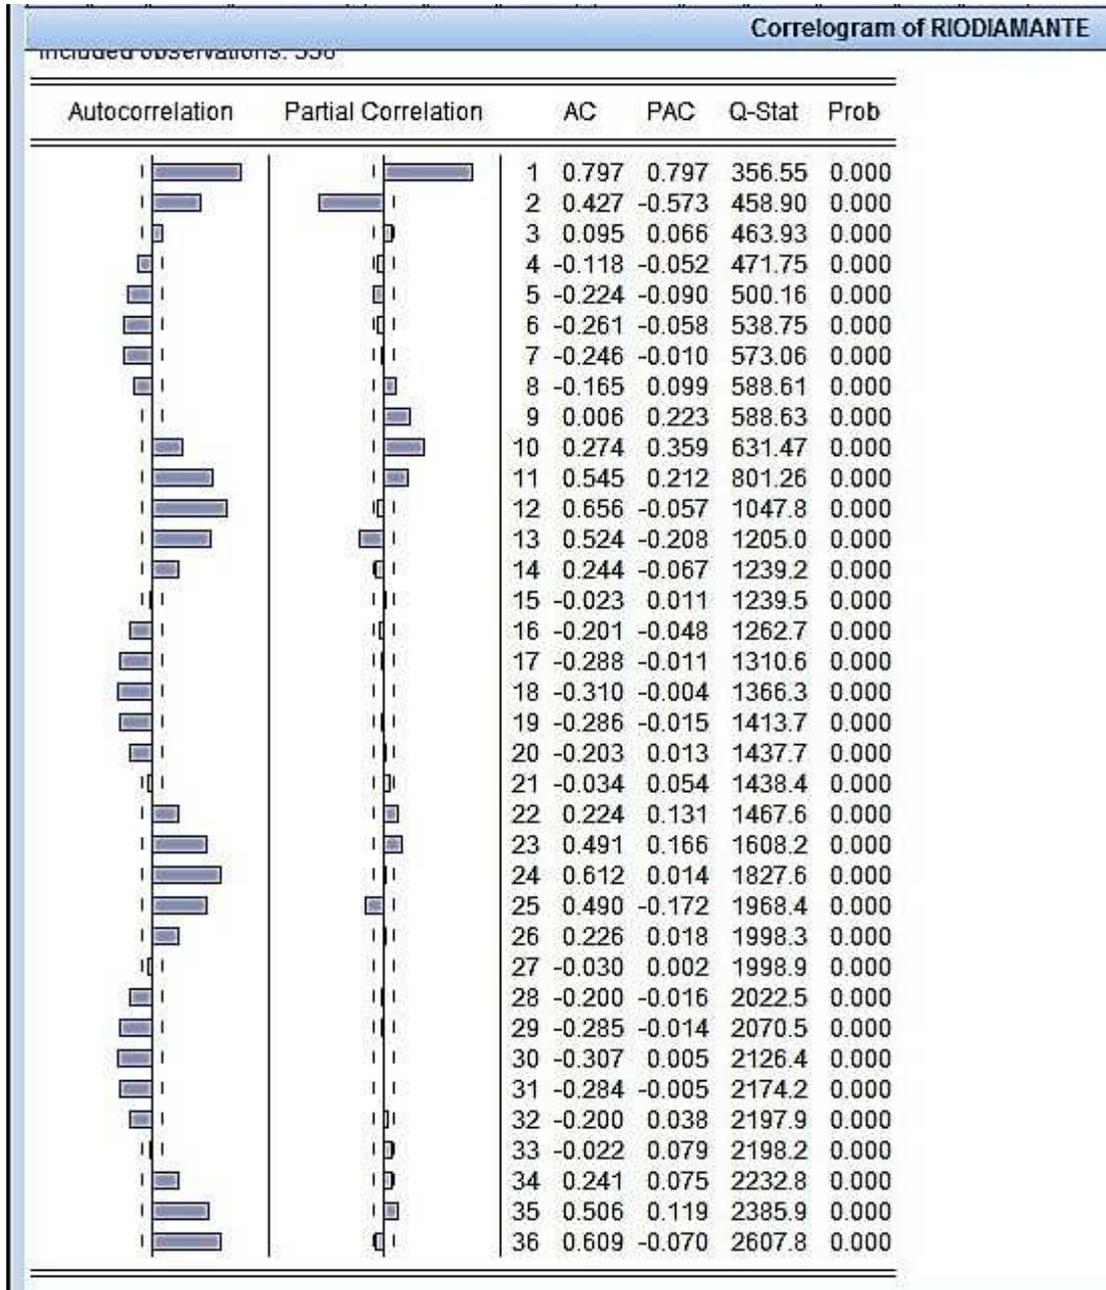
Included observations: 558

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
. .	. .	1	0.030	0.030	0.5078	0.476
. *	. *	2	0.089	0.088	4.9611	0.084
. .	. .	3	0.048	0.044	6.2766	0.099
. .	. .	4	0.016	0.006	6.4160	0.170
. .	. .	5	0.047	0.038	7.6382	0.177
. .	. .	6	0.039	0.034	8.5152	0.203
. .	. .	7	0.001	-0.009	8.5159	0.289
. .	. .	8	0.039	0.030	9.3803	0.311
. .	. .	9	0.012	0.007	9.4596	0.396
. .	. .	10	0.046	0.038	10.648	0.386
. *	. *	11	0.098	0.090	16.132	0.136
. .	. .	12	0.055	0.043	17.870	0.120
. .	. .	13	0.030	0.008	18.401	0.143
. *	. .	14	0.082	0.065	22.299	0.073
. .	. .	15	-0.022	-0.037	22.582	0.093
. .	. .	16	0.034	0.011	23.250	0.107
. .	. .	17	-0.011	-0.022	23.316	0.139
. .	. .	18	0.007	-0.000	23.343	0.178
. .	. .	19	0.001	-0.010	23.343	0.223
. .	. .	20	-0.003	-0.009	23.347	0.272
. .	. .	21	0.004	-0.002	23.358	0.325
. *	. .	22	0.069	0.055	26.110	0.247
. .	. .	23	-0.025	-0.036	26.477	0.279
. .	. .	24	-0.017	-0.039	26.651	0.321
. .	. .	25	-0.008	-0.018	26.689	0.372
. .	. .	26	0.023	0.027	27.002	0.409
. .	. .	27	0.009	0.005	27.047	0.461
. .	. .	28	0.011	0.005	27.122	0.512
. .	. .	29	-0.011	-0.005	27.195	0.561
. .	. .	30	0.004	-0.000	27.204	0.613
. .	. .	31	-0.015	-0.010	27.342	0.655
. .	. .	32	-0.003	-0.009	27.348	0.701
. .	. .	33	0.025	0.022	27.735	0.727
. .	. .	34	0.050	0.055	29.243	0.700
. .	. .	35	0.011	0.013	29.320	0.738
. .	. .	36	0.028	0.015	29.779	0.758

3. Correlograma del Río Diamante

FAC

FACP



Correlograma de los residuos estimación Río Diamante

Sample: 1971M03 2017M06

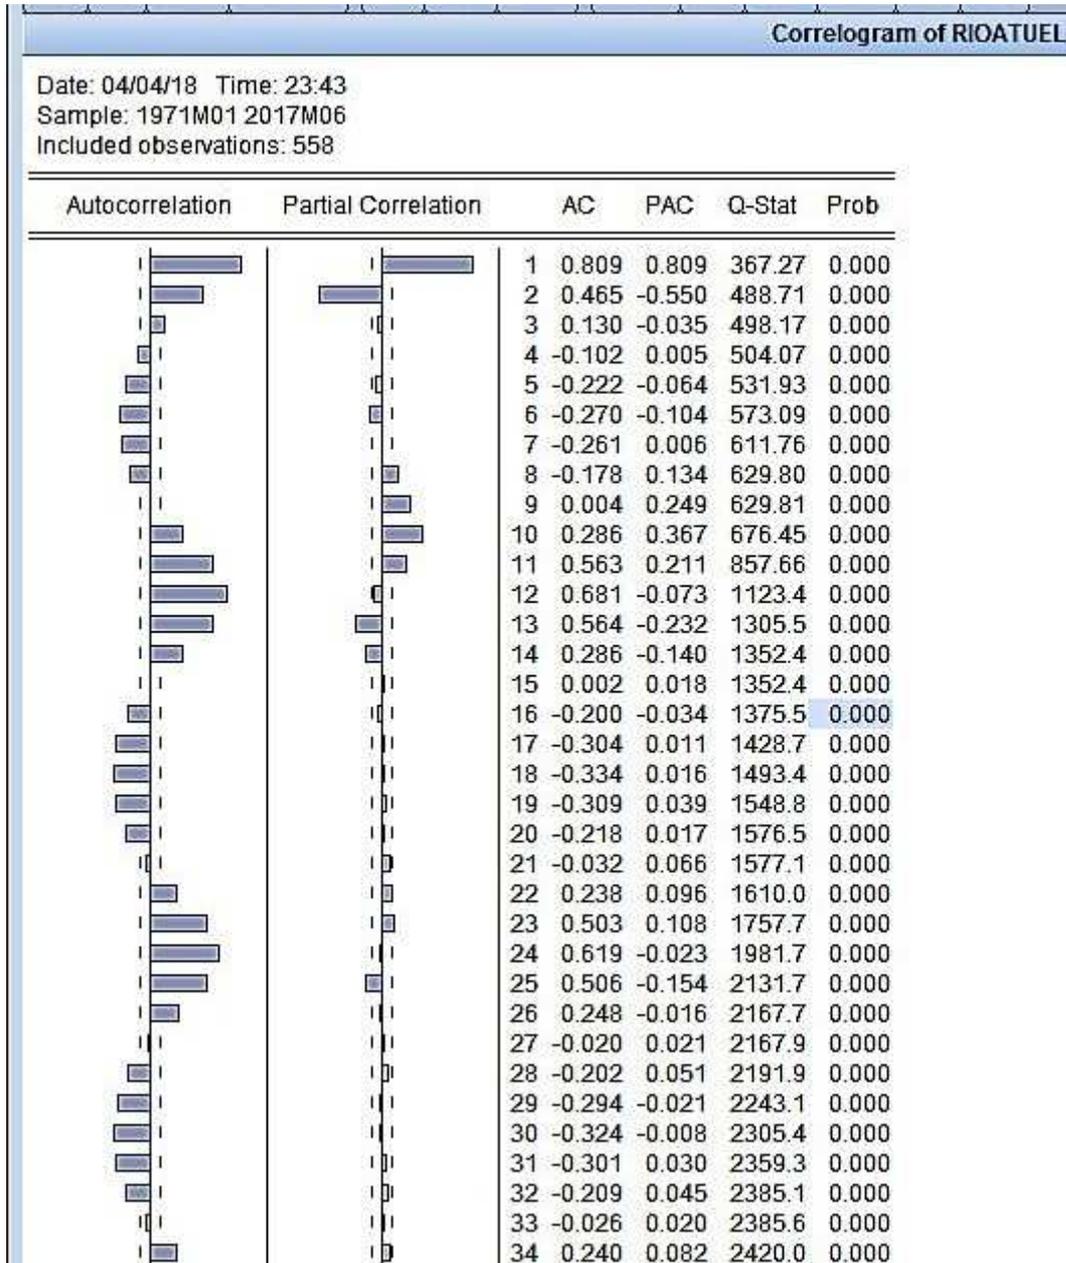
Included observations: 556

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
. .	. .	1	-0.001	-0.001	0.0007	0.978
. .	. .	2	0.002	0.002	0.0034	0.998
. .	. .	3	0.010	0.010	0.0611	0.996
. .	. .	4	0.048	0.048	1.3464	0.853
. .	. .	5	0.053	0.053	2.9102	0.714
. .	. .	6	0.048	0.048	4.2097	0.648
. .	. .	7	0.027	0.027	4.6297	0.705
. .	. .	8	0.050	0.047	6.0269	0.644
. .	. .	9	-0.019	-0.025	6.2387	0.716
. *	. *	10	0.106	0.099	12.586	0.248
. *	. *	11	0.101	0.095	18.344	0.074
. .	. .	12	0.031	0.026	18.901	0.091
. .	. .	13	0.036	0.033	19.649	0.104
. .	. .	14	0.033	0.023	20.268	0.122
. .	. .	15	0.034	0.018	20.950	0.138
. .	. .	16	0.020	-0.001	21.172	0.172
. .	. .	17	0.003	-0.013	21.179	0.218
. .	. .	18	0.026	0.004	21.574	0.251
. .	. .	19	0.017	0.004	21.739	0.297
. .	. .	20	0.021	0.006	21.992	0.341
. .	. .	21	0.013	-0.012	22.094	0.394
. .	. .	22	0.045	0.028	23.289	0.386
. .	. .	23	0.035	0.022	24.012	0.403
. *	. *	24	0.097	0.086	29.470	0.203
. .	. .	25	0.011	0.001	29.538	0.242
. .	. .	26	0.045	0.034	30.706	0.239
. .	. .	27	0.024	0.018	31.057	0.269
. .	. .	28	0.021	0.007	31.324	0.303
. .	. .	29	-0.002	-0.018	31.325	0.350
. .	. .	30	0.026	0.007	31.730	0.380
. .	. .	31	0.019	0.006	31.939	0.420
. .	. .	32	-0.017	-0.039	32.116	0.461
. .	. .	33	0.019	0.006	32.340	0.500
. .	. .	34	0.056	0.026	34.196	0.458
. *	. *	35	0.124	0.107	43.406	0.156
. .	. .	36	0.046	0.039	44.680	0.152

4. Correlograma del Río Atuel

FAC

FACP



Correlograma de los residuos estimación Rio Atuel

Sample: 1971M01 2017M06

Included observations: 558

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
. .	. .	1	-0.045	-0.045	1.1123	0.292
. .	. .	2	0.038	0.036	1.9359	0.380
. .	. .	3	0.028	0.032	2.3886	0.496
. .	. .	4	-0.010	-0.009	2.4504	0.654
. .	. .	5	0.042	0.039	3.4311	0.634
. .	. .	6	0.050	0.053	4.8193	0.567
. .	. .	7	-0.003	-0.001	4.8239	0.681
. .	. .	8	0.023	0.017	5.1235	0.744
. .	. .	9	-0.029	-0.029	5.6019	0.779
. .	. .	10	0.045	0.041	6.7464	0.749
. *	. *	11	0.081	0.083	10.505	0.486
. *	. *	12	0.068	0.073	13.131	0.360
. *	. *	13	0.070	0.068	15.963	0.251
. .	. .	14	0.016	0.016	16.108	0.307
. .	. .	15	0.065	0.062	18.545	0.235
. .	. .	16	-0.011	-0.019	18.620	0.289
. .	. .	17	-0.000	-0.018	18.621	0.351
. .	. .	18	0.015	-0.002	18.746	0.408
. .	. .	19	0.013	0.010	18.848	0.467
. .	. .	20	0.000	-0.004	18.848	0.532
. .	. .	21	0.034	0.024	19.516	0.552
. .	. .	22	0.021	0.019	19.781	0.597
. .	. .	23	0.030	0.013	20.300	0.624
. *	. *	24	0.087	0.075	24.754	0.419
. .	. .	25	0.005	-0.007	24.767	0.475
. .	. .	26	0.045	0.022	25.931	0.467
. .	. .	27	-0.005	-0.016	25.946	0.522
. .	. .	28	0.021	0.013	26.202	0.562
. .	. .	29	0.024	0.016	26.529	0.597
. .	. .	30	0.019	0.011	26.735	0.637
. .	. .	31	-0.014	-0.017	26.859	0.679
. .	. .	32	0.030	0.018	27.385	0.699
. .	. .	33	0.004	0.004	27.395	0.742
. .	. .	34	0.035	0.015	28.135	0.750
. .	. .	35	0.026	0.010	28.551	0.771
. *	. *	36	0.115	0.099	36.414	0.449