

32959



PRECIPITACIONES PLUVIALES DE LA PROVINCIA DE CORRIENTES. SERIES CRONOLOGICAS.


INFORME FINAL

Dr. Heriberto L. Urbisaia

DR. HERIBERTO L. URBISAIA

CIENCIAS ECONOMICAS

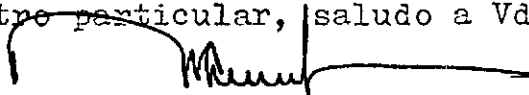
Buenos Aires, 23 de mayo de 1988.-



Consejo Federal de Inversiones
Capital Federal-----

Tengo el agrado de dirigirme a Vd. con el fin de solicitar cuatro (4) ejemplares del informe final sobre precipitaciones pluviales en la Provincia de Corrientes.-

Sin otro particular, saludo a Vd. atte.-


Heriberto Luis Urbisaia

PRECIPITACIONES PLUVIALES EN LA PROVINCIA DE CORRIENTES. SERIES CRONOLOGICAS.

INFORME FINAL



I.- ANTECEDENTES.

Como introducción al cuarto y último informe sobre "Precipitaciones Pluviales en la Provincia de Corrientes", se ha considerado conveniente efectuar una síntesis de los estudios previos, relacionando, en particular, las conclusiones a que se arribó en las diferentes etapas.

El análisis exploratorio de la información de base anual (Primer Informe), tuvo por objetivo identificar componentes de largo plazo : tendencia y movimientos cíclicos. Al respecto, los resultados obtenidos revelaron, no sólo la ausencia de tendencia (coeficientes del ajuste no significativos en diez de las trece series estudiadas), sino también la naturaleza aleatoria de las fluctuaciones en torno a valores medios (ausencia de ciclos), a través del comportamiento del estadístico "d" .


La aplicación de las técnicas del Análisis Espectral a las series anuales y mensuales (Segundo Informe), permitió, en principio, indagar con mayor fineza, sobre la naturaleza de las fluctuaciones observadas. Para las series anuales, los estadísticos empleados en este caso, siguieron no significativos, confirmando la ausencia de ciclos; sin embargo, al pasar a la información

de base mensual, los estadísticos Kappa y de Smirnov-Kolmogorov resultaron significativos : en la mayoría de los casos se detectó un ciclo principal de doce meses, y otro secundario de seis meses.

La aplicación de la metodología de Box-Jenkins, con vistas a la modelización de las series anuales (Tercer Informe), permitió llegar, tras sucesivos ensayos, a la conclusión de que las series son aleatorias : ninguno de los modelos preseleccionados lograron captar el comportamiento de los residuos con mejor performance que la obtenida a partir de la media aritmética del período muestral.

El Cuarto y último Informe completa el análisis de las series de precipitaciones pluviales, aplicando la metodología de Box-Jenkins a la información de base mensual. Se procura, en esta forma, modelizar las series, incorporando en los modelos ARIMA el factor estacional.

Desarrollamos, a continuación, las ideas y conceptos básicos sobre el tema, a los efectos de facilitar la interpretación y evaluación de los resultados.



II.- MODELOS ESTACIONALES .

II.1 Concepto

Cuando en el análisis estadístico se utiliza información con oscilaciones periódicas dependientes de las estaciones del año, se dice que el fenómeno sujeto a estudio presenta fluctuaciones estacionales. Este es, precisamente, el caso de las precipitaciones pluviales que nos ocupa, con datos de base mensual. La incorporación del factor estacional en el proceso de modelización de la serie, da origen a los modelos ARIMA estacionales, que se indican como "modelos SARIMA_s", donde la letra S proviene del término inglés "seasonal", (estacional), y s representa la longitud de la onda estacional ; por ejemplo, s = 12 si trabajamos con datos mensuales.

II.2 Diferentes Tipos

a) Modelos Estacionales Puros : en los que cada observación se relaciona solamente con observaciones distantes de la anterior, s períodos ó múltiplos de s .

Así, un modelo estacional puro automegresivo de orden 1, y período s, es de la forma :

$$\text{SAR } (1)_s : Y_t = \phi_s Y_{t-s} + u_t$$


siendo { Y_t } una serie estacionaria, que no requiere diferenciación, y { u_t } : rui-

Introduciendo el operador de retardos L (L^s Y_t = Y_{t-s}) puede expresarse :

$$\text{SAR } (1)_s : (1 - \phi_s L^s) Y_t = u_t$$

La función de autocorrelación (FAC), correspondiente al SAR (1)_s es de la forma :

$$\rho_k = \begin{cases} 1 & k = 0 \\ \phi_s \rho_{k-s} & k = s, 2s, 3s, \dots \\ 0 & \text{en los demás casos} \end{cases}$$




El modelo estacional puro, promedio móvil de orden 1, y período s , es de la forma :

$$\text{SMA } (1)_s : Y_t = u_t - \theta_s u_{t-s} = (1 - \theta_s L^s) u_t$$

Y la FAC :

$$\rho_k = \begin{cases} 1 & k = 0 \\ \frac{\theta_s}{1 + \theta_s^2} & k = s \\ 0 & \text{en los demás casos} \end{cases}$$



Como puede apreciarse, en la etapa de identificación se aplican los conceptos similares a los utilizados para los modelos AR y MA, considerando únicamente las ordenadas correspondientes a los desfases s , $2s$, $3s$, etc.

En general indicaremos con :

$\text{SAR } (P)_s$: modelo estacional puro, autorregresivo de orden P , y período s .

$\text{SMA } (Q)_s$: modelo estacional puro, de promedio móvil de orden Q , y período s .

$\text{SARMA } (P,Q)_s$: modelo estacional puro, autorregresivo de orden P , de promedio móvil de orden Q , y período s .

Para series no estacionarias, que requieren un número D de diferenciaciones estacionales, hasta lograr estacionariedad :

$\text{SARIMA } (P,D,Q)_s$: modelo estacional puro autorregresivo, integrado, de promedio móvil de orden P , D , Q , y período s .

b) Modelos Multiplicativos

Los modelos estacionales puros suponen que la observación de un mes particular, por ejemplo Marzo, se vincula sólo con observaciones del mismo mes, correspondientes a años anteriores. No tienen en cuenta, por tanto, la proba-

ble relación entre observaciones consecutivas dentro de cada año, situación que corresponde a la mayoría de los fenómenos estacionales.

Los modelos estacionales multiplicativos apuntan a cubrir esta necesidad, combinando el modelo ARIMA (p,d,q) tratado en el informe anterior, en adelante "modelo regular", con el estacional puro SARIMA (P,D,Q)_s, captando de esta manera, la correlación entre observaciones sucesivas. En términos generales, se simbolizan de la siguiente manera :


ARMA (p,q) x SARMA (P,Q)_s para series estacionarias

ARIMA (p,d,q) x SARIMA (P,D,Q)_s si las series requieren diferenciaciones de orden d, en la parte "regular", y de orden D en la "estacional".


La FAC correspondiente a este tipo de modelos, presenta las siguientes características :

- i) Para desfases bajos, (hasta $k = s/2$), sólo aparece la estructura del modelo regular.
- ii) En los desfases $k = s, 2s, 3s, \dots$, se manifiesta el efecto de la fluctuación estacional..
- iii) En los desfases próximos a múltiplos de s, se reproduce simétricamente la estructura del modelo regular. Estos coeficientes de autocorrelación se denominan coeficientes satélites, y muestran la interacción entre las componentes regular y estacionaria del modelo, verificándose, en general, la propiedad de simetría.

Gráficamente, y a título de ejemplo, se indica la forma de la FAC, para dos modelos estacionales multiplicativos; el primero de ellos corresponde a un ARMA (1,0)x SARMA (1,0)_s ; el segundo a un ARMA (0,1) x SARMA (1,0)_s



$$(1 - 0.5L)(1 - 0.5L^s) Y_t = u_t$$



$$(1 + 0.8L^s) Y_t = (1 - 0.5L) u_t$$

La mayoría de las series correspondientes a fenómenos con fluctuaciones estacionales, pueden modelizarse apropiadamente, utilizando alguno de los siguientes tipos :

<u>Componente regular</u>		<u>Componente estacional</u>
(1, d, 0)	x	(1, D, 0) _s
(1, d, 0)	x	(0, D, 1) _s
(0, d, 1)	x	(1, D, 0) _s
(0, d, 1)	x	(0, D, 1) _s

Uno de los más aplicados con resultados satisfactorios es :

$$(0, 1, 1) \quad x \quad (0, 1, 1)_s$$

en el que se requiere una diferenciación regular y otra estacional, para estabilizar la serie original. En general, la experiencia recogida en una gran variedad de aplicaciones indica que, tanto el operador regular, como el estacional, requieren sólo un promedio móvil, ó un autorregresivo, pero no ambos a la vez.

III.- PREDICCIÓN

Si el modelo ARIMA estimado resulta compatible con la estructura de los datos, de acuerdo a los criterios estadísticos ya analizados, el mismo puede ser utilizado a los fines de predicción.

En la exposición de este tema se considerará, por razones de simplicidad, modelos ARIMA regulares, aún cuando la metodología es totalmente aplicable a los estacionales multiplicativos.

Un modelo ARIMA (p,d,q) para la variable Y_t puede expresarse :

$$(1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p)(1 - L)^d Y_t = (1 - \theta_1 L - \theta_2 L^2 - \dots - \theta_q L^q) u_t$$

o bien :

$$Y_t = (1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p)^{-1} (1 - L)^{-d} (1 - \theta_1 L - \theta_2 L^2 - \dots - \theta_q L^q) u_t \quad (1)$$

y efectuando las operaciones indicadas entre operadores, resulta expresado como un modelo MA(∞) :

$$Y_t = (\psi_0 + \psi_1 L + \psi_2 L^2 + \dots) u_t = \sum_{j=0}^{\infty} \psi_j u_{t-j} \quad (2)$$

Supóngase que se pronostica en el momento T , el comportamiento de Y para el período T + τ ($\tau = 1, 2, \dots$), que indicaremos con $\hat{Y}_T(\tau)$. Si $Y_{T+\tau}$ es el valor real para dicho período, se define el error de pronóstico del momento T , para τ períodos en adelante como :

$$e_T(\tau) = Y_{T+\tau} - \hat{Y}_T(\tau) \quad (3)$$

La predicción óptima es la que minimiza el error medio cuadrático $E[e_T^2(\tau)]$, lo que se obtiene al tomar como predicción $\hat{Y}_T(\tau)$ el valor medio condicional :

$$E[Y_{T+\tau} / Y_1, Y_2, \dots, Y_T]$$

es decir, el valor esperado de $Y_{T+\tau}$, dada la información conocida al momento T, que viene dada por Y_T, Y_{T-1}, \dots, Y_1 .

Para el modelo (2) se tiene :

$$Y_{T+\tau} = \psi_0 u_{T+\tau} + \psi_1 u_{T+\tau-1} + \dots + \psi_\tau u_T + \psi_{\tau+1} u_{T-1} + \dots \quad (4)$$

y el valor medio : $E[Y_{T+\tau} / Y_1, Y_2, \dots, Y_T]$ se determina teniendo en cuenta que $\{u_t\}$ es un proceso ruido blanco ; su predicción óptima para cualquier momento posterior a T es cero , y para todo t dentro del período muestral, su valor es conocido.

Por lo tanto, :

$$\hat{Y}_T(\tau) = E[Y_{T+\tau} / Y_1, Y_2, \dots, Y_T] = \psi_\tau u_T + \psi_{\tau+1} u_{T-1} + \dots = \sum_{j=0}^{\tau} \psi_{j+\tau} u_{T-j} \quad (5)$$

El error de pronóstico y su varianza será :

$$e_T(\tau) = Y_{T+\tau} - \hat{Y}_T(\tau) = \sum_{j=0}^{\tau-1} \psi_j u_{T+\tau-j} \quad (6)$$

$$\sigma^2[e_T(\tau)] = \sigma_u^2 \sum_{j=0}^{\tau-1} \psi_j^2 \quad (7)$$

Se observa que la varianza se incrementa a medida que nos alejamos del período muestral, representando los ψ_j la contribución a la varianza, de cada uno de los períodos. Debe tenerse presente, por otra parte, que el análisis desarrollado supone el conocimiento cierto de los parámetros del modelo. Por tanto, la expresión (7) subestima la varianza real del error; y los intervalos de confianza que pueden construirse, suponiendo distribución normal para $\{u_t\}$, resultan de menor amplitud respecto a los verdaderos, para el nivel de confiabilidad elegido.

A título de ejemplo, considérese la predicción con un modelo ARIMA (1,0,0), sin constante, es decir, un AR (1) en variable centrada :

$$Y_t = \phi_1 Y_{t-1} + u_t$$

El pronóstico para el momento $T+1$, es :

$$\hat{Y}_T(1) = E[Y_{T+1} / Y_1, \dots, Y_T] = \phi_1 Y_T \quad (8)$$

Y la varianza del error de predicción :

$$E[e_T^2(1)] = E[Y_{T+1} - \phi_1 Y_T]^2 = \sigma_u^2 \quad (9)$$

El pronóstico y la varianza del error, para dos períodos más adelante del muestral, resultan :

$$\hat{Y}_T(2) = E[Y_{T+2} / Y_1, \dots, Y_T] = \phi_1^2 Y_T \quad (10)$$

$$E[e_T^2(2)] = (1 + \phi_1^2) \sigma_u^2 \quad (11)$$

Y en general, para τ períodos más adelante :

$$\hat{Y}_T(\tau) = \phi_1^\tau Y_T ; \quad E[e_T^2(\tau)] = \frac{(1 - \phi_1^{2\tau})}{1 - \phi_1^2} \sigma_u^2 = (1 - \phi_1^{2\tau}) \sigma_Y^2 \quad (12)$$

Dado que $|\phi_1| < 1$, se aprecia que, a medida que el horizonte del pronóstico se amplía, la predicción resulta menos afectada por la última observación muestral ; ó, lo que es lo mismo, si consideramos el modelo en variable original, el valor del pronóstico tiende al valor medio de las observaciones, cuando $\tau \rightarrow \infty$.

Respecto a la varianza del error de predicción, su tasa de crecimiento a medida que aumenta τ , depende del valor ϕ_1 . Si $\tau \rightarrow \infty$, $E[e^2(\tau)]$ tiende a la varianza σ_Y^2 .



~~IV~~- EVALUACION DE RESULTADOS

Se ha aplicado la metodología de Box-Jenkins a los datos mensuales de las doce estaciones pluviométricas de la Provincia de Corrientes. A los fines del análisis, se ha considerado conveniente efectuar un agrupamiento de las mismas, por el criterio del gradiente según longitud y latitud, ya que dentro de cada grupo existen condiciones físicas que avalan un comportamiento homogéneo, con discrepancias únicamente atribuibles a causas fortuitas.

Los grupos considerados corresponden a :

- I.- Corrientes y Derqui
- II.- Cruz Port y Torrent
- III. Mercedes
- IV.- Santa Lucía, San Roque, Goya y Bella Vista
- V.- Tapebicuá, Paso de los Libres y Bonpland

III.1 Identificación de las Series.

La identificación de la estructura estacional se ha realizado mediante el cálculo de las funciones de autocorrelación y de autocorrelación parcial de cada una de las series, en variable original, y sus distintas transformaciones.


Para la variable Lluvia, sin transformar (Y_t), la FAC de cada una de las estaciones se resume en el Cuadro I, y la FACP en el Cuadro II. Con excepción de las estaciones Cruz Port y Torrent, las restantes ponen en evidencia una estructura estacional definida por una onda de tipo sinusoidal, con coeficientes de autocorrelación negativos en las proximidades de los desfases de orden 6 (y sus múltiplos), y de autocorrelación positiva en las proximidades de los desfases de orden 12 (y sus múltiplos).

CUADRO I

FUNCION DE AUTOCORRELACION

VARIABLE: \bar{Y}_t

Defasajes	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	Q ₃₀
Estaciones Pluviomét.																																
Cruz Port	+											+																				43
Torrent	+			+																												40
Santa Lucía	+	+	+						+		+	+	+					-					+	+	+				-	-	-	255
San Roque	+	+		-	-	-	-	-			+	+	+			-	-	-	-	-	-		+	+	+				-	-	-	397
Mercedes	+	+	-					-			+	+	+								-		+	+	+				-	-	-	147
Corrientes	+	+		-	-	-	-	-	+		+	+	+	+		-	-	-	-	-	-	+	+	+	+	+		-	-	-	-	507
Goya	+	+			-	-	-	-			+	+	+				-	-	-	-	-		+	+	+	+		-	-	-	-	363
Tapebicú	+										+	+																				50
Paso de los Libres I	+	+										+										+	+									81
Paso de los Libres II																																
Bella Vista	+	+		-	-	-	-	-	+		+	+	+			-	-	-	-	-	-		+	+	+	+		-	-	-	-	426
Bonpland	+	+									+	+	+			-								+								74
Derqui	+	+		-	-	-	-	-			+	+	+			-	-	-	-	-	-	+	+	+	+	+		-	-	-	-	338



Asimismo en el Cuadro I se incluyen los coeficientes Q de Box-Pierce, que en este caso se han estimado para 30 coeficientes de autocorrelación. Para las estaciones con comportamiento anómalo ya mencionadas, dicho coeficiente revela falta de estructura estacional.

En el Cuadro III, y como es habitual en este tipo de estudios, se indican los valores numéricos de los coeficientes de autocorrelación, sus errores standard y el coeficiente Q_{30} , tanto para las variables primitivas (Y_t), como para la diferencia regular primera : $(1 - L) Y_t$, diferencia estacional de orden 12 : $(1 - L^{12}) Y_t$, y para una combinación de estas últimas : $(1-L)(1-L^{12}) Y_t$.

Para la variable Y, y dejando de lado la estación Torrent, que no revela estacionalidad, los restantes coeficientes resultan significativamente distintos de cero para un desfase de 12 períodos, aún cuando se los considera demasiado bajos para una variable como la que se está analizando; (el valor máximo se alcanza en Bella Vista : 0.23). Este hecho puede observarse en los Gráficos de algunas estaciones, correspondientes a los últimos años de información, y que se adjuntan al presente informe.

Para el desfase de 24 meses, los valores del coeficiente de autocorrelación se debilitan aún más, y dejan de ser significativos en Torrent, Cruz Port y Tapebicuá.

El análisis de los coeficientes para las series transformadas no revela mejoramiento alguno : sus valores muestrales no difieren significativamente de los teóricos que corresponden a la hipótesis de falta de estacionalidad, y que son los siguientes :

CUADRO III

COEFICIENTES DE AUTOCORRELACION

ESTACION	Y_t			$(1 - L) Y_t$			$(1 - L^2) Y_t$			$(1 - L)(1 - L^2) Y_t$		
	ρ_{12}	ρ_{24}	Q_{30}	ρ_{12}	ρ_{24}	Q_{30}	ρ_{12}	ρ_{24}	Q_{30}	ρ_{12}	ρ_{24}	Q_{30}
Cruz Port	0.076 (0.035)	0.038 (0.035)	43.0	0.068 (0.041)	0.025 (0.042)	218.4	-0.472 (0.035)	-0.019 (0.043)	235.7	-0.471 (0.043)	-0.030 (0.050)	494.8
Torrent	0.038 (0.033)	0.002 (0.033)	39.7	0.006 (0.040)	-0.006 (0.040)	278.9	-0.466 (0.032)	-0.021 (0.039)	240.4	-0.483 (0.041)	-0.011 (0.049)	638.0
Santa Lucía	0.205 (0.039)	0.116 (0.042)	254.8	0.049 (0.041)	0.009 (0.042)	208.2	-0.441 (0.036)	-0.089 (0.043)	229.6	-0.463 (0.046)	-0.072 (0.055)	612.7
San Roque	0.188 (0.036)	0.144 (0.041)	397.5	0.002 (0.039)	-0.027 (0.040)	290.7	-0.467 (0.033)	-0.008 (0.040)	271.9	-0.478 (0.041)	-0.039 (0.051)	749.6
Mercedes	0.119 (0.035)	0.110 (0.036)	147.2	-0.009 (0.040)	0.032 (0.041)	293.6	-0.481 (0.034)	-0.031 (0.041)	277.9	-0.506 (0.043)	-0.007 (0.054)	797.1
Corrientes	0.222 (0.036)	0.195 (0.040)	507.3	0.067 (0.036)	0.055 (0.037)	242.9	-0.470 (0.031)	-0.021 (0.038)	283.7	-0.487 (0.039)	-0.007 (0.047)	716.5
Goya	0.160 (0.037)	0.188 (0.040)	363.7	0.015 (0.040)	0.022 (0.041)	253.3	-0.508 (0.035)	-0.005 (0.043)	309.0	-0.499 (0.043)	-0.051 (0.053)	695.3
Tapebicú	0.097 (0.033)	0.036 (0.033)	49.9	0.059 (0.039)	-0.013 (0.039)	258.6	-0.461 (0.033)	-0.041 (0.039)	254.7	-0.459 (0.042)	-0.060 (0.049)	432.8
Paso de los Libres	0.193 (0.031)	0.059 (0.032)	81.5	0.075 (0.046)	-0.009 (0.047)	227.1	-0.438 (0.039)	-0.075 (0.045)	195.9	-0.446 (0.049)	-0.080 (0.056)	488.2
Bella Vista	0.230 (0.039)	0.184 (0.045)	426.6	0.092 (0.042)	0.029 (0.042)	242.5	-0.445 (0.035)	-0.044 (0.042)	217.6	-0.445 (0.043)	-0.054 (0.051)	552.2
Bonpland	0.112 (0.033)	0.070 (0.033)	74.4	0.027 (0.039)	0.035 (0.039)	262.0	-0.470 (0.033)	-0.014 (0.040)	267.5	-0.502 (0.043)	0.022 (0.051)	752.0
Derqui	0.225 (0.037)	0.157 (0.041)	338.1	0.073 (0.039)	0.013 (0.040)	195.1	-0.450 (0.034)	-0.017 (0.040)	215.3	-0.455 (0.043)	-0.043 (0.049)	545.4

Para $(1 - L) Y_t$: $\rho_{12} = \rho_{24} = 0$.

Para $(1 - L^{12}) Y_t$ y $(1 - L)(1 - L^{12}) Y_t$: $\rho_{12} = -0.5$; $\rho_{24} = 0$

Los Q_{30} resultan significativos debido a la estructura generada por la transformación, en otros desfases.

Como consecuencia de lo expresado precedentemente, la variable a utilizar en la etapa de estimación será Y_t , es decir "Lluvia", sin ningún tipo de diferenciación. El análisis del correlograma de estas series indica, como ya dijimos, coeficientes negativos para desfases de orden 6 (y múltiplos), y coeficientes positivos para desfases de orden doce (y múltiplos). Además se manifiestan coeficientes satélites significativamente distintos de cero, y con el signo correcto, para cada uno de los desfases mencionados, lo que permite presumir la generación de las series a partir de modelos estacionales multiplicativos.

III.2 Estimación del Modelo

El proceso de estimación se ha efectuado concentrando la atención, dentro de cada grupo, en una única estación pluviométrica, seleccionada en base a la mayor fiabilidad de la información. Las estimaciones se realizaron para : Cruz Port, Mercedes, Corrientes, Goya y Bonpland.

Para estas estaciones se ensayaron diferentes modelos, en variables primitivas, y aún en unidades transformadas ; para estas últimas, sin embargo, se obtuvieron, en la generalidad de los casos, coeficientes inestables (cerca de la unidad, ó bien no se logra la convergencia en la estimación); ello confirma lo indicado anteriormente, en el sentido de que la estructura estacional resulta generada por la transformación, y no por la propia naturaleza del fenómeno en estudio.

Para la variable Y_t , los resultados alcanzados se consignan en los Cuadros IV a VIII .

De la lectura de los mismos surge que, si bien se han logrado estimaciones estadísticamente significativas, lo que evidencia la presencia de estacionalidad, la varianza residual de cada uno de los modelos es excesivamente grande en comparación con la varianza de las observaciones.

En definitiva, el modelo quedaría sintetizado de la siguiente forma :

$$Y_t = \text{Estacionalidad} + \text{Componente Aleatoria}$$

Como consecuencia de las consideraciones precedentes, las predicciones logradas para cada uno de los modelos ensayados resultan de muy baja precisión : Los Intervalos de Confianza para el nivel de seguridad elegido son excesivamente amplios, debido precisamente a la importancia relativa de la varianza residual.

En vista de los resultados obtenidos, se aplicó a las estaciones mencionadas el método de desestacionalización ARIMA X 11 , para los últimos 14 años de información . Dicha metodología tiene la ventaja de no presuponer modelos a priori por parte del investigador. En los gráficos adjuntos al presente informe, donde se representaron con trazo continuo las observaciones, y con trazo punteado los datos desestacionalizados, se observa claramente un comportamiento estacional variable, que no define, en modo alguno, un patrón estable. A igual conclusión se llega, de la lectura de los Índices de Estacionalidad promedio, y proyectados para la observación $N+1$, que figuran al pié de los gráficos respectivos.

A mayor abundamiento, se intentó estimar, para las estaciones Mercedes, Corrientes y Goya, modelos autorregresivos de orden doce,

Variable : Y_t Modelos	Constante	Regular				Estacional		Q_{30}	Grados de Libertad	Varianza Residual
		ϕ_1	ϕ_2	θ_1	θ_2	ϕ_s	θ_s			
$(0,0,1) \times (0,0,1)_{12}$	103.85 (34.55)			- 0.098 (2.97)			- 0.086 (2.59)	90.84	27	5942
$(0,0,2) \times (0,0,1)_{12}$	103.79 (30.45)			- 0.124 (3.81)	0.132 (4.06)		- 0.084 (2.53)	66.36	26	5848
$(1,0,1) \times (0,0,1)_{12}$	103.82 (31.29)	0.428 (2.05)		0.303 (1.38)			- 0.083 (2.50)	81.76	26	5907
$(1,0,2) \times (0,0,1)_{12}$	103.80 (31.59)	-0.383 (1.92)		- 0.501 (2.54)	- 0.172 (5.06)		- 0.087 (2.62)	62.54	25	5837
$(0,0,1) \times (1,0,0)_{12}$	103.85 (33.89)			- 0.094 (2.86)		0.100 (3.03)		86.84	27	5933
$(1,0,0) \times (1,0,0)_{12}$	103.84 (32.95)	0.117 (3.58)				0.095 (2.88)		83.84	27	5918
$(1,0,1) \times (1,0,0)_{12}$	103.80 (30.78)	0.432 (2.02)		0.311 (1.38)		0.096 (2.89)		78.62	26	5901
$(2,0,0) \times (1,0,0)_{12}$	103.79 (29.54)	0.104 (3.18)	0.103 (3.14)			0.101 (3.06)		69.25	26	5862
$(1,0,0) \times (1,0,1)_{12}$	100.63 (15.86)	0.084 (2.57)				0.978 (66.45)	0.919 (34.15)	56.96	26	5629
$(0,0,0) \times (1,0,1)_{12}$	100.40 (16.59)					0.977 (67.71)	0.913 (34.00)	62.10	27	5663

CUADRO VIII

ESTACION : BONPLAND

Media : 99.49

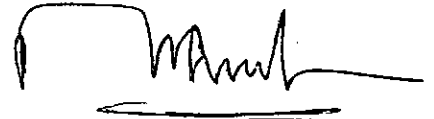
Varianza : 5929

Número de
Observac. 984

Variable : Y_t Modelos	Constante	Regular				Estacional		Q_{30}	Grados de Libertad	Varianza Residual
		ϕ_1	ϕ_2	θ_1	θ_2	ϕ_s	θ_s			
$(0,0,1) \times (0,0,1)_{12}$	99.45 (34.77)			- 0.088 (2.43)			- 0.090 (2.81)	44.16	27	5840
$(0,0,2) \times (0,0,1)_{12}$	99.44 (32.56)			- 0.083 (2.60)	- 0.070 (2.20)		- 0.090 (2.80)	38.49	26	5815
$(1,0,1) \times (0,0,1)_{12}$	99.40 (29.24)	0.720 (4.75)		0.640 (3.82)			- 0.091 (2.83)	40.45	26	5810
$(1,0,2) \times (0,0,1)_{12}$	99.40 (29.01)	0.743 (3.71)		0.663 (3.27)	0.005 (0.11)		- 0.091 (2.79)	40.47	25	5816
$(0,0,1) \times (1,0,0)_{12}$	99.46 (34.17)			- 0.076 (2.37)		0.101 (3.14)		42.63	27	5833
$(1,0,0) \times (1,0,0)_{12}$	99.46 (33.65)	0.087 (2.72)				0.099 (3.09)		41.48	27	5828
$(1,0,1) \times (1,0,0)_{12}$	99.40 (28.64)	0.727 (4.85)		0.649 (3.91)		0.102 (3.18)		38.52	26	5803
$(2,0,0) \times (1,0,0)_{12}$	99.44 (31.36)	0.081 (2.52)	0.068 (2.14)			0.101 (3.13)		37.28	26	5807
$(0,0,0) \times (1,0,0)_{12}$	99.47 (36.17)					0.113 (3.55)		50.68	28	5866


para las variables diferenciadas una vez. Si bien la sobreparametrización de estos modelos logra residuos con comportamiento de ruido blanco, la varianza explicada sigue siendo muy baja respecto a la total de las observaciones, por lo que las predicciones carecen de precisión.

Se adjunta, al final del informe, fotocopia de las salidas de computadora correspondientes a estos últimos ensayos.

A handwritten signature in dark ink, consisting of a series of loops and a long horizontal stroke at the end.



C R U Z P O R T




INDICES DE ESTACIONALIDAD

Multiplicativos

Proyectados N+1

122.0445	90.45392
141.3508	168.4974
117.6195	93.39798
89.96834	93.44737
91.17313	138.7807
66.24935	76.42026
66.52016	64.3211
78.54925	84.27051
92.64504	111.2418
121.848	70.07945
122.6468	156.9115
89.38509	52.17603

MERCEDES



INDICES DE ESTACIONALIDAD


Multiplicativos

Proyectados N+1

146.6377
140.4263
119.6503
103.036
87.3271
56.38251
50.85229
75.2619
87.13636
104.7461
135.261
93.28246

156.0537
195.7449
136.1681
72.53795
99.11747
48.88909
18.40009
73.09513
99.55911
45.66725
178.8176
75.94981

CORRIENTES



INDICES DE ESTACIONALIDAD


Multiplicativos

Proyectados N+1

146.0215
121.7564
147.8633
127.8917
84.69019
58.01857
46.74456
59.50305
46.97922
94.15894
145.8486
120.5241

116.9147
148.6978
75.17232
135.4544
70.25946
42.93343
24.63876
70.6713
73.25886
73.44991
294.3646
73.98459

G O Y A



INDICES DE ESTACIONALIDAD

Multiplicativos

Proyectados N+1

135.0189

198.0117

114.5871

162.4647

153.812

114.447

112.1852

154.2644

104.0053

140.9298

53.98434

46.39608

64.80783

36.32986

38.32005

20.98986

68.66835

58.77296

145.1589

65.15905


92.88405

69.36828

116.568

132.8664

BONPLAND



INDICES DE ESTACIONALIDAD

Multiplicativos

Proyectados N+1

115.2945	78.16796
161.4652	197.2093
105.7409	70.97283
100.1066	58.85637
100.7669	161.6179
62.10005	52.10739
75.14601	58.14036
94.21325	108.6351
91.92568	97.56426
83.49561	40.4727
117.447	186.9085
92.29838	89.44141

MERCEDES



ARIMA: MAXIMUM LIKELIHOOD ESTIMATION

PARAMETER	ESTIMATE	APPROX. STD ERROR	T RATIO	LAG
AR1,1	-0.834463	0.032608	-25.59	1
AR1,2	-0.681479	0.0416881	-16.35	2
AR1,3	-0.706562	0.0452419	-15.62	3
AR1,4	-0.64743	0.0483725	-13.38	4
AR1,5	-0.600765	0.0502054	-11.97	5
AR1,6	-0.548177	0.0514361	-10.66	6
AR1,7	-0.50177	0.0515823	-9.73	7
AR1,8	-0.513318	0.0505563	-10.15	8
AR1,9	-0.480441	0.0489013	-9.82	9
AR1,10	-0.427222	0.0456566	-9.36	10
AR1,11	-0.292173	0.0420038	-6.96	11
AR1,12	-0.15696	0.0328987	-4.77	12

VARIANCE ESTIMATE = 5996.73
 STD ERROR ESTIMATE = 77.4386
 AIC = 10754.9
 SBC = 10813
 NUMBER OF RESIDUALS= 931

AUTOCORRELATION CHECK OF RESIDUALS

TO LAG	CHI SQUARE	DF	PROB	AUTOCORRELATIONS					
6	0.00	0	0.000	-0.005	-0.012	-0.013	-0.013	-0.015	-0.030
12	0.00	0	0.000	-0.026	-0.031	-0.036	-0.052	-0.057	-0.062
18	19.48	6	0.003	-0.063	-0.016	0.013	-0.021	-0.038	-0.006
24	32.38	12	0.001	0.087	-0.041	-0.035	0.021	0.046	0.023
30	43.55	18	0.001	-0.004	-0.001	-0.008	0.022	-0.086	-0.060
36	53.42	24	0.001	-0.001	-0.058	0.011	0.013	0.029	0.076
42	59.92	30	0.001	0.017	-0.018	-0.032	-0.010	-0.035	0.061

OBS FORECAST STD ERROR LOWER 95% UPPER 95% ACTUAL RESIDUAL

-----FORECAST BEGINS-----

933	121.8370	77.4386	-29.9395	273.6136	245.0000	123.1630
934	70.0605	78.4924	-83.7815	223.9025	193.0000	122.9395
935	104.7690	79.7257	-51.4902	261.0233	318.0000	213.2310
936	80.0306	79.7598	-76.2954	236.3566	159.0000	78.9694
937	95.8828	80.0475	-61.0070	252.7727	165.0000	69.1172
938	103.0267	80.2362	-54.2331	260.2865	8.0000	-95.0267
939	102.7712	80.5755	-55.1535	260.6959	76.0000	-26.7712
940	110.6349	80.8748	-47.8764	269.1462	3.0000	-102.6349
941	119.6923	80.9337	-38.9344	278.3191	7.0000	-112.6923
942	140.6258	81.1005	-18.3281	299.5796	208.5000	67.3742
943	118.1715	81.3767	-41.3236	277.6665	65.4000	-52.7715
944	133.1280	82.7043	-28.9690	295.2250	10.0000	-123.1280
945	97.3081	84.5214	-68.3504	262.9666		
946	106.9661	87.3865	-64.3080	279.2402		
947	97.5069	88.1751	-75.3127	270.3265		
948	104.1995	88.7847	-69.8150	278.2140		
949	101.3541	89.1344	-73.3457	276.0538		
950	104.6824	89.5905	-70.9114	280.2762		
951	106.9102	90.0248	-69.5349	283.3553		
952	109.1090	90.4373	-68.1445	286.3625		
953	114.8215	90.7908	-63.1249	292.7678		
954	116.7511	91.1093	-61.8196	295.3218		
955	119.1272	91.5873	-60.3803	298.6347		
956	113.7356	92.2603	-67.0909	294.5621		

CORRIENTES

ARIMA: MAXIMUM LIKELIHOOD ESTIMATION

PARAMETER	ESTIMATE	APPROX. STD ERROR	T RATIO	LAG
AR1,1	-0.794632	0.0305374	-26.02	1
AR1,2	-0.671283	0.0378595	-17.73	2
AR1,3	-0.644197	0.041043	-15.70	3
AR1,4	-0.671808	0.0425816	-15.78	4
AR1,5	-0.645175	0.043832	-14.72	5
AR1,6	-0.601053	0.0444551	-13.52	6
AR1,7	-0.610812	0.0446205	-13.69	7
AR1,8	-0.597194	0.0441941	-13.51	8
AR1,9	-0.533411	0.0431252	-12.37	9
AR1,10	-0.433033	0.0415513	-10.42	10
AR1,11	-0.320578	0.0383677	-8.36	11
AR1,12	-0.140338	0.0308295	-4.55	12
AR2,1	-0.0420731	0.0322689	-1.30	21

VARIANCE ESTIMATE = 6134.05
 STD ERROR ESTIMATE = 73.3202
 AIC = 12349.5
 SBC = 12414.1
 NUMBER OF RESIDUALS= 1067

AUTOCORRELATION CHECK OF RESIDUALS

TO LAG	CHI SQUARE	OF DF	PROB	AUTOCORRELATIONS						
6	0.00	0	0.000	-0.005	-0.004	-0.001	-0.006	-0.010	-0.012	
12	0.00	0	0.000	-0.009	-0.015	-0.034	-0.050	-0.066	-0.074	
18	27.17	5	0.000	-0.059	-0.023	-0.057	-0.048	0.009	-0.006	
24	36.50	11	0.000	0.025	-0.051	-0.000	0.053	0.024	0.045	
30	40.77	17	0.001	0.008	-0.003	0.030	0.025	-0.048	0.000	
36	53.92	23	0.000	-0.015	-0.054	-0.016	-0.052	0.064	0.041	
42	60.84	29	0.000	-0.025	0.040	-0.036	-0.048	-0.012	-0.015	

OBS	FORECAST	STD ERROR	LOWER 95%	UPPER 95%	ACTUAL	RESIDUAL
-----	----------	-----------	-----------	-----------	--------	----------

-----FORECAST BEGINS-----

1057	141.2922	73.3202	-12.2122	294.7966	233.0000	91.7078
1058	137.1199	79.9547	-19.5882	293.8280	166.1000	28.9001
1059	111.1473	80.9989	-47.6074	269.9019	203.3000	94.3027
1060	108.0249	81.2812	-51.2830	267.3327	451.4000	343.3701
1061	122.9114	81.2910	-36.4156	282.2384	239.4000	116.4885
1062	123.5863	81.3495	-35.8555	283.0282	16.0000	-107.5863
1063	133.4453	81.4739	-26.2397	293.1313	50.9000	-82.5453
1064	147.1587	81.4866	-12.5519	306.8692	2.4000	-144.7587
1065	181.7535	81.5269	21.9640	341.5429	4.8000	-176.9535
1066	178.0062	81.7593	17.7612	338.2513	94.4000	-83.6062
1067	197.8664	82.4478	36.2721	359.4607	153.5000	-34.2664
1068	203.0534	83.7231	38.9595	367.1474	64.8000	-138.2534
1069	153.4564	86.6353	-16.3463	323.2591		
1070	146.9254	89.5678	-28.6239	322.4746		
1071	127.2796	90.5823	-50.2581	304.8174		
1072	128.7474	91.1447	-49.8926	307.3873		
1073	125.5510	91.3865	-53.5630	304.6650		
1074	132.9251	91.5295	-46.4690	312.3193		
1075	144.4389	91.6897	-35.2692	324.1470		
1076	138.1352	91.8523	-41.8917	318.1621		
1077	165.5269	92.0511	-14.8896	345.9433		
1078	171.1327	92.1854	-9.5469	351.3124		
1079	173.1186	92.7584	-8.7037	354.9409		
1080	171.9975	93.6701	-11.5922	355.5872		

G O Y A

ARIMA: MAXIMUM LIKELIHOOD ESTIMATION

PARAMETER	ESTIMATE	APPROX. STD ERROR	T RATIO	LAG
AR1,1	-0.737069	0.0329636	-22.36	1
AR1,2	-0.626258	0.0401597	-15.59	2
AR1,3	-0.655442	0.0433847	-15.11	3
AR1,4	-0.563967	0.0457581	-12.32	4
AR1,5	-0.607731	0.0466203	-13.04	5
AR1,6	-0.58146	0.0479197	-12.13	6
AR1,7	-0.511391	0.0479579	-10.66	7
AR1,8	-0.501744	0.0466429	-10.76	8
AR1,9	-0.496141	0.0458492	-10.82	9
AR1,10	-0.392404	0.0436308	-8.99	10
AR1,11	-0.270208	0.0404567	-6.68	11
AR1,12	-0.148282	0.0331645	-4.47	12

VARIANCE ESTIMATE = 6273.94
 STD ERROR ESTIMATE = 79.2082
 AIC = 10553.8
 SBC = 10611.6
 NUMBER OF RESIDUALS= 910

AUTOCORRELATION CHECK OF RESIDUALS

TO LAG	CHI SQUARE	DF	PROB	AUTOCORRELATIONS					
6	0.00	0	0.000	0.007	-0.002	-0.002	-0.007	-0.011	-0.012
12	0.00	0	0.000	-0.018	-0.019	-0.033	-0.046	-0.069	-0.070
18	31.16	6	0.000	-0.065	-0.115	0.015	-0.030	0.010	-0.030
24	46.46	12	0.000	-0.002	0.036	-0.069	-0.021	0.084	0.053
30	54.38	18	0.000	0.064	-0.006	0.013	-0.035	-0.048	-0.024
36	65.81	24	0.000	-0.025	0.024	-0.051	-0.311	0.010	0.090
42	71.96	30	0.000	0.015	-0.021	-0.028	-0.051	-0.046	0.017

OBS	FORECAST	STD ERROR	LOWER 95%	UPPER 95%	ACTUAL	RESIDUAL
-----FORECAST BEGINS-----						
900	150.5777	79.2082	-4.6672	305.8226	319.8000	169.2223
901	170.9313	81.9004	10.4104	331.4533	224.3000	53.3522
902	163.2463	83.1313	0.3122	326.1803	111.6000	-31.6463
903	170.3270	83.2156	7.2277	333.4262	51.1000	-119.2270
904	150.8163	83.7228	-3.2770	324.9096	165.7000	4.8837
905	115.1717	83.7272	-48.9302	279.2735	15.7000	-99.4717
906	101.8587	83.8049	-62.3956	266.1129	34.1000	-67.7587
907	82.0790	84.0637	-32.6825	246.8405	46.4000	-35.6791
908	79.7569	84.2359	-85.3421	244.8559	62.1000	-17.6569
909	92.3860	84.3069	-72.8521	257.6241	33.4000	-59.9860
910	110.9167	84.9683	-55.6177	277.4511	79.6000	-31.3167
911	128.6100	86.4756	-40.8788	298.0987	115.5000	-13.1100
912	145.6395	88.6355	-28.0826	319.3616		
913	146.3598	91.7151	-33.3981	326.1178		
914	149.1909	93.0290	-33.1422	331.5241		
915	144.0558	93.7350	-39.6611	327.7727		
916	137.9520	94.0672	-46.4159	322.3200		
917	126.2340	94.4085	-58.8029	311.2709		
918	113.7412	94.6482	-71.7656	299.2479		
919	106.8697	94.9331	-79.1953	292.9348		
920	104.3247	95.2828	-82.4258	291.0753		
921	107.9151	95.7126	-79.6778	295.5080		
922	115.7195	96.2777	-72.9809	304.4200		
923	124.4534	97.1776	-66.0109	314.9176		

B I B L I O G R A F I A

- 1.- Box, G.E.P. y G.M.Jenkins : "Time Series Analysis. Forecasting and Control".
Holden Day. San Francisco. 1976.
- 2.- Makridakis, S. y S.C. Wheelwright: "Forecasting : Methods and Applications".
J.Wiley. New York. 1978.
- 3.- O'Donovan, T.M. : "Short Term Forecasting.An Introduction to the
Box-Jenkins Approach". J.Wiley. Chichester,
1983.
- 4.- Pankratz, A. : "Forecasting with the Univariate Box-Jenkins
Models." J.Wiley. New York, 1983.
- 5.- Uriel, E. : "Análisis de Series Temporales. Modelos ARIMA".
Paraninfo. Madrid. 1985.