

Proyecto de Estudio Estadístico de las Series de Comercio Exterior

CONVENIO

INSTITUTO NACIONAL DE ESTADÍSTICA Y CENSOS

FACULTAD DE CIENCIAS ECONÓMICAS Y ESTADÍSTICA DE LA U.N. DE ROSARIO

Informe Final

Grupo de Trabajo:

- **María Teresa Blaconá**
- **Elena Martínez**
- **Roberto Muños**
- **Gabriela Sodiro**
- **Nora Ventroni**

Coordinación:

Norma Pizarro de Pereira (Dirección de Estudios Estadísticos - INDEC)

I. INTRODUCCIÓN

En nuestro país, las estadísticas de Comercio Exterior son responsabilidad del Instituto Nacional de Estadística y Censos (INDEC) a través de la Dirección Nacional de Estadísticas de Comercio, la que se encarga de recopilar, medir y caracterizar el flujo de mercaderías que entran y salen del país.

El Programa de Estadísticas de Comercio desarrollado por la citada Dirección Nacional ha introducido recientemente cambios en todas las etapas de elaboración de datos con el fin de mejorar cualitativa y cuantitativamente la producción de la información (INDEC,1991).

El Proyecto de Estudio Estadístico de las Series de Comercio Exterior se desarrolla en el marco del Convenio entre el Instituto Nacional de Estadística y Censos y la Facultad de Ciencias Económicas y Estadística de la Universidad Nacional de Rosario y es coordinado por la Dirección de Estudios Estadísticos del INDEC. Su objetivo es complementar las tareas realizadas por la Dirección Nacional de Estadísticas de Comercio mediante un estudio profundo de las series de Importaciones y Exportaciones, utilizando técnicas de series de tiempo.

El Proyecto se divide en dos áreas:

- Apoyo metodológico
- Análisis de las series de Comercio Exterior

El área de apoyo metodológico tiene a su cargo las tareas de evaluar las diferentes metodologías de análisis y modelación de series de tiempo disponibles y seleccionar aquellas que resuelvan más eficientemente los requerimientos fijados. Asimismo desarrolla una metodología que permite estimar en forma robusta modelos de regresión con errores ARIMA, teniendo en cuenta la posibilidad de que haya valores atípicos tanto en la serie como en las variables explicativas.

El área de análisis tiene a su cargo las tareas de describir las series de Importaciones y Exportaciones, e identificar y estimar modelos de pronóstico para las mismas.

En este informe se describen las tareas desarrolladas en el área de análisis. En el parágrafo II se presentan las metodologías utilizadas en las distintas etapas del estudio, en el parágrafo III los resultados obtenidos.

II. METODOLOGÍA

II.1 Análisis descriptivo de las series.

Con el fin de describir las series y obtener una idea preliminar de la posible existencia de periodicidades o tendencias, como así también detectar la presencia de valores extremos, se realizan gráficos de las series, gráficos de medias y medianas mensuales, y periodogramas. Asimismo en esta etapa descriptiva se utilizan el programa X11-ARIMA de ajuste estacional y un programa de estimación robusta de modelos ARIMA.

A continuación se describirán brevemente cada una de las técnicas utilizadas.

- II.1.1. Gráficos de medias y medianas mensuales.

Con el propósito de evaluar inicialmente la posible existencia de ciclos de periodicidad anual en las series (estacionalidad), se realizan gráficos de medias y medianas mensuales.

En los gráficos de medias se presentan, en primer lugar, el valor medio de cada mes a lo largo de los años juntamente con los correspondientes valores mínimo y máximo. En el segundo gráfico de medias se presentan los valores observados de la serie ordenados por mes, juntamente con el valor medio del mes.

En los gráficos de medianas se presentan en un caso la mediana de cada mes a lo largo de los años juntamente con los correspondientes cuartiles. En el segundo gráfico de medianas se presentan los valores observados de la serie ordenados por mes, juntamente con la mediana del mes.

Se realizan ambos tipos de gráficos ya que, si hay valores atípicos en la serie, tanto la media como los valores mínimo y máximo se ven muy influenciados, no así las medianas ni los cuartiles.

- II.1.2. Periodograma.

En algunas situaciones, particularmente en el ajuste de series con estacionalidad, es necesario tener en cuenta las características periódicas de la serie. La función de autocorrelación puede no ser un buen indicador de esas características porque los efectos periódicos se suelen distribuir entre varias correlaciones.

El periodograma (Box y Jenkins (1976), Dagum et al (1975)) está especialmente diseñado para detectar periodicidades y se basa en la hipótesis de que la serie está compuesta por ondas seno y coseno con diferentes frecuencias. Es una función que asigna a cada frecuencia su intensidad.

El periodograma acumulado normalizado puede ser representado gráficamente y es posible determinar visualmente si hay componentes periódicas en la serie. Si la serie es una realización de un proceso puramente aleatorio, es decir si no hay ningún tipo de estructura temporal, y si el número de observaciones es suficientemente grande, el periodograma acumulado normalizado tiende a coincidir con la diagonal del rectángulo en el cual se grafica. Utilizando el test de Kolmogorov-Smirnov es posible construir bandas de confianza alrededor de dicha diagonal que permiten testear la hipótesis de aleatoriedad de la serie y detectar periodicidades a ciertas frecuencias.

- II.1.3. X11-ARIMA.

El programa X11-ARIMA (Dagum (1988)) implementa un método de ajuste estacional de series de tiempo basado en un modelo de descomposición de la serie en las siguientes componentes básicas: tendencia-ciclo, estacionalidad e irregularidad. Estas componentes no son observables sino estimadas.

-*Tendencia-Ciclo*: es la evolución de la serie a largo plazo y puede incluir fluctuaciones periódicas con períodos alternativos de expansión y contracción (ciclos).

-*Estacionalidad*: está compuesta por movimientos que se repiten en forma más o menos regular año a año.

-*Irregularidad*: es el residuo no explicado por las otras componentes y representa no sólo

En este informe se describen las tareas desarrolladas en el área de análisis. En el párrafo II se presentan las metodologías utilizadas en las distintas etapas del estudio, en el párrafo III los resultados obtenidos.

II. METODOLOGÍA

II.1 Análisis descriptivo de las series.

Con el fin de describir las series y obtener una idea preliminar de la posible existencia de periodicidades o tendencias, como así también detectar la presencia de valores extremos, se realizan gráficos de las series, gráficos de medias y medianas mensuales, y periodogramas. Asimismo en esta etapa descriptiva se utilizan el programa X11-ARIMA de ajuste estacional y un programa de estimación robusta de modelos ARIMA.

A continuación se describirán brevemente cada una de las técnicas utilizadas.

- II.1.1. Gráficos de medias y medianas mensuales.

Con el propósito de evaluar inicialmente la posible existencia de ciclos de periodicidad anual en las series (estacionalidad), se realizan gráficos de medias y medianas mensuales.

En los gráficos de medias se presentan, en primer lugar, el valor medio de cada mes a lo largo de los años juntamente con los correspondientes valores mínimo y máximo. En el segundo gráfico de medias se presentan los valores observados de la serie ordenados por mes, juntamente con el valor medio del mes.

En los gráficos de medianas se presentan en un caso la mediana de cada mes a lo largo de los años juntamente con los correspondientes cuartiles. En el segundo gráfico de medianas se presentan los valores observados de la serie ordenados por mes, juntamente con la mediana del mes.

Se realizan ambos tipos de gráficos ya que, si hay valores atípicos en la serie, tanto la media como los valores mínimo y máximo se ven muy influenciados, no así las medianas ni los cuartiles.

errores de medición sino también decisiones económicas o eventos temporarios que afectan el comportamiento esperado de la serie. Aquellas irregulares que generan fluctuaciones grandes en la serie original se denominan extremos (outliers) y tienen, generalmente, causas identificables.

En el caso de series mensuales, sobretodo en las de tipo flujo en las cuáles el dato mensual es el acumulado de datos diarios, puede ser necesario incluir una componente de variación por días de actividad (trading-day).

-*Efecto días de actividad*: representa el efecto que ejerce sobre la variable en estudio el número de veces que cada día de la semana ocurre en un mes dado.

El método X11-ARIMA básicamente consiste en:

- Modelación de la serie original mediante un modelo SARIMA (Box y Jenkins (1976)). Hay modelos incorporados al programa que son estimados y se ajusta el que satisface ciertos requerimientos especificados. Además existe la posibilidad de que el usuario imponga el modelo a aplicar si ninguno de los modelos incorporados es adecuado.
- Extrapolación de un año de datos en cada extremo de la serie original a partir del modelo SARIMA estimado, si existe un modelo apropiado.
- Ajuste estacional de la serie original o extendida, mediante el Método X11 (Shiskin et al (1967)). Este método se basa en razones al promedio móvil y supone que, aunque las componentes de la serie son funciones suaves del tiempo no pueden ser aproximadas por funciones simples sobre el rango total de la serie.

El programa X11-ARIMA provee tests que permiten probar hipótesis de estacionalidad estable, estacionalidad móvil, estacionalidad identificable y efecto días de actividad. Asimismo provee medidas de bondad del ajuste estacional (Lothian y Morry (1978)). En particular da una evaluación de la contribución relativa de cada componente a la varianza de la serie original. Esta contribución relativa se calcula sobre los cambios porcentuales (diferencias) a distintos lags (distancias entre meses). Dado que lo que se quiere es

obtener una idea clara de la variación relativa de la componente estacional respecto a la irregular, obviamente una primera diferencia (lag 1) elimina demasiada estacionalidad en relación a la irregular. Por esta razón se recomienda el análisis de la diferencia a lag 3, ya que ésta preserva las proporciones originales entre las dos componentes. En la presentación de los resultados se incluirán las contribuciones relativas a la varianza de la serie original correspondientes a ambos lags.

- II.1.4. Estimación robusta de modelos ARIMA.

El programa ESTIN de identificación, estimación y predicción robusta de modelos ARIMA provee métodos robustos para las distintas etapas de selección y modelación de una serie de tiempo (Martínez y Yohai (1989)).

El método utilizado se basa fundamentalmente en un proceso de filtrado de la serie original, el cual reemplaza las observaciones que aparentan ser atípicas (outliers) por valores acordes al resto de la serie. Este proceso de filtrado tiene como objetivo, por una parte obtener funciones de autocorrelación y autocorrelación parcial muestrales no alteradas por los posibles outliers presentes en la serie, y por otro, obtener residuos que permitan estimar el modelo en forma robusta. Estos residuos se calculan de manera tal que se evita la propagación del efecto de un valor atípico a residuos posteriores al tiempo en que éste se produce.

Como se mencionó, en el proceso de filtrado de la serie son eventualmente detectados posibles valores atípicos, ya sean del tipo outlier aditivo, correspondiente a un valor extremo aislado, como cambios de nivel en la serie. Estos valores detectados, representados por variables ficticias (dummies), son utilizados en la etapa de construcción de modelos de regresión con errores ARIMA.

II.2 Modelos ARIMA.

Una serie de tiempo observada $Z_1, Z_2, \dots, Z_T$ se puede considerar como una realización particular de un proceso estocástico, es decir de un fenómeno que se desarrolla a lo largo del tiempo según leyes probabilísticas.

La familia de modelos autorregresivos promedios móviles integrados multiplicativos (SARIMA), formalizada por Box y Jenkins (1976) contiene modelos de la forma:

$$(1 - B)^d (1 - B^s)^D \phi(B) \Phi(B^s) (Z_t - \mu) = \theta(B) \Theta(B^s) a_t \quad (\text{II.2.1})$$

siendo B el operador de rezago, tal que $B Z_t = Z_{t-1}$ y en general, $B^m Z_t = Z_{t-m}$.

Este modelo se indica SARIMA $(p, d, q) (P, D, Q)_s$, donde

d = número de diferencias ordinarias,

D = número de diferencias estacionales,

s = período de estacionalidad (en el caso de series mensuales, $s=12$),

$\phi(B) = (1 - \phi_1 B - \dots - \phi_p B^p)$ es el polinomio autorregresivo de orden p ,

$\theta(B) = (1 - \theta_1 B - \dots - \theta_q B^q)$ es el polinomio promedio móvil de orden q ,

$\Phi(B^s) = (1 - \Phi_1 B^s - \dots - \Phi_P B^{Ps})$ es el polinomio autorregresivo estacional de orden P ,

$\Theta(B^s) = (1 - \Theta_1 B^s - \dots - \Theta_Q B^{Qs})$ es el polinomio promedio móvil estacional de orden Q .

Todos estos polinomios deben tener sus raíces fuera del círculo unitario para que se cumplan las necesarias condiciones de estacionaridad e invertibilidad.

a_t es una serie ruido blanco, es decir que tiene media cero, varianza constante y valores no correlacionados ($Cov(a_t, a_{t'}) = 0$, $\text{sit } t \neq t'$).

El procedimiento de modelación es un proceso iterativo que consta de tres etapas:

(i) Identificación;

(ii) Estimación;

(iii) Diagnóstico y verificación.

(i) *Identificación*: En el análisis de series de tiempo esta etapa es crucial en la construcción de modelos; requiere entender bien el proceso y sus características. Las herramientas básicas usadas para la identificación son la función de autocorrelación muestral (FACM),

la función de autocorrelación parcial muestral (FACPM) y la función de autocorrelación inversa muestral (FACIM).

En base a la forma de estas funciones y al gráfico de la serie se determinan las transformaciones requeridas, el número de diferencias ordinarias y estacionales (d y D), y los órdenes p, q, P y Q .

(ii) *Estimación*: Luego de identificar un modelo tentativo la siguiente etapa es estimar sus parámetros. Los supuestos básicos en el proceso de estimación son:

- Los errores a_t son un proceso ruido blanco con distribución normal
- El proceso eventualmente transformado y/o diferenciado es estacionario e invertible.

Hay varios métodos clásicos de estimación de los parámetros del modelo, entre otros: máxima verosimilitud (MV), mínimos cuadrados condicional (MCC) y mínimos cuadrados incondicional (MCI).

El no cumplimiento de los supuestos enunciados anteriormente, como ser presencia de valores atípicos o cambios de comportamiento, afectan sustancialmente tanto la identificación del modelo como la estimación de los parámetros, por lo que se deben buscar caminos alternativos para su solución. Esto se describirá en párrafos siguientes.

(iii) *Diagnóstico y verificación*: Una vez estimado el modelo, la prueba básica de adecuación del ajuste es verificar que los residuales estimados son estimaciones de los valores ruido blanco a_t , no observados. Esta etapa se realiza a través de un cuidadoso análisis de la serie de residuales estimados, utilizando inicialmente el gráfico de la misma y sus funciones de autocorrelación muestral.

Para verificar la aleatoriedad de la serie de residuales estimados se puede utilizar el test de bondad de ajuste debido a Ljung y Box (1978) el cual usa un conjunto de K autocorrelaciones muestrales de dicha serie para chequear la hipótesis nula conjunta:

$$H_0) \rho_1 = \rho_2 = \dots \rho_K = 0$$

a través del estadístico

$$Q = n(n+2) \sum_{k=1}^K \frac{r_k^2}{(n-k)}$$

siendo r_k un estimador de la autocorrelación muestral de orden k .

Bajo la hipótesis nula, Q tiene distribución aproximadamente Chi cuadrado con $K - m$ grados de libertad, siendo m el número de parámetros estimados en el modelo.

Además de verificar la aleatoriedad de la serie de residuales estimados se analiza la estacionaridad e invertibilidad del modelo estimado, como así también la subespecificación o sobreespecificación del mismo.

El objetivo fundamental del estudio es obtener buenas previsiones para las series en consideración, por lo cual para la selección final del modelo a utilizar, se evaluará la capacidad predictiva de los modelos analizados.

II.3 Modelos de regresión con errores ARIMA.

Con el propósito de incluir en el modelo de pronóstico posibles variables explicativas que mejoren su capacidad predictiva y/o variables artificiales (dummies) que permitan modelar cambios de nivel, outliers, etc. , es posible trabajar con los denominados modelos de regresión con errores correlacionados (REG-ARIMA). Su forma general es:

$$Z_t = \beta' X_t + \epsilon_t, \quad t = 1, \dots, T$$

$$(1 - B)^d (1 - B^s)^D \phi(B) \Phi(B^s) (\epsilon_t - \mu) = \theta(B) \Theta(B^s) a_t \quad (\text{II.3.1})$$

donde el vector de variables independientes está dado por $X'_t = (X_{t,1}, \dots, X_{t,m})$, y $\beta' = (\beta_1, \dots, \beta_m)$ es el vector de parámetros de la regresión. Los errores ϵ_t siguen un modelo SARIMA $(p, d, q)(P, D, Q)_s$.

El procedimiento clásico para estimar modelos REG-ARIMA es el estimador de máxima verosimilitud (EMV) correspondiente a errores normales. Pierce (1971) utilizó

el enfoque de suma de cuadrados condicionales (SCC), el cual puede considerarse una aproximación asintóticamente equivalente a máxima verosimilitud exacta.

Dado que todos los estimadores clásicos son extremadamente sensibles a la presencia de outliers tanto en la serie en estudio como en las variables explicativas, se hace necesario contar con una metodología robusta de estimación de modelos REG-ARIMA, que está siendo desarrollada por el área metodológica de este Proyecto.

Las variables explicativas del modelo REG-ARIMA pueden ser variables cuantitativas relacionadas con la serie en estudio o variables ficticias que representen outliers aislados, cambios de nivel, etc. Así una variable ficticia que represente un outlier en el instante T_0 es de la forma

$$OA_t^{T_0} = \begin{cases} 1 & t = T_0 \\ 0 & t \neq T_0 \end{cases}$$

y una variable que represente un cambio de nivel en el instante T_0 puede ser de la forma

$$CN_t^{T_0} = \begin{cases} -1 & t < T_0 \\ 0 & t \geq T_0 \end{cases}$$

Asimismo es posible utilizar variables que representen, por ejemplo, crecimientos o decrecimientos lineales, de la forma

$$R_t^{T_0, T_1} = \begin{cases} -1 & t \leq T_0 \\ \frac{t-T_0}{T_1-T_0} - 1 & T_0 < t < T_1 \\ 0 & t \geq T_1 \end{cases}$$

II.4 Modelos ARIMA con intervención.

Las series de tiempo se ven frecuentemente afectadas por eventos externos tales como cambios de políticas económicas, los cuáles producen cambios de nivel o valores atípicos (outliers). Box y Tiao (1975) denominan intervenciones a estos eventos externos que

influyen sobre el comportamiento de la serie y proponen una técnica para tratarlos a la que se denomina modelos ARIMA con intervención.

Para especificar estos modelos se requieren dos características: el punto de partida donde un evento externo (intervención) comienza a influir sobre la serie y la forma general del impacto del mismo sobre el comportamiento de la serie.

Existen dos tipos comunes de variables de intervención:

- una intervención que ocurre en el tiempo T_0 y cuyo efecto continúa en los períodos subsiguientes. En este caso la variable de intervención es una función escalonada del tipo

$$S_t^{T_0} = \begin{cases} 0 & t < T_0 \\ 1 & t \geq T_0 \end{cases}$$

- una intervención que sólo afecta un período, es decir una función pulso del tipo

$$P_t^{T_0} = \begin{cases} 1 & t = T_0 \\ 0 & t \neq T_0 \end{cases}$$

Existen muchas formas posibles de funciones de intervención pero en este caso sólo se presentan las usadas en el análisis de las series en estudio. Ellas son:

- Existe un ~~un~~ impacto en el instante T_0 que no repercute en otros períodos. En este caso el término correspondiente a la intervención es de la forma

$$w_0 P_t^{T_0}$$

- Existe un impacto en un período determinado y el efecto de la intervención repercute en los períodos siguientes en forma gradual. En este caso la intervención es de la forma

$$\frac{w_0}{(1 - \delta B)} S_t^{T_0}$$

donde δ toma generalmente valores entre 0 y 1.

Si se tiene un modelo SARIMA univariado (II.2.1), se pueden incorporar intervenciones modificando la ecuación como sigue

$$(Z_t - \mu) = \frac{\theta(B) \Theta(B^s)}{(1 - B)^d (1 - B^s)^D \phi(B) \Phi(B^s)} a_t + \sum_{i=1}^K \Psi_i(B) E_{it}^{T_0} \quad (\text{II.4.1})$$

siendo K el número de intervenciones, $E_{it}^{T_0}(B)$ una variable tipo $P_i^{T_0}$ o $S_i^{T_0}$ y

$$\Psi_i(B) = \frac{w_i(B)}{\delta_i(B)},$$

con $w_i(B) = w_{i0} + w_{i1} B + \dots + w_{ir} B^{ir}$, $\delta_i(B) = 1 - \delta_{i1} B - \dots - \delta_{iv} B^{iv}$

El orden de estos dos polinomios depende del tipo de intervención. Normalmente se supone que $w_i(B)$ tiene raíces fuera del círculo unitario y $\delta_i(B)$, fuera o sobre el círculo unitario.

Este tipo de modelo sólo debe usarse cuando existe realmente un factor externo que afecta el comportamiento de la serie en estudio.

II.5 Selección de modelos.

Puede ocurrir que existan varios modelos adecuados que representan el conjunto de datos ; decidir cuál de ellos es el mejor, puede ser dificultoso. Por ello existen diferentes criterios para comparar modelos, entre los que podemos mencionar:

- Comparación de los errores cuadráticos medios.
- criterio de AKAIKE (AIC): Este criterio debido a Akaike (1974) se basa en Teoría de la Información y selecciona el modelo en base no sólo a menor varianza de los residuales sino también utilizando el principio de parsimonia que consiste en elegir entre modelos que producen igual varianza aquel que contiene menor número de

parámetros. Si M es el número de parámetros estimados en el modelo y $\hat{\sigma}^2$ es la varianza de los residuos, el criterio de Akaike consiste en minimizar:

$$AIC = -2 \ln(\hat{\sigma}^2) + 2M$$

- criterio de SCHWARTZ (SBC): Es similar al criterio anterior y es debido a Schwartz (1978). Utiliza un criterio Bayesiano para la selección del modelo y consiste en minimizar:

$$SBC = -2 \ln(\hat{\sigma}^2) + \ln(n) M$$

siendo n la longitud de la serie en estudio.

- Criterios basados en la capacidad predictiva de los modelos: Con el propósito de evaluar la capacidad predictiva de los modelos es posible realizar estimaciones y pronósticos sobre diferentes períodos. Se calculan tres conjuntos de errores y medidas basadas en ellos (Makridakis et al (1982)). El primer conjunto de errores se calcula sobre el período de estimación total de longitud $n - 3$, el segundo sobre el último año de ese período y el tercero sobre tres meses posteriores al período de estimación y no incluidos en el mismo. Se realizan pronósticos a un horizonte máximo de tres meses por razones que serán expuestas en el parágrafo III.

Si $e_t = Z_t - \hat{Z}_t$, se definen:

El error medio absoluto porcentual (MAPE):

$$MAPE = \frac{1}{n-3} \sum_{t=1}^{n-3} \frac{|e_t|}{Z_t} * 100$$

El error medio absoluto porcentual sobre los últimos 12 meses (MAPE12):

$$MAPE12 = \frac{1}{12} \sum_{t=n-14}^{n-3} \frac{|e_t|}{Z_t} * 100$$

El error medio absoluto porcentual post-muestral (PSMAPE):

$$\text{PSMAPE} = \frac{1}{3} \sum_{t=n-2}^n \frac{|e_t|}{Z_t} * 100$$

II.6 Detección y tratamiento de valores extremos.

Se utilizaron dos diferentes metodologías para detectar y modelar valores extremos. A continuación se describen brevemente ambas.

- II.6.1. Utilización del método X11-ARIMA.

A través del programa X-11 ARIMA, descrito en el párrafo II.1.3, se puede estimar la serie de irregulares I_t . Valores muy grandes o chicos de irregulares pueden estar indicando valores extremos, los cuales afectan, como ya se mencionó, tanto la etapa de identificación como la de estimación del modelo, como así también aumentan considerablemente la varianza de los errores.

Una forma de tratar estos irregulares extremos es usar una variable auxiliar escalonada que toma distintos valores según la magnitud de los mismos.

El valor del desvío standard de los irregulares, σ_I , es un valor que se puede tomar como referencia para construir la variable auxiliar. Por ejemplo, si se trabaja con un modelo multiplicativo, se podría definir la variable auxiliar de la siguiente manera:

$$Y_t = \begin{cases} 1 & I_t > 100 + 3\sigma_I \\ 0.5 & 100 + 2\sigma_I < I_t \leq 100 + 3\sigma_I \\ 0 & 100 - 2\sigma_I < I_t \leq 100 + 2\sigma_I \\ -0.5 & 100 - 3\sigma_I < I_t \leq 100 - 2\sigma_I \\ -1 & I_t \leq 100 - 3\sigma_I \end{cases}$$

El modelo (II.4.1) incorporando esta nueva variable auxiliar se puede expresar:

$$(Z_t - \mu) = \frac{\theta(B)\Theta(B^s)}{(1-B)^d(1-B^s)^D\phi(B)\Phi(B^s)}a_t + \sum_{i=1}^K \Psi_i(B)E_{it}^{T_0} + \gamma Y_t$$

- II.6.2. Utilización de un método robusto de identificación de outliers.

El programa ESTIN de estimación robusta de modelos SARIMA detecta posibles outliers aditivos y cambios de nivel que es posible incorporar a un modelo de regresión con errores correlacionados en la forma de variables dummy, del tipo descritas en el párrafo II.3. Ese tipo de variables también permite modelar comportamientos lineales crecientes o decrecientes. El modelo de regresión a utilizar será de la forma

$$Z_t = \beta' X_t + \epsilon_t, \quad t = 1, \dots, T$$

$$(1 - B)^d (1 - B^s)^D \phi(B) \Phi(B^s) (\epsilon_t - \mu) = \theta(B) \Theta(B^s) a_t$$

donde $X_t = (X_{t1}, \dots, X_{tm})$ incluye como componentes variables del tipo $OA_t^{T_0}$, $CN_t^{T_0}$ o $R_t^{T_0, T_1}$.

II.7 Combinación de pronósticos.

Si se dispone de dos o más conjuntos de pronósticos, ya sea basados en modelos competitivos, en formas funcionales diferentes o en distintos conjuntos de información, en general se obtiene una considerable mejora en la capacidad predictiva utilizando pronósticos combinados (Granger & Newbold (1977), Granger & Ramanathan (1984), Newbold & Granger (1974), Winkler & Makridakis (1983)). De hecho puede ocurrir que uno de los modelos individuales contenga información que los otros no contienen o sea mejor predictor en algún tipo de situación particular. Por lo tanto en vez de descartar uno de los modelos alternativos puede ser ventajoso incorporarlo en un único pronóstico combinado.

Una manera simple de obtener pronósticos combinados es a través de promedios ponderados de los pronósticos individuales con pesos elegidos adecuadamente.

- II.7.1. Combinación de pronósticos a un paso.

Se describirá la combinación de dos pronósticos, que es el caso de interés en este estudio, aunque es posible obtener la generalización a más de dos.

Sean $f_n^{(1)}$ y $f_n^{(2)}$ pronósticos insesgados a un paso de Z_n , obtenidos mediante los dos modelos alternativos que denominaremos 1 y 2 respectivamente, con errores de pronóstico

$$e_n^{(j)} = Z_n - f_n^{(j)}, \quad j = 1, 2$$

tales que

$$E(e_n^{(j)}) = 0, \quad E(e_n^{(j)})^2 = \sigma_j^2, \quad j = 1, 2$$

y

$$E(e_n^{(1)} e_n^{(2)}) = \rho \sigma_1 \sigma_2$$

Si se considera ahora una combinación lineal de ambos pronósticos

$$C_n = k f_n^{(1)} + (1 - k) f_n^{(2)}$$

el error de pronóstico correspondiente es

$$e_n^{(c)} = Z_n - C_n = k e_n^{(1)} + (1 - k) e_n^{(2)}$$

y la varianza del error de predicción

$$\sigma_c^2 = k^2 \sigma_1^2 + (1 - k)^2 \sigma_2^2 + 2k(1 - k) \rho \sigma_1 \sigma_2$$

Esta varianza se minimiza para el valor de k dado por:

$$k_0 = \frac{\sigma_2^2 - \rho \sigma_1 \sigma_2}{\sigma_1^2 + \sigma_2^2 - 2\rho \sigma_1 \sigma_2}$$

Sustituyendo k_0 en la expresión de la varianza se obtiene la mínima varianza

$$\sigma_{c,0}^2 = \frac{\sigma_1^2 \sigma_2^2 (1 - \rho^2)}{\sigma_1^2 + \sigma_2^2 - 2\rho\sigma_1\sigma_2}$$

Es de notar que $\sigma_{c,0}^2$ es menor que el mínimo entre σ_1^2 y σ_2^2 , es decir que el pronóstico combinado óptimo tiene menor error cuadrático medio que los dos pronósticos componentes.

En la práctica los valores de σ_1^2, σ_2^2 y ρ deben ser reemplazados por sus estimadores muestrales. Una elección natural es:

$$\widehat{k}_n = \frac{\sum_{t=n-v}^{n-1} (e_t^{(2)2} - e_t^{(1)} e_t^{(2)})}{\sum_{t=n-v}^{n-1} (e_t^{(1)2} + e_t^{(2)2} - 2e_t^{(1)} e_t^{(2)})} \quad (1)$$

Dada una muestra $e_t^{(j)}$, $t = n - v, \dots, n - 1$, $j = 1, 2$ de una distribución normal bivariada, $\widehat{k}_n$ es el estimador de máxima verosimilitud de k_0 .

Aunque esta forma de elegir los pesos es natural, tiene dos dificultades. En primer lugar, el coeficiente de correlación no es bien estimado en el caso de muestras pequeñas, y en segundo lugar podría ocurrir que la performance relativa de ambos modelos de pronóstico sea no estacionaria, haciendo necesario el uso de pesos que se adapten rápidamente a los cambios. Bates y Granger (1969) proponen una serie de elecciones alternativas de pesos, incluyendo las siguientes:

$$\widehat{k}_n = \frac{\sum_{t=n-v}^{n-1} e_t^{(2)2}}{\sum_{t=n-v}^{n-1} (e_t^{(1)2} + e_t^{(2)2})} \quad (2)$$

$$\widehat{k}_n = \alpha \widehat{k}_{n-1} + \frac{(1-\alpha) \sum_{t=n-v}^{n-1} e_t^{(2)2}}{\sum_{t=n-v}^{n-1} (e_t^{(1)2} + e_t^{(2)2})}, \quad 0 < \alpha < 1 \quad (3)$$

$$\widehat{k}_n = \frac{\sum_{t=1}^{n-1} W_t (e_t^{(2)2} - e_t^{(1)} e_t^{(2)})}{\sum_{t=1}^{n-1} W_t (e_t^{(1)2} + e_t^{(2)2} - 2e_t^{(1)} e_t^{(2)})}, \quad W \geq 1 \quad (4)$$

$$\widehat{k}_n = \frac{\sum_{t=1}^{n-1} W_t e_t^{(2)2}}{\sum_{t=1}^{n-1} W_t (e_t^{(1)2} + e_t^{(2)2})}, \quad W \geq 1 \quad (5)$$

Diferentes estudios empíricos han mostrado que el pronóstico combinado es superior a ambos pronósticos individuales en un alto porcentaje de las series analizadas. Además Granger y Newbold (1977) mostraron que los procedimientos que ignoran la correlación entre los errores de pronóstico (2,3 y 5) son considerablemente más exitosos que los que la tienen en cuenta (1 y 4).

En el caso de las series que son objeto de este estudio se analiza mediante la simulación de varios conjuntos de pronósticos, el comportamiento de los distintos sistemas de pesos, con el fin de seleccionar el más adecuado a estas series, teniendo en cuenta además las recomendaciones halladas en la bibliografía.

- II.7.2. Combinación de pronósticos a más de un paso.

Las fórmulas obtenidas para ponderaciones óptimas y varianza mínima se generalizan inmediatamente al caso de pronósticos a l pasos ($l > 1$) reemplazando las varianzas σ_1^2 y σ_2^2 y la correlación ρ por las correspondientes varianzas y correlación de las series de errores de pronósticos a l pasos.

III. RESULTADOS

III.1 Serie Total de Importaciones.

Tanto los valores de las series de Importaciones como las de Exportaciones se consignan en miles de dólares y en todos los casos se presentan los modelos seleccionados en base a los criterios expuestos en el párrafo II.5. Los valores pronosticados y los correspondientes intervalos de confianza se consignan en millones de dólares.

Dado que los modelos se identificaron y estimaron en base a la información disponible hasta marzo de 1993, contenida en el Informe Semanal del día 21 de septiembre, se deberá analizar periódicamente cómo se modifican los mismos cuando se incorporan nuevos datos. Este análisis podría conducir a cambios en los modelos presentados.


- III.1.1. ~~Análisis~~ análisis descriptivo.

A partir de la observación de gráficos de la serie , como así también del análisis de la misma mediante el método X11-ARIMA y el método robusto de estimación, se resuelve trabajar con el período reducido comenzando en enero de 1983, debido a que los tres primeros años muestran un comportamiento altamente irregular que afecta tanto la identificación como la estimación de posibles modelos de pronóstico.

Como se observa en el Gráfico 1 la serie de Importaciones fluctúa aproximadamente alrededor de un nivel desde 1983 y hasta los primeros meses de 1991 . A partir de entonces comienza un crecimiento acelerado hasta octubre de 1992. Los últimos meses del período





en estudio muestran un comportamiento errático.

Gráfico 1 - Total de Importaciones (01/80 a 03/93)




En los gráficos de medias y medianas mensuales (Gráfico 2) correspondientes al período reducido, se observa un comportamiento estacional más marcado en el gráfico de medianas que en el de medias, con un descenso en el mes de febrero y un pico en el mes de septiembre. La diferencia entre ambos gráficos se debe probablemente a que los valores extremos, frecuentes en nuestras series económicas, oscurecen muchas veces o al menos atenúan el efecto estacional.

Gráfico 2 - Total de Importaciones - Medias y medianas mensuales



Al procesar la serie con el programa X11-ARIMA los tests provistos por el mismo confirman la presencia de estacionalidad identificable, siendo tanto el test paramétrico como el no paramétrico de estacionalidad estable significativos al 1%, y no detectándose estacionalidad móvil. Asimismo resulta significativo a nivel 1% el test para presencia del efecto días de actividad (trading-day). En el Gráfico 3 se presenta el periodograma acumulado de la serie Importaciones desprovista de tendencia. Se observa claramente la presencia de estacionalidad, reflejada por un salto en la frecuencia 1, correspondiente a un ciclo anual.

Gráfico 3 - Total de Importaciones - Periodograma acumulado



Es de destacar la importante contribución de la componente irregular a la varianza de la serie:

Lapso (meses)	Irregularidad	Tendencia	Estacionalidad
1	42.64	6.99	44.99
3	20.32	35.48	42.81

El programa ESTIN de estimación robusta de modelos ARIMA detecta posibles outliers (valores atípicos) y cambios de nivel. Entre ellos los más significativos son dos outliers aditivos correspondientes a los meses de marzo de 1992 y abril de 1991. Este último período coincide con el comienzo del plan de convertibilidad.

Finalmente se realizan correlogramas y correlogramas parciales de la serie original y de la serie con una diferencia ordinaria, una diferencia estacional y ambas diferencias con el propósito de analizar la estructura de autocorrelación. Estos correlogramas son utilizados posteriormente en la etapa de identificación de modelos.

- III.1.2. Modelos ARIMA con intervención.

El modelo seleccionado consta de los siguientes términos:

- un modelo ~~SARIMA~~ $SARIMA(1, 0, 1)(0, 1, 1)_{12}$,
- una intervención del tipo:

$$\frac{w_0}{(1 - \delta B)} X_t$$

donde

$$X_t = \begin{cases} 1 & 4/91 \leq t \leq 8/92 \\ 0 & \text{en otro caso} \end{cases}$$

que representa el brusco cambio de comportamiento a partir de abril del año 1991, producido por la implementación de un nuevo plan económico, el cual afecta gradualmente los períodos posteriores hasta el mes de agosto de 1992,

- una intervención del tipo $w_1 S_t$, donde

$$S_t = \begin{cases} 1 & 11/92 \leq t \leq 2/93 \\ 0 & \text{en otro caso} \end{cases}$$

que representa un nuevo cambio en el comportamiento de la serie a partir de noviembre de 1992 con efecto hasta febrero de 1993. Este cambio se debe a un ajuste de la política económica.

- una variable auxiliar del tipo Y_t , descrita en el párrafo II.3.2.1, la cual fue incorporada al modelo como

$$Y_t = \begin{cases} 1 & I_t > 120 \\ 0.5 & 110 < I_t \leq 120 \\ 0 & 90 < I_t \leq 110 \\ -0.5 & 80 < I_t \leq 90 \\ -1 & I_t < 80 \end{cases}$$

- Esta variable permite neutralizar el efecto de irregulares que deben ser tratados como valores extremos. Dichos irregulares son estimados a partir del procedimiento X11 del SAS. Se detectan valores irregulares muy alejados del valor medio 100, tanto por defecto (menos importaciones que las esperadas para el mes), como por exceso (más importaciones que las esperadas para el mes).

- un término de la forma

$$\sum_{j=1}^8 \nu_j T_{jt}$$

que permite ajustar el efecto de variación trading-day, siendo

$$T_{jt} = X_{jt} - X_{7t} \quad 1 \leq j \leq 6$$

y X_{jt} , $j = 1, \dots, 7$, el número de veces que los días lunes, martes, etc., ocurren en el mes t .

Este término resulta de reparametrizar la forma natural de modelación del efecto trading-day:

$$TD_t = \sum_{j=1}^7 \eta_j X_{jt}$$

siendo η_j , $j = 1, 2, \dots, 7$ la tasa promedio de actividad de los días de la semana.

El modelo resultante que se ajusta a la serie de Importaciones es:

$$Z_t = \frac{(1 - \theta_1 B)(1 - \Theta_{12} B^{12})}{(1 - B^{12})(1 - \phi_1 B)} a_t + \frac{w_0}{(1 - \delta B)} X_t + w_1 S_t + \gamma_0 Y_t + \sum_{j=1}^6 \nu_j T_{jt} \quad (\text{III.1.1})$$

Utilizando el procedimiento ARIMA del SAS se estiman los parámetros del modelo por el método de máxima verosimilitud, obteniéndose, para el período analizado, los siguientes resultados:

Parámetro	Estimador	Error std aprox.	Razón T
θ_1	-0.24729	0.11307	-2.19
Θ_{12}	0.45679	0.11885	3.84
Φ_1	0.82551	0.06392	12.91
w_0	63803.0	8297.5	7.69
δ	0.99364	0.00999	99.49
w_1	-263994.3	31337.4	-8.42
γ_0	90813.2	9278.9	9.79
ν_1	-8733.5	4672.8	-1.87
ν_2	16515.4	4978.2	3.32
ν_3	9827.6	4756.7	2.07
ν_4	-10172.0	4955.0	-2.05
ν_5	8607.7	5009.4	1.72
ν_6	7660.9	4733.1	1.62

Varianza estimada = 1648714802

Error standard estimado = 40604.3692

Es de destacar la alta significación del estimador de w_0 y el valor de δ cercano a 1, que indica un crecimiento prácticamente lineal en el período abril de 1991 a agosto de 1992.

El test de Ljung y Box para testear autocorrelación en los residuales de este modelo produjo los siguientes valores p a distintos lags:

Hasta lag	Chi cuadrado	Grados de libertad	Probabilidad asociada
6	10.43	3	0.015
12	13.67	9	0.135
18	14.37	15	0.498
24	15.66	21	0.788

Utilizando este modelo se realizaron previsiones a tres meses. Dichas previsiones (en millones de dólares) juntamente con los límites de los correspondientes intervalos de confianza de nivel 0.95 son:

Mes	Valor pronosticado	Límite inferior	Límite superior
Abril 93	1289.3	1209.7	1368.9
Mayo 93	1165.4	1048.7	1282.1
Junio 93	1287.4	1151.1	1423.8

El error medio absoluto porcentual sobre los últimos doce meses (MAPE12) es de 3.25% y el error medio absoluto porcentual post-muestral (PSMAPE) es 7.5 %.

En éste y los demás modelos utilizados en el trabajo, el horizonte de previsión se mantuvo en un máximo de tres períodos, ya que la varianza de los pronósticos y por ende la longitud de los intervalos de confianza, hacen que no sea razonable realizar pronósticos a un horizonte mayor.

- III.1.3. Modelos de regresión con errores ARIMA.

El modelo ajustado a la serie de Importaciones es el siguiente:

$$Z_t = \beta_1 \text{Rec} + \beta_2 \text{R9105} + \beta_3 \text{OA9104} + \beta_4 \text{OA9203} + \beta_5 \text{CN9112} + \beta_6 \text{R9208} + \epsilon_t$$

$$(1 - B)(1 - B^{12})(1 - \phi_1 B - \phi_2 B^2)\epsilon_t = (1 - \Theta_{12} B^{12})a_t \quad (\text{III.1.2})$$

siendo

- Rec : Derechos de Importación
- R9105 : una rampa representando un crecimiento lineal desde mayo de 1991 hasta agosto de 1992. La forma general de una rampa comenzando en el mes t_1 y finalizando en el mes t_2 es:

$$\text{Rampa}(t) = \begin{cases} -1 & t \leq t_1 \\ \frac{t-t_1}{t_2-t_1} - 1 & t_1 < t < t_2 \\ 0 & t \geq t_2 \end{cases}$$

- OA9104 : un outlier aditivo en el mes de abril de 1991
- OA9203 : un outlier aditivo en el mes de marzo de 1992
- CN9112 : un cambio de nivel en diciembre de 1991
- R9208 : una rampa representando un decrecimiento lineal desde agosto de 1992 hasta enero de 1993

Los outliers aditivos y cambios de nivel se detectan utilizando el programa ESTIN de estimación robusta de modelos SARIMA. En cuanto a las rampas se las construye a partir del análisis del comportamiento de la serie y de su relación con las medidas económicas mencionadas al describir el modelo de intervención.


Respecto a la variable Derechos de Importación (Rec), ésta fue seleccionada luego del análisis de diferentes variables que podrían ser utilizadas como explicativas en un modelo

de regresión. El Derecho de Importación es un gravamen que se aplica sobre el valor CIF de la mercadería importada. Esta información es proporcionada por la Dirección Nacional de Investigaciones y Análisis Fiscal de la Secretaría de Ingresos Públicos. La serie considerada representa los Derechos de Importación totales mensuales. En el Gráfico 4 se presenta esta serie en el período en estudio y en el Gráfico 5 se describe la relación entre Derechos de Importación y la serie de Importaciones.

Gráfico 4 - Derechos de Importación (01/80 a 03/93)



Gráfico 5 - Relación entre Derechos de Importación e Importaciones



Se observa la alta correlación entre ambas, la cual se confirma analíticamente. Cabe destacar que, a pesar de que en general, se cuenta con valores de Derechos de Importación con anterioridad a los valores de Importaciones, es necesario en algunas circunstancias pronosticar valores de la primera a fin de obtener pronósticos a 1, 2 y 3 pasos para la segunda. Por esa razón la serie Derechos de Importación debe ser modelada y se obtienen, cuando es necesario, valores pronosticados de la misma. Las varianzas de los errores de predicción obviamente incluyen, cuando Derechos de Importación es pronosticada, el término correspondiente a la varianza de su error de predicción.

Utilizando el procedimiento ARIMA del SAS se estiman los parámetros del modelo por el método de máxima verosimilitud, obteniéndose, para el período analizado, los siguientes resultados:

Parámetro	Estimador	Error std aprox.	Razón T
Θ_{12}	0.75986	0.14775	5.14
Φ_1	-0.35270	0.09911	-3.56
Φ_2	-0.42834	0.09837	-4.35
<i>Rec</i>	2077.0	414.12450	5.02
<i>R9105</i>	802165.3	141510.1	5.67
<i>OA9104</i>	115009.3	41581.6	2.77
<i>OA9203</i>	-242762.1	50184.2	-4.84
<i>CN9112</i>	-169688.7	52460.0	-3.23
<i>R9208</i>	-274969.3	69440.0	-3.96

Varianza estimada = 2963908641

Error standard estimado = 54441.7913

Es importante la significación del estimador del coeficiente correspondiente a Derechos de Importación, como así también la del correspondiente a la rampa que representa el crecimiento lineal en el período mayo de 1991 a agosto de 1992.

El test de Ljung y Box para testear autocorrelación en los residuales de este modelo produjo los siguientes valores p a distintos lags:

Hasta lag	Chi cuadrado	Grados de libertad	Probabilidad asociada
6	0.74	3	0.865
12	3.77	9	0.926
18	7.85	15	0.930
24	15.03	21	0.821

Utilizando este modelo se realizan previsiones a tres meses. Dichas previsiones juntamente con los límites de los correspondientes intervalos de confianza de nivel 0.95 son:

Mes	Valor pronosticado	Límite inferior	Límite superior
Abril 93	1241.1	1130.2	1352.0
Mayo 93	1118.8	986.7	1250.9
Junio 93	1232.1	1094.6	1369.5

El error MAPE12 es del 4.2 % y el error promedio de predicción PSMAPE es del 8.7 %.

- III.1.4. Pronósticos combinados.

Con el fin de seleccionar el método de ponderación y el conjunto de parámetros más adecuados a la serie en estudio se consideraron distintas combinaciones de métodos y parámetros, las cuáles se describen en la Tabla 1.

Se desarrolló un programa en lenguaje SAS el cual, en base a los estimadores de ambos modelos obtenidos con el procedimiento ARIMA, calcula las tres series de errores

de predicción a 1, 2 y 3 pasos. Posteriormente estima las varianzas de las tres series y las correlaciones entre los errores de predicción de ambos modelos. Finalmente calcula, para cada método y combinación de parámetros, las ponderaciones y las varianzas combinadas para pronóstico a 1, 2 y 3 pasos.

Utilizando este programa SAS, se procedió tanto en el caso de la serie de Importaciones como en la de Exportaciones a "simular" el comportamiento de los diferentes métodos de ponderación. Para ello se comenzó considerando el período de estimación terminado en diciembre de 1991, y se obtuvo el pronóstico combinado a 1, 2 y 3 pasos por cada uno de los métodos. Luego se fue incorporando un mes al período de estimación hasta obtener un conjunto de 14 pronósticos a 1 paso, 2 pasos y 3 pasos.

Se calcularon los errores de pronóstico y el porcentaje de veces que la varianza del error de predicción combinado es inferior a las varianzas de los modelos componentes (Tabla 2).

Se calcularon varios estadísticos de los conjuntos de errores de predicción. En la Tabla 3 se presentan los valores de la suma de cuadrados de los errores relativos de predicción a 1, 2 y 3 pasos ($SC(i)$, $i = 1, 2, 3$) y el promedio de los valores absolutos de los errores relativos ($PER(i)$, $i = 1, 2, 3$), o sea:

$$SC(i) = \sum_t^{14} e_{t,i}^2 \quad i = 1, 2, 3$$

$$PER(i) = \frac{1}{14} \sum_t^{14} |e_{t,i}| \quad i = 1, 2, 3$$

siendo $e_{t,i}$ el error relativo a i pasos en el período t .

En base al análisis de estos resultados, se resolvió trabajar con el método de ponderación 5 con $W = 1$, es decir se seleccionaron los pesos:

$$\widehat{k_n} = \frac{\sum_{t=1}^{n-1} e_t^{(2)2}}{\sum_{t=1}^{n-1} (e_t^{(1)2} + e_t^{(2)2})}$$

Los pronósticos combinados obtenidos son los siguientes:

Mes	Valor pronosticado	Límite inferior	Límite superior
Abril 93	1272.9	1200.3	1345.4
Mayo 93	1140.7	1061.4	1220.0
Junio 93	1259.4	1181.2	1337.6

El error PSMAPE de los pronósticos combinados es del 8.4 %

Cabe destacar que la utilización del pronóstico combinado produce una disminución del 17 % en la varianza de los errores de predicción a un paso, respecto a la menor varianza de los modelos individuales y, por lo tanto una disminución de la amplitud de los intervalos de confianza.


III.2 Serie Total de Exportaciones.

- III.2.1. Análisis descriptivo.

La serie Total de Exportaciones (Gráfico 6) fluctúa alrededor de un nivel hasta fines de 1987. A partir de 1988 parece existir una tendencia ligeramente creciente, no pudiéndose

determinar aún si la misma continúa durante el último año del período en estudio.





Gráfico 6 - Total de Exportaciones (01/80 a 03/93)



En el Gráfico 7, de medias y medianas mensuales, se observa un claro comportamiento estacional, creciente desde noviembre hasta julio y decreciente a partir de ese mes.


Al procesar la serie con el programa X11 ARIMA, los tests provistos por el mismo confirmaron la presencia de estacionalidad identificable, siendo tanto el test paramétrico como el no paramétrico de estacionalidad estable, significativos al 0.1% y 1%, respectivamente, y no detectándose estacionalidad móvil.

Gráfico 7 - Total de Exportaciones - Medias y medianas mensuales



En el periodograma acumulado de la serie de Exportaciones desprovista de tendencia (Gráfico 8), se observa claramente la presencia de estacionalidad, reflejada por un salto en la frecuencia 1 correspondiente a un ciclo anual.

Gráfico 8 - Total de Exportaciones- Periodograma acumulado



Es importante la contribución relativa de la componente Irregular a la varianza de la serie:

Lapso (meses)	Irregularidad	Tendencia	Estacionalidad
1	54.02	4.88	41.10
3	20.97	11.89	67.14

El programa ESTIN de estimación robusta de modelos ARIMA detecta posibles outliers. Entre ellos los más significativos son los outliers aditivos correspondientes a los meses de diciembre de 1988 y marzo de 1990 y un cambio de nivel en enero de 1990.

- III.2.2. Modelos ARIMA con intervención.

El modelo que representa la serie es un $SARIMA(1, 0, 2)(0, 1, 1)_{12}$ con $\theta_1 = 0$, al cual se le adiciona una variable auxiliar para neutralizar los valores extremos,

$$Z_t = \frac{(1 - \theta_2 B^2)(1 - \Theta_{12} B^{12})}{(1 - B^{12})(1 - \phi_1 B)} a_t + \gamma_0 Y_t \quad (\text{III.2.1})$$

La variable auxiliar Y_t se define en la forma descrita en el párrafo II.6.1 con $\sigma = 8$.

La estimación de los coeficientes de este modelo arrojó los siguientes resultados:

Parámetro	Estimador	Error std aprox.	Razón T
θ_2	-0.23081	0.08316	-2.78
Θ_{12}	0.73566	0.08075	9.11
Φ_1	0.86117	0.04593	18.75
γ_0	206735.0	17946.9	11.52

Varianza estimada = 5860141299

Error standard estimado = 76551.5597

El test de Ljung y-Box para testear autocorrelación en los residuales produjo los siguientes valores p a distintos lags:

Hasta lag	Chi cuadrado	Grados de libertad	Probabilidad asociada
6	3.11	3	0.375
12	10.00	9	0.350
18	18.58	15	0.233
24	24.58	21	0.266

Estimado el modelo, se realizaron previsiones a 3 meses, las cuales se presentan juntamente con sus respectivos intervalos de confianza de nivel 0.95.

Mes	Valor pronosticado	Límite inferior	Límite superior
Abril 93	1071.5	921.5	1221.6
Mayo 93	1192.0	993.9	1390.0
Junio 93	1186.6	940.6	1432.5

El error MAPE12 es 4.8 % y el error PSMAPE es 1.5 %.

- III.2.3. Modelos de regresión con errores ARIMA.

El modelo ajustado a la serie de Exportaciones es el siguiente:

$$Z_t = \beta_1 CN8009 + \beta_2 OA8204 + \beta_3 OA8212 + \beta_4 OA8706 + \beta_5 OA8808 \\ + \beta_6 OA8811 + \beta_7 OA8812 + \beta_8 CN9001 + \beta_9 OA9003 + \beta_{10} OA9101 + \epsilon_t$$

$$(1 - B^{12})(1 - \phi_1 B)\epsilon_t = (1 - \theta_1 B)(1 - \Theta_{12} B^{12})a_t$$

siendo, en general,

- OAamm : un outlier aditivo en el mes mm del año aa.
- CNaamm : un cambio de nivel en el mes mm del año aa.

La estimación de los coeficientes de este modelo arroja los siguientes resultados:

Parámetro	Estimador	Error std aprox.	Razón T
θ_4	0.24789	0.09104	2.72
Θ_{12}	0.69567	0.07955	8.75
ϕ_1	0.88228	0.04574	19.29
CN8009	177588.8	64235.2	2.76
OA8204	195034.0	48074.8	4.06
OA8212	165182.8	48108.7	3.43
OA8706	188063.1	47226.1	3.98
OA8808	195317.2	49257.3	3.97
OA8811	181958.1	54841.1	3.32
OA8812	313847.6	56183.0	5.59
CN9001	261176.0	57372.8	4.55
OA9003	256981.2	47996.9	5.35
OA9101	-166088.0	48553.2	-3.42

Varianza estimada = 5222818241

Error standard estimado = 72269.0684

El test de Ljung y Box para testear autocorrelación en los residuales produce los siguientes valores p a distintos lags:

Hasta lag	Chi cuadrado	Grados de libertad	Probabilidad asociada
6	0.31	3	0.957
12	4.75	9	0.855
18	9.04	15	0.876
24	12.52	21	0.924

Estimado el modelo, se realizan previsiones a 3 meses, las cuales se presentan juntamente con sus respectivos intervalos de confianza de nivel 0.95.

Mes	Valor pronosticado	Límite inferior	Límite superior
Abril 93	1100.9	960.6	1241.2
Mayo 93	1218.2	1031.1	1405.3
Junio 93	1221.6	1005.0	1438.3

El error de previsión MAPE₁₂ es 4.5 % y el PSMAPE 1.8 %.

- III.2.4. Pronósticos combinados.

Mediante un análisis similar al efectuado para la serie de Importaciones se llegó a la misma selección del método de ponderación, es decir se utiliza el método 5 con $W = 1$.

Los pronósticos combinados obtenidos son los siguientes:

Mes	Valor pronosticado	Límite inferior	Límite superior
Abril 93	1085.3	966.1	1204.5
Mayo 93	1206.4	1085.9	1327.0
Junio 93	1206.3	1085.5	1327.1

El error PSMAPE es del 1.2 %, y la utilización del pronóstico combinado produjo una disminución en la varianza de los errores de predicción a un paso del orden del 28 % respecto a la menor varianza de los pronósticos individuales.

III.3 Series de Importaciones por usos económicos.

Al comienzo del estudio se analizaron las componentes de la serie Importaciones, no sólo por uso económico, sino también a nivel desagregado a tres dígitos de la Clasificación por Grandes Categorías Económicas (CGCE). El propósito de ese análisis era obtener modelos para los grandes grupos y, a partir de ellos obtener pronósticos para el total. Dado que no fue posible hallar modelos satisfactorios para todas las componentes se realizan finalmente pronósticos sólo a nivel general. De cualquier manera, se presenta a continuación el análisis realizado y, cuando es posible, el modelo obtenido para las componentes de Importaciones clasificada por usos económicos. Estas componentes son:

- * Bienes de Capital
- * Bienes Intermedios
- * Bienes de Consumo
- * Combustibles
- * Vehículos automotores de pasajeros
- * Piezas y accesorios para Bienes de Capital
- * Resto

El período de análisis comienza en enero de 1983 y termina en diciembre de 1992 dado que no se cuenta con valores más actualizados definitivos.

Para determinar cómo es el comportamiento de cada uno de los rubros con respecto al Total, se realizó un análisis de regresión de cada componente respecto del Total, obteniéndose los siguientes valores de R^2 :


Variable explicativa	R^2
Bienes de Capital	0.899
Bienes Intermedios	0.754
Bienes de Consumo	0.879
Combustibles	0.453
Vehículos	0.785
Piezas y Accesorios	0.626
Resto	0.016

Si bien se trata de análisis parciales, se observa que Bienes de Capital y Bienes de Consumo explican el mayor porcentaje de la variabilidad de la serie Total de Importaciones, seguidas por Vehículos y Bienes Intermedios.

III.3.1. Importación de Bienes de Capital.

Es de destacar el crecimiento acelerado que comienza en los primeros meses del año 1991 y se prolonga hasta octubre de 1992.





Gráfico 9 - Bienes de Capital (01/80 a 12/92)



En el gráfico de medias y medianas mensuales (Gráfico 10) se observa escasa estacionalidad en el gráfico de medias y un comportamiento más marcado en el de medianas con un valor mínimo en el mes de febrero y un máximo en agosto. Sin embargo este comportamiento se ve magnificado por la escala ya que en el segundo gráfico de medianas, en el cual juntamente con la mediana se representan los valores originales, ya no aparece.

Se procesa la serie con el programa X11-ARIMA el cual detecta efecto trading-day y muestra que no hay estacionalidad identificable, a pesar de que el test no paramétrico detecta estacionalidad a nivel 1%.

Gráfico 10 - Bienes de Capital - Medias y medianas mensuales



El hecho de que la estacionalidad, si la hay, no sea identificable por el método X11 se debe, entre otras razones, a la importante contribución de la componente irregular a la varianza de la serie.

Lapso (meses)	Irregularidad	Tendencia	Estacionalidad
1	62.80	6.56	24.85
3	49.13	36.30	13.20

Mediante el programa ESTIN de estimación robusta se detectan valores atípicos siendo los más significativos noviembre de 1992, abril de 1991, octubre de 1984 y marzo de 1989.

La modelación de la serie utilizando modelos ARIMA con intervención no produce resultados muy satisfactorios, pudiendo considerarse como el modelo más aceptable el siguiente:

$$Z_t = \frac{1}{(1-B)(1-\Phi_{12}B^{12})}a_t + \frac{w_0}{(1-\delta B)}X_t + w_1 P_t + \gamma_0 Y_t + \sum_{j=1}^6 \nu_j T_{jt}$$

Las variables Y_t , X_t y T_{jt} se definen en forma similar al caso de la serie Total de Importaciones y la variable P_t se define:

$$P_t = \begin{cases} 1 & t = 11/92 \\ 0 & \text{en otro caso} \end{cases}$$

La estimación de este modelo mediante el método de máxima verosimilitud produce los siguientes resultados:

Parámetro	Estimador	Error std aprox.	Razón T
Φ_{12}	0.27058	0.10870	2.49
w_0	5711.7	2678.5	2.13
δ	1.00247	0.02652	40.81
w_1	-83769.9	9053.3	-9.25
γ_0	29897.2	3951.3	7.57
ν_1	-2686.1	1706.4	-1.57
ν_2	7066.5	1714.8	4.12
ν_3	-1499.0	1691.5	-0.89
ν_4	360.2	1750.7	0.21
ν_5	-1812.6	1793.7	-1.01
ν_6	-195.2	1699.3	-0.11

Varianza estimada = 149790127

Error standard estimado = 12238.8777

El test de Ljung y Box para testear autocorrelación en los residuales produjo los siguientes valores p a distintos lags:

Hasta lag	Chi cuadrado	Grados de libertad	Probabilidad
6	7.18	5	0.208
12	9.73	11	0.555
18	13.85	17	0.678
24	20.63	23	0.604

El error MAPE12 con este modelo es 11.3 %.

Por otra parte, el modelo de regresión con errores ARIMA seleccionado para esta serie es el siguiente:

$$Z_t = \beta_1 R9105 + \beta_2 OA8410 + \beta_3 OA8903 + \beta_4 OA9104 + \beta_5 OA9211 + \epsilon_t$$

$$(1 - B)(1 - B^{12})\epsilon_t = (1 - \theta_1 B)(1 - \Theta_{12} B^{12})a_t$$

siendo R9105 una rampa representando un crecimiento lineal desde mayo de 1991 hasta diciembre de 1992, y OAaamm un outlier aditivo en el mes mm del año aa.

La estimación de los coeficientes de este modelo arroja los siguientes resultados:

Parámetro	Estimador	Error std aprox.	Razón T
θ_1	0.34515	0.09485	3.64
Θ_{12}	0.67828	0.07966	8.51
R9105	248217.2	47883.6	5.18
OA8410	45365.5	11022.3	4.12
OA8903	34054.8	11114.5	3.06
OA9104	29814.8	11442.4	2.61
OA9211	-88232.7	12240.9	-7.21

Varianza estimada = 212524939

Error standard estimado = 14578.2351

El test de Ljung y Box para testear autocorrelación en los residuales produce los siguientes valores p a distintos lags:

Hasta lag	Chi cuadrado	Grados de libertad	Probabilidad
6	1.08	4	0.897
12	8.65	10	0.566
18	12.16	16	0.733
24	14.82	22	0.870

El error MAPE12 con este modelo es 7.5 %.

- III.3.2. Importación de Bienes Intermedios.

Es de destacar en el gráfico de esta serie el comportamiento creciente a partir del segundo semestre de 1990, con un pico máximo en octubre de 1992.

Gráfico 11 - Bienes Intermedios (01/80 a 12/92)








Gráfico 12 - Bienes Intermedios - Medias y medianas mensuales



En el Gráfico 12 de medias y medianas mensuales se observa un valor mínimo en febrero con un crecimiento a partir de ese mes. Los meses con valores más altos son septiembre, julio y los meses de octubre a diciembre .

El programa X11-ARIMA detecta efecto trading-day, resultando también significativos los tests de estacionalidad estable e identificable.

La contribución relativa de las componentes a la varianza de la serie es :

Lapso (meses)	Irregularidad	Tendencia	Estacionalidad
1	49.30	5.30	38.00
3	28.40	27.70	41.80

Mediante el programa ESTIN de estimación robusta se detectan valores atípicos siendo los más significativos, como en el caso de Bienes de Capital, noviembre de 1992 y abril de 1991. Asimismo se detectan como atípicos marzo de 1991 y diciembre de 1992. De estos outliers, dos coinciden con el final del período en estudio, en el cual la serie sufre un brusco descenso.

El modelo ARIMA con intervención ajustado a esta serie es:

$$Z_t = \frac{(1 - \theta_6 B^6)(1 - \Theta_{12} B^{12})}{(1 - \phi_1 B)(1 - B^{12})} a_t + \frac{w_0}{(1 - \delta B)} X_t + \gamma_0 Y_t + \sum_{j=1}^6 \nu_j T_{jt}$$

donde las variables X_t, Y_t y T_{jt} son definidas en forma similar que para la serie Bienes de Capital.

La estimación de este modelo mediante el método de máxima verosimilitud produce los siguientes resultados:

Parámetro	Estimador	Error std aprox.	Razón T
θ_0	0.26774	0.11869	2.26
Θ_{12}	0.70784	0.12058	5.87
Φ_1	0.85854	0.05530	15.52
w_0	26058.1	6059.3	4.30
δ	0.91464	0.03226	28.35
γ_0	71311.0	5975.1	11.93
ν_1	5283.3	2995.3	1.76
ν_2	4598.4	3139.7	1.46
ν_3	4059.9	3178.3	1.28
ν_4	-11623.9	3147.3	-3.69
ν_5	13565.6	3165.5	4.29
ν_6	2986.6	2927.9	1.02

Varianza estimada = 468297624

Error standard estimado = 21640.1854

El test de Ljung y Box para testear autocorrelación en los residuales produce los siguientes valores p a distintos lags:

Hasta lag	Chi cuadrado	Grados de libertad	Probabilidad
6	0.71	3	0.871
12	2.78	9	0.972
18	7.74	15	0.934
24	9.41	21	0.986

El error de previsión medio para el último año (MAPE12) es 7.0 %.

El modelo de regresión con errores ARIMA seleccionado para esta serie es el siguiente:

$$Z_t = \beta_1 OA9001 + \beta_2 OA9103 + \beta_3 OA9104 + \beta_4 OA9104 + \beta_5 OA9211 + \beta_6 OA9212 + \epsilon_t$$

$$(1 - B)(1 - B^{12})\epsilon_t = (1 - \theta_1 B - \theta_2 B^2)(1 - \Theta_{12} B^{12})a_t$$

La estimación de los coeficientes de este modelo utilizando el procedimiento ARIMA de SAS, arroja los siguientes resultados:

Parámetro	Estimador	Error std aprox.	Razón T
θ_1	0.28421	0.08486	3.35
θ_3	-0.36400	0.09028	-4.03
θ_{12}	0.73423	0.12385	5.93
OA9001	66320.9	18539.5	3.58
OA9103	-97470.9	19556.2	-4.98
OA9104	57737.0	19450.5	2.97
OA9112	-81906.8	20063.8	-4.08
OA9211	-101398.0	26230.1	-3.87
OA9212	-153521.7	33306.3	-4.61

Varianza estimada = 721040697

Error standard estimado = 26852.201

El test de Ljung y Box para testear autocorrelación en los residuales produce los siguientes valores p a distintos lags:


Hasta lag	Chi cuadrado	Grados de libertad	Probabilidad
6	1.67	3	0.643
12	3.06	9	0.962
18	4.52	15	0.995
24	10.08	21	0.978

El error MAPE12 para este modelo es 3.0 %.

- III.3.3. Importación de Bienes de Consumo.





El nivel de esta serie (Gráfico 13) se mantiene entre mediados de 1982 y mediados de 1990, donde comienza un brusco ascenso con un pico máximo en octubre de 1992.

Gráfico 13 - Bienes de Consumo (01/80 a 12/92)



En el Gráfico 14 de medias y medianas mensuales se observa una estacionalidad creciente desde febrero hasta diciembre.

Gráfico 14 - Bienes de Consumo - Medias y medianas mensuales



El programa X11-ARIMA detecta efecto trading-day y estacionalidad identificable, ya que los tests de estacionalidad estable resultan significativos y no lo es el de estacionalidad móvil.

La contribución relativa de las componentes a la varianza de la serie original es:

Lapso (meses)	Irregularidad	Tendencia	Estacionalidad
1	35.10	12.10	46.14
3	14.00	42.10	42.63

El programa ESTIN de estimación robusta de modelos ARIMA detecta varios valores atípicos, siendo los más significativos los correspondientes a los meses de octubre, enero y febrero de 1992 y septiembre de 1991.

El modelo ARIMA con intervención que mejor ajusta a los datos es de la forma:

$$Z_t = \frac{(1 - \theta_1 B - \theta_2 B^2 - \theta_3 B^3)}{(1 - B)(1 - \Phi_{12} B^{12})} a_t + \frac{w_0}{(1 - \delta B)} X_t + w_1 P_t + \gamma_0 Y_t + \sum_{j=1}^6 \nu_j T_{jt}$$

donde las variables X_t, P_t, Y_t y T_{jt} son definidas en forma similar al caso de la serie Bienes de Capital.

La estimación de este modelo mediante el método de máxima verosimilitud produce los siguientes resultados:

Parámetro	Estimador	Error std aprox.	Razón T
θ_1	-0.27013	0.08532	-3.17
θ_2	0.55688	0.08396	6.63
θ_3	0.65062	0.09348	6.96
Φ_{12}	0.66385	0.14191	4.68
w_0	19630.9	2246.3	8.74
δ	0.97374	0.00940	103.56
w_1	-60645.1	6991.2	-8.67
γ_0	7716.1	2362.5	3.27
ν_1	-2061.3	935.660	-2.20
ν_2	4482.8	1135.6	3.95
ν_3	- 822.58	938.27	-0.88
ν_4	-2128.2	1160.3	-1.83
ν_5	854.6	1035.8	0.83
ν_6	648.844	1066.1	0.61

Varianza estimada = 113274097

Error standard estimado = 10643.0304

El test de Ljung y. Box para testear autocorrelación en los residuales produce los siguientes valores p:

Hasta lag	Chi cuadrado	Grados de libertad	Probabilidad
6	4.06	2	0.131
12	21.45	8	0.006
18	30.62	14	0.006
24	32.08	20	0.042

Como se observa, este modelo no resulta adecuado desde el punto de vista de los tests de aleatoriedad de los residuos, pero no se halló una explicación para las autocorrelaciones significativas.

El error de previsión medio para el último año es 11.2 %.

El modelo de regresión con errores ARIMA seleccionado para esta serie es el siguiente:

$$Z_t = \beta_1 R9104 + \beta_2 R9203 + \beta_3 OA9109 + \beta_4 OA9201 + \beta_5 OA9202 + \beta_6 OA9210 + \epsilon_t$$

$$(1 - B)(1 - B^{12})(1 - \phi_1 B)\epsilon_t = (1 - \Theta_{12} B^{12})a_t$$

siendo R9104 y R9203 rampas representando crecimientos lineales desde abril a noviembre de 1991 y marzo a junio de 1992 respectivamente, y OAaamm un outlier aditivo en el mes mm del año aa.

La estimación de los coeficientes de este modelo utilizando el procedimiento ARIMA de SAS, arroja los siguientes resultados:

Parámetro	Estimador	Error std aprox.	Razón T
ϕ_1	- 0.46998	0.09806	-4.79
Θ_{12}	0.75484	0.14986	5.04
R9104	169388.2	12613.5	13.43
R9203	60943.3	8856.0	6.88
OA9109	-43151.7	5383.2	-8.02
OA9201	-67912.3	5722.7	-11.87
OA9202	-49492.2	5740.1	-8.62
OA9210	90382.4	6288.2	14.37

Varianza estimada = 49130775.5

Error standard estimado = 7009.335

El test de Ljung y Box para testear autocorrelación en los residuales de este modelo produce los siguientes valores p a distintos lags:

Hasta lag	Chi cuadrado	Grados de libertad	Probabilidad
6	3.27	4	0.514
12	3.95	10	0.950
18	13.89	16	0.607
24	19.40	22	0.621


El error de previsión absoluto promedio del último año es 2.8 %.

- III.3.4. Importación de Combustibles.

En el caso de esta serie y las restantes componentes de Importaciones sólo se presenta el análisis descriptivo, ya que su modelación es prácticamente imposible dentro de márgenes admisibles de error de pronóstico.





En el gráfico de esta serie (Gráfico 15) se observa que se produce un cambio de nivel a partir de 1982 y que el comportamiento general es muy irregular. En esta serie no se observa el crecimiento que presentan las series Bienes de Capital, Bienes Intermedios y Bienes de Consumo a partir del año 1991.

Gráfico 15 - Combustibles (01/80 a 12/92)



En el Gráfico 16 de medias y medianas mensuales se observa una estacionalidad creciente desde febrero hasta julio y decreciente a partir de este mes.

Gráfico 16 - Combustibles - Medias y medianas mensuales



Los tests provistos por el programa X11-ARIMA indican que no hay estacionalidad identificable en la serie, es decir que si bien puede existir un comportamiento estacional, éste no puede ser estimado por el método dada la gran irregularidad presente en la serie. La siguiente tabla muestra los altos valores de la contribución relativa de la componente Irregular a la varianza de la serie original.

Lapso (meses)	Irregularidad	Tendencia	Estacionalidad
1	71.39	3.01	24.30
3	32.37	16.34	50.52

Como era de esperar se detecta un gran número de valores atípicos en esta serie.

- III.3.5. Importación de Vehículos.

Gráfico 17 - Vehículos (01/80 a 12/92)








Gráfico 18 - Vehículos - Medias y medianas mensuales



En el gráfico de la serie (Gráfico 17) se observa que, luego de un período inicial de dos años, la serie baja a valores muy pequeños, inclusive con valores nulos. A partir de comienzos de 1991 se inicia un brusco crecimiento con un pico en julio de 1992.

En el Gráfico 18 de medias y medianas mensuales no aparece un comportamiento estacional significativo, salvo un ligero cambio de nivel en el segundo semestre del año.

Los tests provistos por el programa X11-ARIMA confirman la no presencia de estacionalidad en la serie. La siguiente tabla muestra nuevamente los altos valores de la contribución relativa de la componente Irregular a la varianza de la serie original.

Lapso (meses)	Irregularidad	Tendencia	Estacionalidad
1	71.31	18.33	7.02
3	36.47	58.13	4.38

- III.3.5. Importación de Piezas.

Gráfico 19 - Piezas (01/80 a 12/92)








Gráfico 20 - Piezas - Medias y medianas mensuales



En el Gráfico 20 de medias y medianas mensuales no se aprecia un comportamiento estacional significativo, lo cual es confirmado por los tests provistos por el programa X11-ARIMA. La aparente estacionalidad en el primer gráfico de medianas se debe a la escala del mismo y ya no aparece en el segundo gráfico. Las contribuciones de las componentes a la varianza de la serie original son:

Lapso (meses)	Irregularidad	Tendencia	Estacionalidad
1	65.91	4.94	29.15
3	44.78	26.92	28.30

III.4 Series de Exportaciones por grandes rubros. .

Al igual que en el caso de la serie de Importaciones, se comenzó el estudio analizando la serie Total de Exportaciones subdividida por los siguientes grandes rubros económicos:

- * **Productos Primarios**
- * **Manufacturas de Origen Agropecuario (MOA)**
- * **Manufacturas de Origen Industrial (MOI)**
- * **Combustibles y Energía**

Como se mencionó en el párrafo III.3. el análisis que se realiza es menos detallado que para el Total y el período de estudio finaliza en diciembre de 1992, por no contarse con datos más actualizados definitivos.

Para determinar el comportamiento de cada uno de los rubros con respecto al Total, se realiza un análisis de regresión obteniéndose los siguientes valores de R^2 :

Variable explicativa	R^2
Productos primarios	0.339
MOA	0.673
MOI	0.426
Combustibles y Energía	0.256

Si bien se trata de un análisis parcial, dado que no se cumplen los supuestos básicos de la regresión, se observa que Exportaciones de Manufacturas de Origen Agropecuario (MOA) es la que mayor porcentaje explica de la variabilidad de la serie Total de Exportaciones, seguida por Manufacturas de Origen Industrial (MOI), luego por Productos Primarios y por último, Combustibles y energía.

- III.4.1. Exportación de Productos Primarios.

Gráfico 21 - Productos Primarios (01/80 a 12/92)








Gráfico 22 - Productos Primarios - Medias y medianas mensuales



En el Gráfico 22 de medias y medianas mensuales se observa un claro comportamiento estacional, reflejado también en el gráfico de la serie. Este comportamiento estacional es creciente desde noviembre hasta julio y decreciente a partir de allí.

Los tests de estacionalidad provistos por el programa X11-ARIMA detectan estacionalidad identificable en la serie ya que la estacionalidad estable es significativa y no lo es la móvil.

Es muy fuerte la contribución relativa de la componente estacional a la varianza de la serie:

Lapso (meses)	Irregularidad	Tendencia	Estacionalidad
1	36.29	3.09	60.50
3	20.30	4.50	75.30

Mediante el programa ESTIN de estimación robusta se detectan varios valores extremos, siendo los más significativos los outliers aditivos correspondientes a los meses de marzo de 1990, julio de 1991 y enero de 1990 y un cambio de nivel en julio de 1985.

- El modelo del tipo denominado con intervención, considerado como el más apropiado para el ajuste de la serie es:

$$Z_t = \frac{(1 - \theta_2 B^2)(1 - \Theta_{12} B^{12})}{(1 - \phi_1 B)(1 - B^{12})} a_t + \gamma_0 Y_t$$

donde la variable Y_t se define en forma similar a la descripta anteriormente.

La estimación de este modelo mediante el procedimiento ARIMA de SAS produce los siguientes resultados:

Parámetro	Estimador	Error std aprox.	Razón T
θ_2	-0.32883	0.08338	-3.94
Θ_{12}	0.83485	0.08420	9.92
ϕ_1	0.73627	0.06073	12.12
γ_0	67181.8	10453.2	6.43

Varianza estimada = 2393335540

Error standard estimado = 48921.7287

El test de Ljung y Box para testear autocorrelación en los residuales produce los siguientes valores p:

Hasta lag	Chi cuadrado	Grados de libertad	Probabilidad
6	2.28	3	0.517
12	10.48	9	0.313
18	21.68	15	0.117
24	23.83	21	0.301

El error de previsión medio para el último año es de 19.6%.

El modelo de regresión con errores ARIMA seleccionado para esta serie es el siguiente:

$$Z_t = \beta_1 OA8203 + \beta_2 CN8507 + \beta_3 OA8705 + \beta_4 OA8807 + \beta_5 OA9001 \\ + \beta_6 OA9003 + \beta_7 OA9107 + \epsilon_t$$

$$(1 - B^{12})(1 - \phi_1 B - \phi_2 B^2)\epsilon_t = (1 - \Theta_{12} B^{12})a_t$$

La estimación de los coeficientes de este modelo utilizando el procedimiento ARIMA de SAS, arroja los siguientes resultados:

Parámetro	Estimador	Error std aprox.	Razón T
ϕ_1	1.10700	0.08378	13.92
ϕ_2	-0.38445	0.07975	-4.84
Θ_{12}	0.70340	0.07951	8.40
OA8203	-86128.9	27039.1	-3.19
CN8507	-119427.3	27599.6	-4.33
OA8705	-83887.4	26791.9	-3.13
OA8807	-73803.2	26908.2	-2.74
OA9001	104226.0	27549.8	3.78
OA9003	125639.7	27532.9	4.56
OA9107	122664.9	27702.4	4.43

Varianza estimada = 2083204787

Error standard estimado = 45642.1383

El test de Ljung y Box para testear autocorrelación en los residuales produce los siguientes valores p:

Hasta lag	Chi cuadrado	Grados de libertad	Probabilidad
6	2.27	3	0.519
12	6.01	9	0.739
18	19.05	15	0.212
24	21.08	21	0.454

El error de previsión absoluto promedio del último año es 8.0 %.

- III.4.2. Exportación de Manufacturas de Origen Agropecuario.

Gráfico 23 - Manufacturas de Origen Agropecuario (01/80 a 12/92)








Gráfico 24 - MOA - Medias y medianas mensuales



Esta serie (Gráfico 23) se mantiene en el mismo nivel desde el comienzo del período en estudio hasta comienzos de 1988 donde comienza un crecimiento que se estabiliza a fines del mismo año, ubicándose en un nuevo nivel que mantiene hasta finalizar el período en estudio.

En los gráficos de medias y medianas mensuales (Gráfico 24) se observa una cierta estacionalidad con un pico en el mes de julio, más evidente en el gráfico de medianas.

Los tests provistos por el X11-ARIMA indican que probablemente no hay estacionalidad identificable en la serie.

Es muy fuerte la contribución relativa de la componente Irregular a la varianza total.

Lapso (meses)	Irregularidad	Tendencia	Estacionalidad
1	65.79	3.24	30.96
3	43.77	14.83	41.39

Mediante el programa ESTIN de estimación robusta se detectan varios valores extremos, siendo los más significativos el cambio de nivel en el mes de mayo de 1988 y dos outliers aditivos correspondientes a los meses de agosto de 1988 y diciembre de 1989.

El modelo del tipo denominado con intervención, considerado como el más apropiado para el ajuste de la serie es:

$$Z_t = \frac{(1 - \theta_1 B)(1 - \Theta_{12} B^{12})}{(1 - \phi_1 B)(1 - B^{12})} a_t + \gamma_0 Y_t$$

donde la variable Y_t se define en forma similar a los modelos anteriores.

La estimación de este modelo mediante el procedimiento ARIMA de SAS produce los siguientes resultados:

Parámetro	Estimador	Error std aprox.	Razón T
θ_1	0.38739	0.08598	4.51
θ_{12}	0.73270	0.08053	9.10
ϕ_1	0.95548	0.02915	32.78
γ_0	120375.1	12204.1	9.86

Varianza estimada = 1173010066

Error standard estimado = 34249.2345

El test de Ljung y Box para testear autocorrelación en los residuales produce los siguientes valores p:

Hasta lag	Chi cuadrado	Grados de libertad	Probabilidad
6	3.04	3	0.386
12	8.74	9	0.462
18	13.80	15	0.541
24	19.34	21	0.564

El error de previsión promedio del último año es de 5.8 %.

El modelo de regresión con errores ARIMA seleccionado para esta serie es el siguiente:

$$Z_t = \beta_1 OA8706 + \beta_2 CN8805 + \beta_3 OA8808 + \beta_4 OA8810 + \beta_5 OA8912 + \beta_6 OA9109 + \epsilon_t$$

$$(1 - B^{12})(1 - \phi_1 B)\epsilon_t = (1 - \Theta_{12} B^{12})a_t$$

La estimación de los coeficientes de este modelo utilizando el procedimiento ARIMA de SAS, arroja los siguientes resultados:

Parámetro	Estimador	Error std aprox.	Razón T
ϕ_1	0.54320	0.07046	7.71
Θ_{12}	0.78219	0.08943	8.75
OA8706	93601.8	26861.6	3.48
CN8805	139464.8	12901.4	10.81
OA8808	133501.4	26927.4	4.96
OA8810	-90251.1	26938.3	-3.35
OA8912	-120752.9	27171.9	-4.44
OA9109	91865.4	28023.6	3.28

Varianza estimada = 1115362981

Error standard estimado = 33397.0505

El test de Ljung y Box para testear autocorrelación en los residuales produce los siguientes valores p:

Hasta lag	Chi cuadrado	Grados de libertad	Probabilidad
6	3.14	4	0.535
12	13.39	10	0.203
18	16.32	16	0.431
24	19.08	22	0.640

El error de previsión absoluto promedio del último año es 8.5 %.

- III.4.3. Exportación de Manufacturas de Origen Industrial.

Gráfico 25 - Manufacturas de Origen Industrial (01/80 a 12/92)





Gráfico 26 - MOI - Medias y medianas mensuales



Los gráficos de medias y medianas mensuales (Gráfico 26) muestran escasa estacionalidad en la serie, y el método X11-ARIMA indica que no hay estacionalidad identificable.

La contribución relativa de la componente Irregular a la varianza de la serie es muy grande, predominando ampliamente sobre las otras componentes.

Lapso (meses)	Irregularidad	Tendencia	Estacionalidad
1	72.90	0.90	26.30
3	55.60	5.40	38.90

Mediante el programa ESTIN de estimación robusta se detectan varios valores extremos, siendo los más significativos dos outliers aditivos en los meses de diciembre de 1988 y marzo de 1990 y dos cambios de nivel en los meses de mayo de 1982 y noviembre de 1989.

El modelo del tipo denominado con intervención, considerado como el más apropiado para el ajuste de la serie es:

$$Z_t = \frac{(1 - \theta_1 B)}{(1 - \phi_1 B - \phi_2 B^2)(1 - \Phi_{12} B^{12})(1 - B^{12})} a_t + \gamma_0 Y_t$$

donde la variable Y_t se define como en los modelos anteriores.

La estimación de este modelo mediante el procedimiento ARIMA de SAS produce los siguientes resultados:

Parámetro	Estimador	Error std aprox.	Razón T
θ_1	0.68454	0.14671	4.67
ϕ_1	1.24146	0.18266	6.80
ϕ_2	-0.26650	0.16826	-1.58
Φ_{12}	-0.61866	0.06723	-9.20
γ_0	83963.0	6682.3	12.56

Varianza estimada = 761812573

Error standard estimado = 27600.9524

El test de Ljung y Box para testear autocorrelación en los residuales produce los siguientes valores p:

Hasta lag	Chi cuadrado	Grados de libertad	Probabilidad
6	1.38	2	0.501
12	7.39	8	0.495
18	12.09	14	0.599
24	18.80	20	0.535

El error de previsión promedio para el último año es 9.3%.

El modelo de regresión con errores ARIMA seleccionado para esta serie es el siguiente:

$$Z_t = \beta_1 CN8205 + \beta_2 OA8812 + \beta_3 CN8911 + \beta_4 OA9003 + \beta_5 CN9101 + \beta_6 CN9201 + \epsilon_t$$

$$(1 - B)(1 - B^{12})(1 - \phi_1 B)\epsilon_t = (1 - \theta_1 B)(1 - \Theta_{12} B^{12})a_t$$

La estimación de los coeficientes de este modelo utilizando el procedimiento ARIMA de SAS, arroja los siguientes resultados:

Parámetro	Estimador	Error std aprox.	Razón T
ϕ_1	-0.37115	0.11156	-3.33
θ_1	0.48342	0.11387	4.25
Θ_{12}	0.85205	0.09476	8.99
CN8205	-97479.9	18303.8	-5.33
OA8812	188666.8	21823.7	8.65
CN8911	-85385.4	17630.3	-4.84
OA9003	90178.9	21784.5	4.14
CN9101	-99422.6	18149.3	-5.48
CN9201	-66798.4	18203.7	-3.67

Varianza estimada = 681852882

Error standard estimado = 26112.3129

El test de Ljung y Box para testear autocorrelación en los residuales produce los siguientes valores p:

Hasta lag	Chi cuadrado	Grados de libertad	Probabilidad
6	6.44	3	0.092
12	17.04	9	0.048
18	21.94	15	0.109
24	23.66	21	0.310

El error de previsión absoluto promedio del último año es 8.4 %.

- III.4.4. Exportación de Combustible y Energía.

Gráfico 27 - Combustibles y Energía (01/80 a 12/92)








Gráfico 28 - Combustibles y Energía - Medias y medianas mensuales



Se observa una gran irregularidad en el gráfico de la serie y escasa estacionalidad en los gráficos de medias y medianas (Gráfico 28).

Se procesó la serie utilizando el programa X11-ARIMA confirmandose lo ya observado gráficamente, ya que no se detecta estacionalidad identificable. La relación entre las componentes muestra que la contribución de la componente irregular a la varianza de la serie representa más del 240 % de la contribución de la componente estacional a retardo 1 y sigue superándola a retardo 3.

Lapso (meses)	Irregularidad	Tendencia	Estacionalidad
1	71.24	6.90	21.86
3	39.63	26.93	33.44

IV. CONSIDERACIONES FINALES

Los modelos obtenidos para las series Importaciones y Exportaciones Totales pueden considerarse adecuados para propósitos predictivos dentro de los márgenes admisibles de error fijados en este estudio. Respecto a los modelos obtenidos para algunas componentes, tanto de Importaciones como de Exportaciones, en algunos casos podrían considerarse adecuados ~~para~~, en general, se observa que no sería posible obtener pronósticos para el Total a partir de la modelación de las componentes.

Dada la mejoría obtenida al utilizar pronósticos combinados, desde el punto de vista de la disminución de la varianza de los errores de predicción, se considera de interés explorar la posibilidad de incluir otros modelos alternativos en la combinación.

Cabe recordar que los modelos aquí presentados son dinámicos y pueden sufrir variaciones a medida que se incorporen nuevos datos, por lo que los coeficientes estimados y las previsiones de los modelos son valores que representan exclusivamente el período en estudio.

REFERENCIAS

- Akaike, H. (1974) *A new look at the statistical model identification*. IEEE Transactions on Automatic Control, AC-19, 716-723.
- Bates, J.M. y Granger, W.J. (1969) *The combination of forecasts*. Oper. Res. Q. 20, 451-468.
- Box, G y Jenkins, G. (1976) *Time series analysis. Forecasting and control*. Holden-Day.
- Box G. y Tiao G. (1975) *Intervention analysis with applications to economic and environmental problems*. Journal of the American Statistical Association, 70, 70-79.
- Dagum, E.B. (1988) *The X11 ARIMA seasonal adjustment method - Foundations and user's manual*. Statistics Canada.
- Dagum E.B., Lothian J. y Morry, M. (1975) *A test of independence of the residuals based on the cumulative periodogram*. Statistics Canada.
- Granger C. y Newbold P. (1977) *Forecasting economic time series*. Academic Press.
- Granger C. y Ramanathan R. (1984) *Improved methods of combining forecasts*. Journal of Forecasting, Vol. 3, 197-194.
- INDEC. (1991) *Comercio Exterior Argentino - Resumen Estadístico - 1984/1989*.
- Ljung G.M. y Box G.E.P. (1978) *On a measure of lack of fit in time series models*. Biometrika, 65, 297-303.
- Lothian, J. y Morry, M. (1978) *A set of quality control statistics for the X11-ARIMA seasonal adjustment method*. Statistics Canada.
- Makridakis S., Andersen A., Carbone R., Fildes R., Hibon M., Lewandowski R., Newton J., Parzen E. y Winkler R. (1982) *The accuracy of extrapolation (time series) methods: results of a forecasting competition*. Journal of forecasting, 1, 111-153.
- Martínez E. y Yohai, V. (1989) *Identificación, estimación y predicción robusta en modelos ARIMA*, INDEC.

- Newbold P. y Granger C. (1974) *Experience with forecasting univariate time series and the combination of forecasts*. J. R. Statist. Soc. A, 137, 131-164.
- Pierce D. A. (1971) *Least squares estimation in the regression model with autoregressive-moving average errors*. Biometrika, 58, 299-312.
- Schwartz, G. (1978) *Estimating the dimension of a model*. Annals of Statistics, 6, 461-464.
- Shiskin, J., Young, A.H. y Musgrave, J.C. (1967) *The X11 variant of Census Method II seasonal adjustment*. Technical paper 15, Bureau of the Census, U.S. Department of Commerce.
- Winkler R. y Makridakis S. (1983) *The combination of forecasts*. J. R. Statist. Soc. A, 146, 150-157.

Tabla 1 - Pronósticos combinados - Métodos y parámetros considerados.

Número	Método	v	α	W
1	1	3		
2	1	6		
3	1	9		
4	1	12		
5	1	n-3		
6	2	3		
7	2	6		
8	2	9		
9	2	12		
10	2	n-3		
11	3	3	0.25	
12	3	6	0.25	
13	3	9	0.25	
14	3	12	0.25	
15	3	n-3	0.25	
16	3	3	0.50	
17	3	6	0.50	
18	3	9	0.50	
19	3	12	0.50	
20	3	n-3	0.50	

Tabla 1 - Continuación.

Número	Método	v	α	W
21	3	3	0.75	
22	3	6	0.75	
23	3	9	0.75	
24	3	12	0.75	
25	3	n-3	0.75	
26	4			0.5
27	4			0.66
28	4			0.8
29	4			0.9
30	4			1.0
31	5			0.5
32	5			0.66
33	5			0.8
34	5			0.9
35	5			1.0

Tabla 2 - Importaciones. Porcentaje de casos en que la varianza del pronóstico combinado es inferior a las varianzas de los pronósticos componentes.

Método	1 paso	2 pasos	3 pasos
1	0.0	14.2	7.1
2	14.3	28.6	35.7
3	21.4	35.7	57.1
4	28.6	42.9	64.3
5	100.0	92.9	100.0
6	42.9	71.4	50.0
7	57.1	71.4	42.9
8	35.7	78.6	50.0
9	35.7	78.6	42.9
10	100.0	78.6	50.0
11	42.9	64.3	42.9
12	57.1	57.1	42.9
13	35.7	71.4	50.0
14	35.7	78.6	50.0
15	100.0	57.1	50.0
16	50.0	64.3	50.0
17	57.1	50.0	42.9
18	35.7	71.4	50.0
19	35.7	78.6	57.1
20	100.0	50.0	42.9

Tabla 2 - Continuación.

Método	1 paso	2 pasos	3 pasos
21	50.0	57.1	57.1
22	57.1	50.0	50.0
23	35.7	71.4	50.0
24	42.9	78.6	64.3
25	100.0	21.4	42.9
26	28.6	71.4	78.6
27	35.7	85.7	92.9
28	50.0	100.0	100.0
29	71.4	100.0	100.0
30	100.0	100.0	100.0
31	50.0	100.0	100.0
32	57.1	100.0	100.0
33	57.1	100.0	100.0
34	78.6	100.0	100.0
35	100.0	100.0	100.0

Tabla 3 - Importaciones. Estadísticos de los errores relativos de pronóstico a 1, 2 y 3 pasos.

Método	SC(1)	SC(2)	SC(3)	PER(1)	PER(2)	PER(3)
1	0.07	0.17	0.29	0.06	0.09	0.11
2	0.09	0.12	0.18	0.06	0.08	0.08
3	0.08	0.12	0.28	0.06	0.08	0.10
4	0.06	0.11	0.21	0.05	0.08	0.09
5	0.07	0.12	0.20	0.06	0.08	0.09
6	0.07	0.13	0.28	0.06	0.07	0.11
7	0.07	0.11	0.23	0.06	0.07	0.08
8	0.07	0.12	0.24	0.05	0.08	0.09
9	0.06	0.12	0.24	0.05	0.08	0.09
10	0.06	0.12	0.23	0.05	0.07	0.08
11	0.07	0.12	0.26	0.06	0.07	0.10
12	0.07	0.12	0.23	0.06	0.08	0.08
13	0.07	0.13	0.24	0.05	0.08	0.09
14	0.06	0.12	0.24	0.05	0.08	0.09
15	0.06	0.12	0.23	0.05	0.07	0.08
16	0.06	0.11	0.24	0.06	0.08	0.09
17	0.07	0.13	0.24	0.06	0.08	0.08
18	0.07	0.13	0.24	0.05	0.08	0.08
19	0.06	0.12	0.23	0.05	0.08	0.08
20	0.06	0.13	0.24	0.05	0.08	0.09

Tabla 3 - Continuación.

Método	SC(1)	SC(2)	SC(3)	PER(1)	PER(2)	PER(3)
21	0.06	0.12	0.22	0.06	0.08	0.08
22	0.07	0.13	0.25	0.06	0.08	0.09
23	0.07	0.13	0.24	0.05	0.08	0.08
24	0.06	0.12	0.23	0.05	0.08	0.08
25	0.06	0.13	0.26	0.06	0.08	0.09
26	0.07	0.13	0.30	0.06	0.08	0.11
27	0.07	0.12	0.19	0.06	0.08	0.08
28	0.07	0.13	0.18	0.06	0.08	0.08
29	0.06	0.12	0.20	0.05	0.08	0.08
30	0.07	0.12	0.20	0.06	0.08	0.09
31	0.07	0.12	0.26	0.06	0.07	0.10
32	0.07	0.12	0.24	0.06	0.07	0.09
33	0.06	0.12	0.24	0.05	0.07	0.08
34	0.06	0.12	0.24	0.05	0.08	0.08
35	0.06	0.12	0.23	0.05	0.07	0.08

