



ESCUELA SUPERIOR POLITECNICA DEL LITORAL

Instituto de Ciencias Matemáticas

Ingeniería en Estadística Informática

**"Desestacionalización de Series Económicas de las Cuentas Nacionales del
Ecuador con X12-ARIMA"**

TESIS DE GRADO

Previa a la obtención del Título de:

INGENIERA EN ESTADISTICA INFORMATICA

Presentada por:

Vanessa Viviana Vásquez Villón

GUAYAQUIL – ECUADOR

AÑO

2004

AGRADECIMIENTO

A Dios, por ser el punto de partida, el motor que impulsa mi vida y a quien le debo todo cuanto soy; a mi familia, quienes me han apoyado en todo momento, lugar y en la forma en la que lo he necesitado; a todas aquellas personas que de una u otra forma han contribuido a mi crecimiento personal y profesional.

TRIBUNAL DE GRADUACION


DEDICATORIA


Ing. Washington Armas

DIRECTOR DEL ICM


Ing. Juan Ramirez Figueroa

VICEDIRECTOR


A todas aquellas personas
que no se dejan vencer por
los obstáculos que se
presentan en la vida. Pero
sobre todo para aquellas
personas que creen en el
Dios Grande y
Todopoderoso

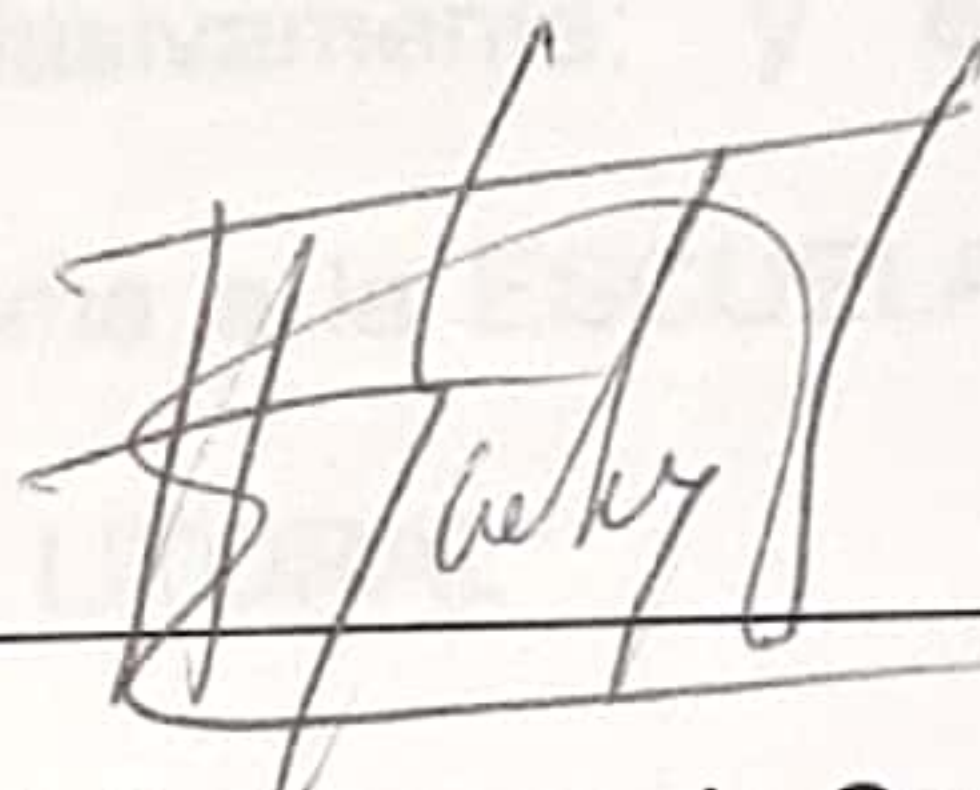


TRIBUNAL DE GRADUACION



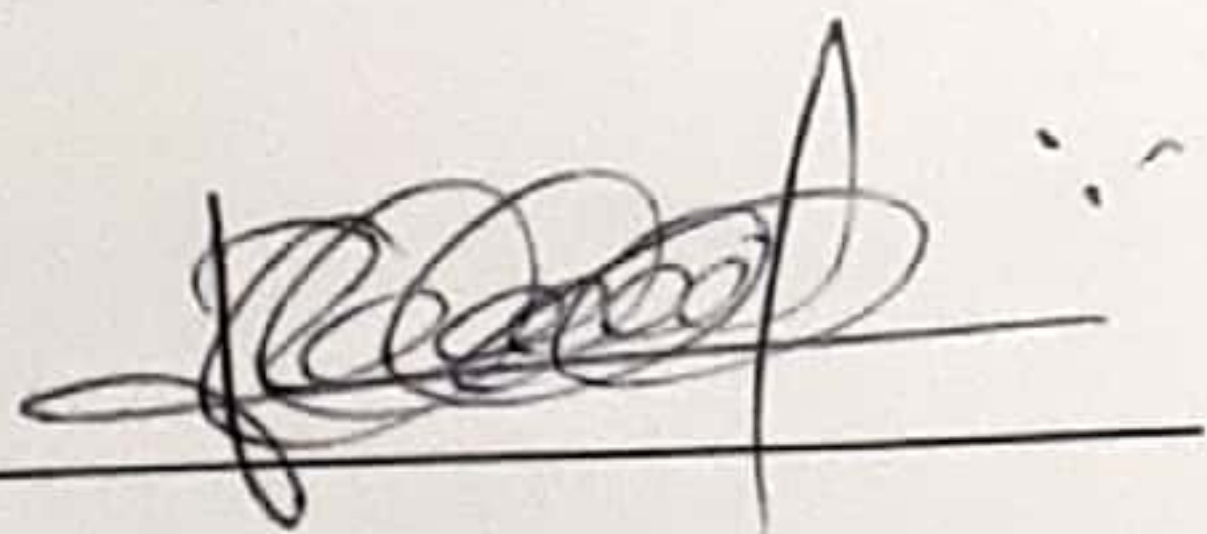
Ing. Washington Armas

DIRECTOR DEL ICM



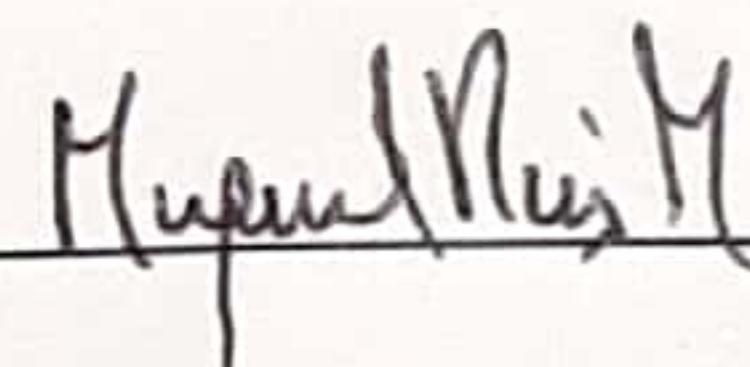
M.Sc. Fernando Sandoya S.

DIRECTOR DE TESIS



Mat. John Ramírez Figueroa

VOCAL



Econ. Miguel Ruiz Martínez

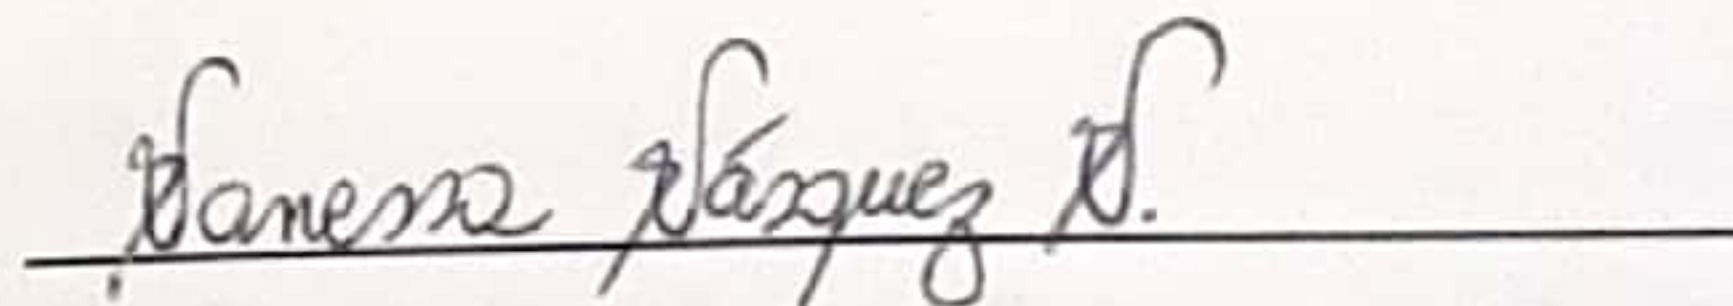
VOCAL



DECLARACION EXPRESA

"La responsabilidad del contenido de esta tesis de grado, me corresponde exclusivamente; y el patrimonio intelectual de la misma a la ESCUELA SUPERIOR POLITECNICA DEL LITORAL"

(Reglamento de graduación de la ESPOL)



Vanessa Viviana Vásquez Villón

RESUMEN

En este trabajo se tiene como objetivo principal lograr la desestacionalización de las series económicas de las Cuentas Nacionales del Ecuador, con la ayuda del modelo de extracción de señales X12-ARIMA y el apoyo del software DEMETRA 2.0 desarrollado por EUROSTAT (Oficina de Estadística de la Unión Europea).

En esencia la desestacionalización se refiere a la eliminación de las componentes estacional y de efecto calendario (variaciones por días laborables y feriados de fecha móvil) de una serie de tiempo, esto con el propósito de conseguir una señal de tendencia más clara de las series y por tanto entender mejor la situación presente y ajustar los pronósticos.

Para lograr este objetivo es necesario que el analista económico este familiarizado con los conceptos básicos en torno a las series temporales, y por ello, en el capítulo uno se exponen las principales y esenciales nociones referentes al estudio de las series de tiempo y los procesos estocásticos.

En el capítulo dos se explican los aspectos conceptuales sobre extracción de señales de una serie de tiempo, esto involucra conocer sus componentes (Tendencia, Ciclo, Estacionalidad, Irregularidad y Efecto Calendario) y los principales modelos de desestacionalización (Métodos basados en promedios móviles y Métodos basados en Modelos).

Como en el análisis de las series de las Cuentas Nacionales del Ecuador se aplica el método X12-ARIMA, en el capítulo tres se da una explicación amplia de la forma en que procesa los datos este modelo de extracción de señales. Se indican sus ventajas y desventajas en comparación con los demás métodos existentes.

Finalmente en el capítulo cuatro se muestran los resultados obtenidos del procesamiento de las series económicas, con la explicación del módulo automático realizado en el software DEMETRA cuya principal ventaja es el análisis masivo de las series de tiempo económicas.


Al llegar a este punto de la investigación el lector se podrá percatar de la real importancia del ajuste estacional de las series económicas y el por que del desarrollo del presente trabajo, el país y las empresas necesitan información confiable y oportuna para la interpretación de los fenómenos económicos y la toma de decisiones. En este sentido es importante eliminar el ruido presente

en los indicadores, que podría provocar una interpretación incorrecta y por consiguiente implicar la toma de una decisión equivocada.

	Pag.
RESUMEN	I
INDICE GENERAL	IV
ABREVIATURAS	II
SIMBOLOGIA	XII
INDICE DE GRAFICOS	XVI
INDICE DE TABLAS	XIX
INTRODUCCION	1


CAPTULO 1

1. SERIES DE TIEMPO	3
1.1. Introducción	3
1.2. Series Temporales	4
1.2.1. Tipos de Datos	6
1.2.1.1. Series Transitorias	6
1.2.1.2. Series Temporales	7
1.2.1.3. Datos de Panel	8
1.2.2. Medicion de las Series Temporales	9
1.2.2.1. Series en Niveles	9
1.2.2.1.1. Variable de Flujo	9
1.2.2.1.2. Variable Acumulada o de "Stock"	10
1.2.2.1.3. Saldo	12
1.2.2.1.4. Ratio	13



INDICE GENERAL

	Pág.
RESUMEN.....	I
INDICE GENERAL.....	IV
ABREVIATURAS.....	X
SIMBOLOGIA.....	XII
INDICE DE GRAFICOS.....	XVI
INDICE DE TABLAS.....	XIX
INTRODUCCION.....	1
CAPITULO 1	
1. SERIES DE TIEMPO.....	3
1.1. Introducción.....	3
1.2. Series Temporales.....	4
1.2.1. Tipos de Datos y Frecuencia.....	6
1.2.1.1. Series Transversales.....	6
1.2.1.2. Series Temporales.....	7
1.2.1.3. Datos de Panel.....	8
1.2.2. Medición de las Series Temporales.....	9
1.2.2.1. Series en Niveles.....	9
1.2.2.1.1 Variable de Flujo.....	9
1.2.2.1.2 Variable Acumulada o de "Stock".....	10
1.2.2.1.3 Saldo.....	12
1.2.2.1.4 Ratio.....	13



1.2.2.2	Series medidas con Números Índices.....	13
1.2.2.3	Series medidas en Tasas de Crecimiento.....	14
1.2.3	Técnicas y Métodos de Previsión.....	16
1.2.3.1	Métodos Cualitativos.....	17
1.2.3.2	Métodos Cuantitativos.....	18
1.2.3.2.1	Métodos Multivariantes.....	19
1.2.3.2.2	Métodos Univariantes.....	22
1.3.	Procesos Estocásticos.....	26
1.3.1.	Caracterización.....	27
1.3.2.	Las Series Temporales desde el Contexto de los Procesos Estocásticos.....	29
1.3.3.	Procesos Estacionarios y Ergódicos.....	31
1.3.3.1.	Procesos Estacionarios.....	31
1.3.3.2.	Procesos Ergódicos.....	34
1.3.4.	Procesos Lineales.....	35
1.3.4.1.	Ruido Blanco.....	35
1.3.4.2.	Proceso Autorregresivo AR(p).....	36
1.3.4.2.1.	Características del Proceso AR(p).....	37
1.3.4.3.	Proceso de Medias Móviles MA(q).....	40
1.3.4.3.1.	Características del Proceso MA(q).....	42
1.3.4.4.	Proceso Mixto ARMA(p,q).....	44
1.3.4.4.1.	Características del Proceso ARMA(p,q).....	45

1.3.5. Procesos No Estacionarios.....	49
1.3.5.1. Modelos ARIMA.....	51
1.3.5.2. Proceso ARIMA.....	54
1.3.5.2.1. Identificación.....	56
1.3.5.2.2. Estimación.....	57
1.3.5.2.3. Verificación.....	58
1.3.5.2.4. Predicción.....	59
1.3.6. Funciones de Autocorrelación y Autocorrelación Parcial:	
Teórica y Estimada.....	59
1.3.6.1. Función de Autocorrelación Estimada.....	60
1.3.6.2. Función de Autocorrelación Parcial Teórica y	
Estimada.....	64
1.3.7. Modelos Estacionales SARIMA.....	70

CAPITULO 3

3. EL MÉTODO X12 - ARIMA.....	123
-------------------------------	-----

CAPITULO 2

2. MODELOS BASADOS EN LA EXTRACCIÓN DE LA SEÑAL.....	72
2.1. Introducción.....	72
2.2. Análisis de Intervención.....	74
2.3. Componentes de una Serie de Tiempo.....	79
2.4. Modelos de Descomposición.....	88
2.5. Desestacionalización de Series de Tiempo.....	92

2.5.1. Métodos de Desestacionalización de Series.....	93
2.6. Métodos de Extracción de Señales.....	98
2.6.1. Medias Móviles.....	102
2.6.2. Familia de los Modelos X11.....	105
2.6.2.1. Modelo X11 (Census I y II)	106
2.6.2.2. Modelo X11-ARIMA.....	110
2.6.3. Incorporación de Modelos ARIMA al Proceso de Ajuste	110
Estacional.....	114
2.6.4. Selección del Modelo ARIMA.....	118
2.6.5. Método X12-ARIMA.....	120
CAPITULO 2.7. Elección de un Método.....	121
A. APLICACIÓN DEL MÉTODO X12-ARIMA AL TRATAMIENTO DE LAS SERIES ECONÓMICAS DE LAS CUENTAS NACIONALES DEL	154

CAPITULO 3

3. EL MÉTODO X12 – ARIMA.....	123
3.1. Introducción.....	123
3.2. La Extracción de Señales con X12-ARIMA	126
3.2.1. Modelos regARIMA	129
3.2.2. Modelización y Comparación de Modelos	135
3.2.2.1. Comparación de Diferentes Ajustes	
Transformaciones.....	138
3.2.3. El Ajuste Estacional.....	139



3.2.4. Diagnósticos.....	146
3.2.4.1. Análisis Espectral.....	147
3.2.4.2. Diagnósticos de Calidad del Ajuste Estacional.....	149
3.2.4.3. Diagnósticos de Estabilidad del Ajuste Estacional.....	150
3.2.4.3.1. Sliding Spans.....	150
3.2.4.3.2. Historia de Revisión.....	152

ANEXOS
BIBLIOGRAFIA
CAPITULO 4

4. APLICACIÓN DEL MÉTODO X12-ARIMA AL TRATAMIENTO DE LAS SERIES ECONOMICAS DE LAS CUENTAS NACIONALES DEL	154
4.1. Selección del Periodo de Análisis y las Series Económicas.....	155
4.2. Programa Computacional Utilizado.....	157
4.3. Tratamiento de las Series Económicas.....	159
4.3.1. Módulo Automático.....	159
4.4. Resultados Obtenidos.....	172
4.4.1. Resultados Series Rechazadas en el Ajuste Estacional.....	173

4.4.2. Resultados Series Aceptadas en el Ajuste

Estacional.....204

CAPITULO 5

5. CONCLUSIONES Y RECOMENDACIONES.....220

5.1. Conclusiones.....220

5.2. Recomendaciones.....223

**ANEXOS
BIBLIOGRAFIA**

AIC	Criterio de Akaike
AO	Additive Outliers, Alpicos Activos
	Autoregresivo
	Autoregresivo Integrado de Medias Móviles
ARMA	Mixto (Autoregresivo - Medias Móviles)
BCE	Banco Central del Ecuador
DOS	Disk Operating System, Sistema Operativo de Disco
EUROSTAT	Oficina de Estadística de la Unión Europea
FACE	Función de Autocorrelación Estimada
FACE	Función de Autocorrelación Parcial Estimada
FACE	Función de Autocorrelación Parcial Teórica
FACE	Función de Autocorrelación Teórica
LS	Level Shift, Cambios de Nivel
MA	Medias Móviles
PBI	Producto Interno Bruto
regARIMA	Regresión Lineal con errores ARIMA
SA	Ajuste Estacional
SARIMA	Autoregresivo Integrado de Medias Móviles Estacional

ABREVIATURAS

AIC	Criterio de Akaike
AO	Additive Outliers: Atípicos Aditivos
AR	Autorregresivo
ARIMA	Autorregresivo Integrado de Medias Móviles
ARMA	Mixto (Autorregresivo – Medias Móviles)
BCE	Banco Central del Ecuador
DOS	Disk Operating System: Sistema Operativo de Disco
EUROSTAT	Oficina de Estadística de la Unión Europea
FACE	Función de Autocorrelación Estimada
FACPE	Función de Autocorrelación Parcial Estimada
FACPT	Función de Autocorrelación Parcial Teórica
FACT	Función de Autocorrelación Teórica
LS	Level Shift: Cambios de Nivel
MA	Medias Móviles
PIB	Producto Interno Bruto
regARIMA	Regresión Lineal con errores ARIMA
SA	Ajuste Estacional
SARIMA	Autorregresivo Integrado de Medias Móviles Estacional

SEATS

Signal Extraction in ARIMA Time Series: Extracción de la Señal en Series de Tiempo ARIMA


STAMP

TRAMO

Time Series Regresión with ARIMA Noise, Missing Observations and Outliers: Regresión de Series de Tiempo con Ruido ARIMA, Observaciones Perdidas y Atípicos

TC


Transitory Change: Cambios Transitorios



SIMBOLOGIA


Y_t	Serie Temporal
D_t	Componente Determinista
N_t	Componente Aleatorio
$Y(t,u)$	Proceso estocástico; con tiempo t y variable aleatoria u
$Y(t_0,u)$	Variable aleatoria medida en el instante t_0
$Y(t,u_0)$	Valor del proceso estocástico para cada momento de tiempo
$F[Y(t_i)]$	Función de distribución de probabilidad de $Y(t)$
$F[Y(t_i), Y(t_j)]$	Distribución de probabilidad conjunta bivalente
(t_1, t_2, \dots, t_n)	Conjunto finito de valores del tiempo
$F[Y(t_i), Y(t_j), \dots, Y(t_n)]$	Función de distribución conjunta para un conjunto finito de variables del proceso estocástico
μ_t	Media del Proceso o momento de primer orden
$E[Y_t]$	Valor esperado de Y_t
$\text{Var}[Y_t]$ ó σ_t^2	Varianza de Y_t
$\gamma_{t,s}$ ó $\text{Cov}(Y_t, Y_s)$	Autocovarianza o Covarianza entre Y_t y Y_s

$\rho_{t,s}$	Coefficiente de autocorrelación
$\forall t$	Para todo valor de t
∞	Infinito
γ_k	Autocovarianza de orden k
γ_0	Varianza del proceso
ρ_k	Autocorrelación del proceso
$\hat{\mu}$	Estimador de la media
$\hat{\sigma}_0$	Estimador de la varianza
$\hat{\sigma}_k$	Estimador de la autocovarianza
ε_t	Ruido blanco
$\hat{\sigma}_\varepsilon^2$	Varianza Estimada del Ruido Blanco
AR(p)	Autorregresivo de orden p
$\phi(L)$	Operador polinomial de retardos en un modelo autorregresivo
δ	Término independiente
L	Operador de retardos
λ_i	Raíces de la ecuación característica
MA(q)	Medias móviles de orden q
$\theta(L)$	Operador polinomial de retardos en un modelo de medias móviles
θ_j	Coefficientes del modelo MA
ϕ_i	Coefficientes del modelo AR
ARMA(p,q)	Mixtos (Autorregresivos – Medias Móviles) de orden p y q
$\Psi(L)$	Operador de infinitos retardos en un modelo ARMA



$\pi(L)$	Operador Polinomial de invertibilidad en modelos ARMA
w_t	Proceso estacionario
ARIMA(p, d, q)	Proceso integrado Y_t que al tomar diferencias de orden d se obtiene un proceso estacionario w_t de la forma ARMA(p, q)
Δ	Operador de diferencias
$\ln Y_t$	Logaritmo Natural de Y_t
$\log Y_t$	Logaritmo de Y_t
$Y_t^{(\lambda)}$	Transformación instantánea logarítmica de Y_t de orden λ
\bar{w}	Media Estimada del Proceso Estacionario w_t
r_τ	coeficientes de autocorrelación muestral de orden τ
Var(r_τ)	Varianza coeficiente de autocorrelación muestral
$\hat{\theta}_j$	Coeficientes estimados del modelo MA
$\hat{\phi}_{ii}$	Coeficientes estimados del modelo AR
SARIMA(p, d, q)(P,D,Q)_s	Modelo ARIMA estacional: de orden p y q con diferencias de orden d en la parte no estacional, y orden P y Q con diferencias de orden D en la parte estacional
$\Theta_s(L)$	Operador polinomial de retardos en un modelo de medias móviles estacional
$\Phi_s(L)$	Operador polinomial de retardos en un modelo Autorregresivo estacional
T	Componente Tendencia

C	Componente Ciclo
C_t	Componente Tendencia-Ciclo
S_t	Componente Estacional
i_t	Componente Irregular
r_t	Componente de Días Laborales
h_t	Componente de Feriados Móviles
w	Frecuencia
Y_t^{des}	Serie Desestacionalizada
R₁	Indicador del grado de suavidad de la serie basado en el error cuadrático medio
R₂	Indicador del grado de suavidad de la serie basado en el Filtro de Henderson
m_i	Pesos de los filtros de promedios móviles
z_t	Serie filtrada por promedios móviles en el tiempo <i>t</i>
N(μ, σ²)	Distribución Normal con media μ y varianza σ ²
f_t(Y_t)	Transformación no lineal de la serie Y _t
d_t	Secuencia adecuada de divisores
X_t	Matriz de regresiones
w_t	Pesos para el componente irregular durante el ajuste estacional
M1 – M11	Estadísticos de Control de Calidad del Ajuste Estacional
Q1 y Q2	Medidas resumen de calidad del Ajuste Estacional
Q	Estadístico combinado (M1, M3-M11) para medir la calidad del Ajuste Estacional



INDICE DE GRAFICOS

	Pág.
GRAFICO 1.1	Métodos Cualitativos de Previsión.....18
GRAFICO 1.2	Métodos Cuantitativos de Previsión.....25
GRAFICO 1.3	Etapas de Elaboración de un Modelo ARIMA.....55
GRAFICO 1.4	Funciones de Autocorrelación FACE y FACPE.....69
GRAFICO 2.1	Variable Impulso.....76
GRAFICO 2.2	Variable Escalón.....76
GRAFICO 2.3	Variable Tendencia.....77
GRAFICO 3.1	Diagrama para el Ajuste Estacional con X12- ARIMA.....128
GRAFICO 4.1	Reglas para rechazar la calidad del Ajuste Estacional con X12-ARIMA162
GRAFICO 4.2	Proceso de SA con X12-ARIMA, Efecto Días Laborables.....171
GRAFICO 4.3	Serie Original y de Tendencia Final para I-x03.....184
GRAFICO 4.4	Serie Original y Serie Final Ajustada Estacionalmente de I-x03.....185
GRAFICO 4.5	Serie Original, Tendencia Final y Serie Final Ajustada

	Estacionalmente de I-x03.....	186
GRAFICO 4.6	Serie Original y Serie Final Ajustada Estacionalmente de I-m09.....	190
GRAFICO 4.7	Serie Original y de Tendencia Final para I-m09.....	192
GRAFICO 4.8	Serie Original, Tendencia Final y Serie Final Ajustada Estacionalmente de I-m09.....	192
GRAFICO 4.9	Serie Original y de Tendencia Final para I-x06.....	196
GRAFICO 4.10	Serie Original y Serie Final Ajustada Estacionalmente de I-x06.....	197
GRAFICO 4.11	Serie Original, Tendencia Final y Serie Final Ajustada Estacionalmente de I-x06.....	198
GRAFICO 4.12	Serie Original y Serie Final Ajustada Estacionalmente de I-m07.....	201
GRAFICO 4.13	Serie Original, Tendencia Final y Serie Final Ajustada Estacionalmente de I-m07.....	203
GRAFICO 4.14	Serie Original y de Tendencia Final para I-x01.....	210
GRAFICO 4.15	Serie Original y Serie Final Ajustada Estacionalmente de	



I-x01.....	211
GRAFICO 4.16 Serie Original, Tendencia Final y Serie Final Ajustada Estacionalmente de I-x01.....	211
GRAFICO 4.17 Serie Original y Serie Final Ajustada Estacionalmente de I-pr20.....	215
GRAFICO 4.18 Serie Original y de Tendencia Final para I-pr20.....	218
GRAFICO 4.19 Serie Original, Tendencia Final y Serie Final Ajustada Estacionalmente de I-pr20.....	218
TABLA 1	
TABLA 2	
TABLA 3	
TABLA 4	
TABLA 5	
TABLA 6	
TABLA 7	
TABLA 8	
TABLA 9	
TABLA 10	
TABLA 11	



INDICE DE TABLAS

	Pág.
TABLA 1 Importaciones Agrícolas Año 2002.....	10
TABLA 2 Ingresos Corrientes y de Capital, Gobierno Ecuatoriano Año 2003.....	11
TABLA 3 Exportaciones Ecuatorianas Año 2002.....	12
TABLA 4 Evolución del Desempleo en el Ecuador 1998 – 2002.....	14
TABLA 5 Resumen Funciones de Autocorrelación.....	68
TABLA 6 Pesos para Componente Irregular.....	143
TABLA 7 Resultados Tratamiento de Series con DEMETRA utilizando el Ajuste Estacional X12-ARIMA.....	173
TABLA 8 Información sobre el modelo para la serie de exportaciones I-x03.....	174
TABLA 9 Información de Diagnóstico de la serie de exportaciones I-x03 con X12-ARIMA.....	182
TABLA 10 Información sobre el modelo para la serie de importaciones I-m09.....	187
TABLA 11 Información de Diagnóstico de la serie de importaciones I-m09 con X12-ARIMA.....	190

INTRODUCCIÓN


TABLA 12	Información sobre el modelo para la serie de exportaciones I-x06.....	193
TABLA 13	Información de Diagnóstico de la serie de exportaciones I-x06 con X12-ARIMA.....	195
TABLA 14	Información sobre el modelo para la serie de importaciones I-m07.....	199
TABLA 15	Información de Diagnóstico de la serie de importaciones I-m07 con X12-ARIMA.....	202
TABLA 16	Información sobre el modelo para la serie de exportaciones I-x01.....	205
TABLA 17	Información de Diagnóstico de la serie de exportaciones I-x01 con X12-ARIMA.....	208
TABLA 18	Información sobre el modelo para la serie de manufactura I-pr20.....	212
TABLA 19	Información de Diagnóstico para la serie de manufactura I-pr20 con X12-ARIMA.....	216

INTRODUCCION

Las series de tiempo económicas analizadas en el presente trabajo son las Cuentas Nacionales del Ecuador, las cuales fueron proporcionadas por el Banco Central del Ecuador (BCE) con el fin de contribuir al cumplimiento de la principal responsabilidad que maneja este ente gubernamental.

El lograr eliminar de las series aquellos factores externos que causan ruido y no permiten establecer su real comportamiento a corto y a largo plazo, permite tener indicadores económicos que sirven de base para la recomendación y toma de decisiones de política económica. Esto es de vital importancia para el BCE dado que en el marco de las funciones que le otorga la legislación vigente debe producir una amplia gama de estadísticas, información y análisis económicos. EL BCE no realiza investigaciones de base, porque su responsabilidad principal es elaborar estadísticas de síntesis e indicadores específicos que de manera acertada y oportuna den cuenta de la marcha económica ecuatoriana.

En este aspecto, aplicar la metodología X12-ARIMA para desestacionalizar las series de Cuentas Nacionales del Ecuador es una opción acertada dado que este modelo basado en promedios móviles tiene como objetivo remover



o reducir la fuerza con que ciertos ciclos afectan a las series de datos, a través de la sucesiva aplicación de filtros hasta lograr una serie más suave.

En el desarrollo del presente trabajo el lector podrá conocer desde los conceptos principales en torno a las series de tiempo (importante para el entendimiento del proceso de descomposición de las series) hasta la aplicación de la metodología X2-ARIMA, pasando por la revisión general del resto de metodologías empleadas para el Ajuste Estacional.

1.1. Introducción

De esta manera se espera al finalizar contar con unas series económicas de Cuentas Nacionales del Ecuador depuradas en su gran mayoría. Donde se conoce como se realizó el proceso de descomposición y los principales resultados obtenidos con la aplicación del método X12-ARIMA utilizado en muchas oficinas de estadística a nivel mundial.

Mayores detalles en cuanto a series de tiempo, componentes de una serie, métodos de descomposición, aplicación de metodología X12-ARIMA y resultados obtenidos se podrán encontrar en el desarrollo de los capítulos que incluye el presente trabajo.

CAPITULO 1

1. SERIES DE TIEMPO

1.1. Introducción

Hoy en día tanto el gobierno como las empresas y las familias requieren conocer el comportamiento futuro de ciertos fenómenos con el fin de planificar sus actividades futuras. Pero esta previsión, generalmente, se basa en hechos ocurridos en el pasado. Así pues se tiene un nuevo tipo de inferencia estadística que se hace acerca del futuro de alguna variable o grupo de variables basándose en sucesos pasados. La técnica más importante para hacer inferencias sobre el futuro con base en lo ocurrido en el pasado, es el análisis de series de tiempo.

Son muchas las aplicaciones que se pueden citar, en distintas áreas del conocimiento, tales como: economía, física, geofísica, química, electricidad, demografía, marketing, telecomunicaciones, transporte, etc.



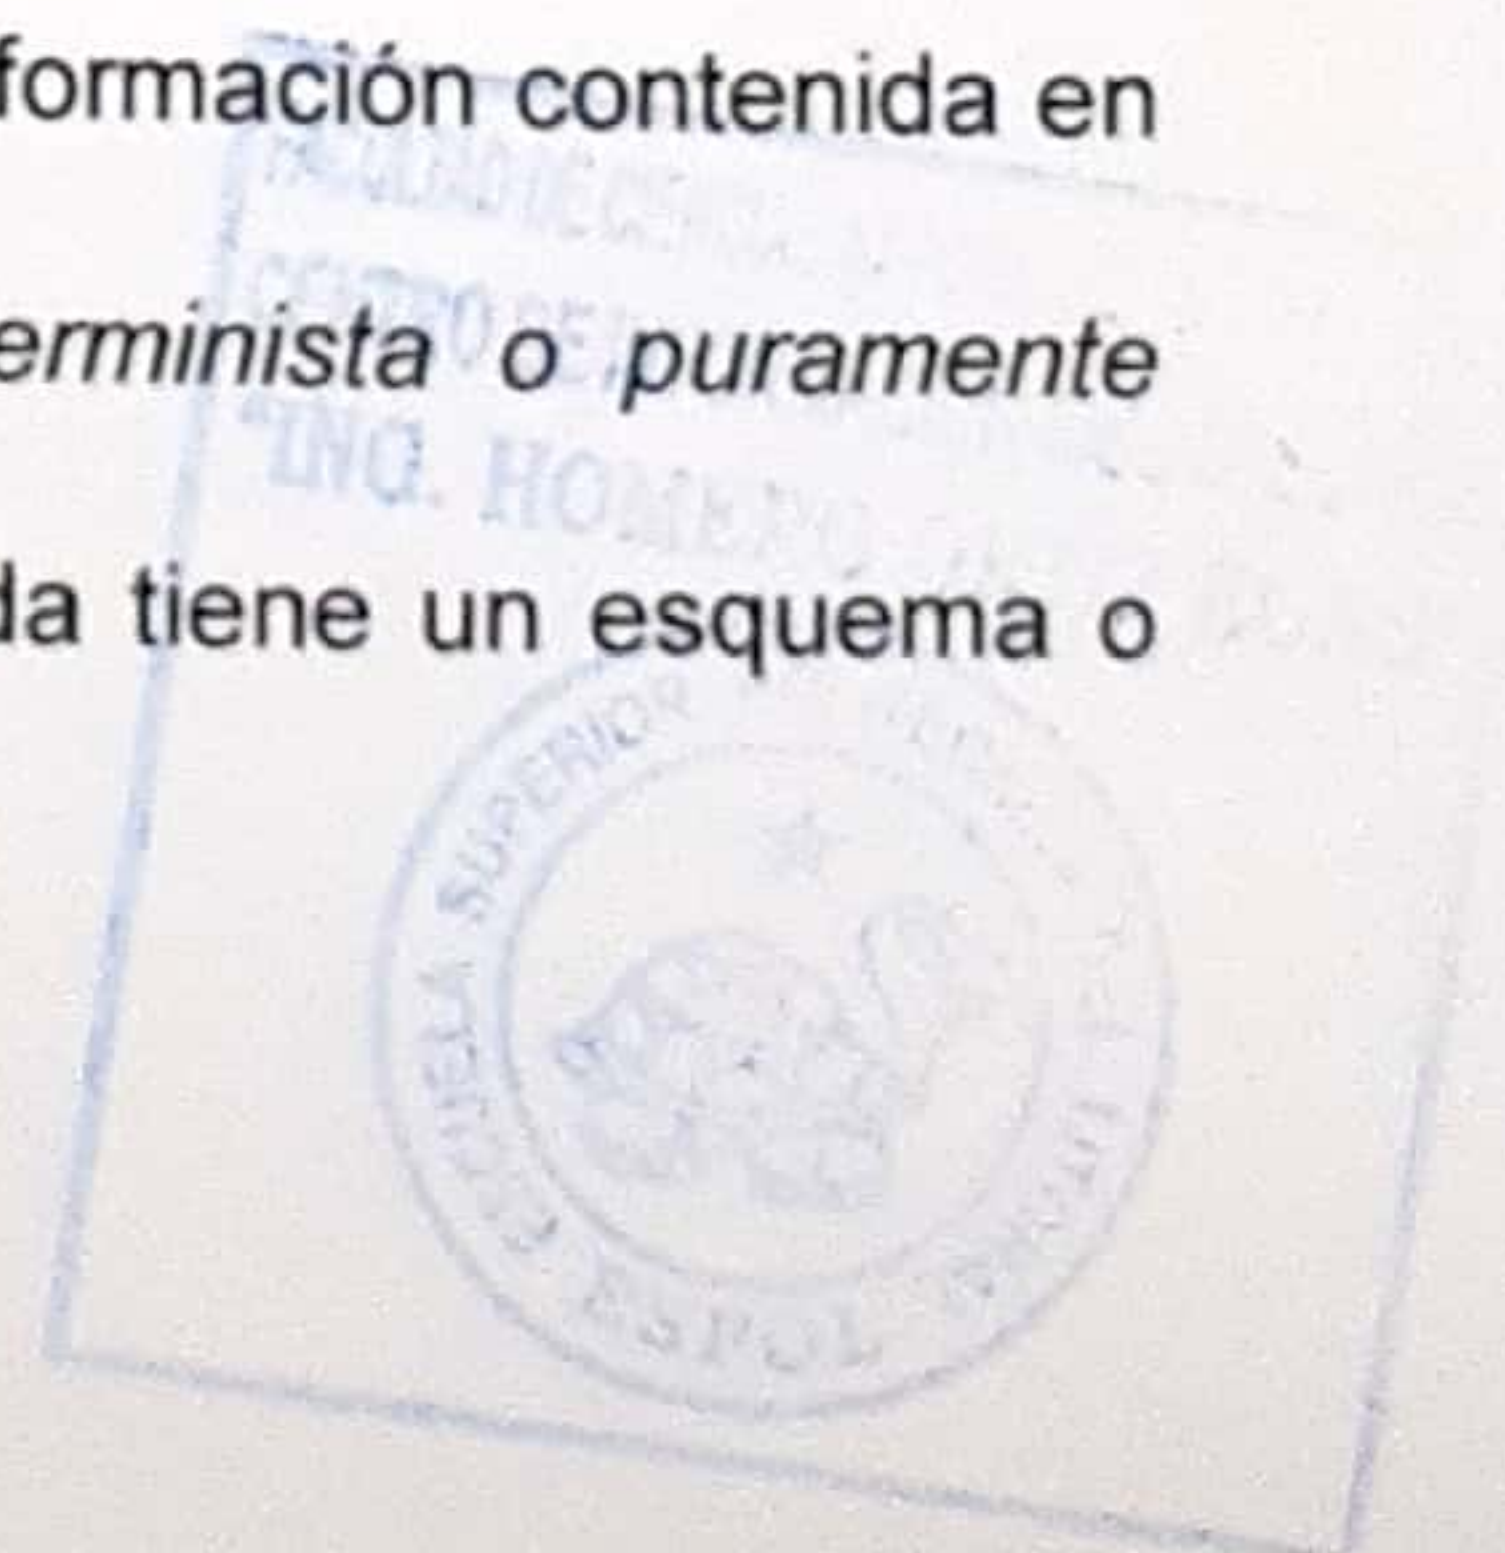
Sin embargo, para realizar un adecuado análisis de un conjunto determinado de datos, en este caso a través de la metodología X12-ARIMA, previamente se hace necesario el manejo de ciertos conceptos básicos y fundamentales en torno a las series de tiempo.

Este es el objetivo del presente capítulo, donde se examinan aquellas definiciones que se consideran de suma importancia conocer para posteriormente poder realizar análisis más profundos que involucren a las series temporales.

1.2. Series Temporales

Intuitivamente una serie de tiempo es un conjunto de observaciones acerca de una variable Y , observada a intervalos regulares de tiempo. La información que se maneja en una serie temporal es generalmente de carácter agregado, aunque el grado de agregación dependerá del sistema que se esté estudiando.

Un punto importante es la cantidad y calidad de información contenida en la serie temporal, así una serie puede ser *determinista* o *puramente aleatoria*. En el primer caso la variable observada tiene un esquema o



patrón de comportamiento fijo, mientras que en el segundo caso no existe ningún patrón de comportamiento.

En general las series económicas contienen ambos tipos de componentes, si se designa a D_t como el componente determinista y a N_t como el componente aleatorio, una serie temporal Y_t podría expresarse como la adición de ambos aunque existen otras formas de integración.

1.2.1.1. Series Transversales

$$Y_t = D_t + N_t$$

Donde t denota al tiempo, $t = 1, 2, 3, \dots$

Un ejemplo de serie temporal constituyen las cifras del PIB del Ecuador, de ellas se puede disponer en forma mensual, trimestral, anual, etc., en millones de dólares y para determinados periodos de tiempo, por mencionar un caso.


1.2.1. Tipos de Datos y Frecuencia

Dentro de un análisis económico se pueden utilizar series con los siguientes tipos de datos, que difieren según su proyección en el espacio y el tiempo:

1.2.1.1. Series Transversales

Los datos de corte transversal se caracterizan porque van todos referidos a un mismo momento del tiempo. Estos datos suelen consistir en información de familias, empresas, etc. en general un conjunto de datos de carácter macroeconómico. A este conjunto se le denomina información censal cuando contiene información exhaustiva de todos los elementos del colectivo que se está investigando y si solamente se investiga una parte del colectivo, la información obtenida es de carácter muestral.

En los datos de corte transversal no se plantea, en principio, problemas de interrelación entre los diferentes



1.2.1.1. elementos que integran la muestra o, en su caso, el censo obtenido.

En este tipo de serie los datos cubren el mismo tiempo en el mismo espacio. Por ejemplo el registro de ventas de camarón para el año 2003 de las diferentes distribuidoras del producto en el país.

1.2.1.2. Series Temporales

Los datos procedentes de una serie temporal constituyen un conjunto de observaciones de una variable a intervalos regulares de tiempo. Cuando se utiliza una serie temporal no es razonable adoptar el supuesto de que el valor que toma la variable estudiada en un periodo de tiempo es independiente de los valores que ha tomado dicha variable en los periodos que la han precedido.

Por ejemplo las exportaciones de combustibles y lubricantes realizadas por el Ecuador en los últimos 20 años (miles de dólares).

1.2.1.3. Datos de Panel

En este tipo de serie los datos cubren al mismo tiempo un espacio temporal y transversal. Por ejemplo se realiza una encuesta de aceptación de varios productos en el mercado para una misma línea y se hace una prueba a 20 personas cada semana durante un mes. Así se recaba información luego de que esas personas han probado el producto durante una semana y entonces tenemos un conjunto de datos de panel por analizar.

Otro concepto importante en una serie temporal es su **FRECUENCIA**, la cual se entiende como el espacio de tiempo que separa dos de sus datos.

En series económicas es habitual encontrar frecuencias anuales (un dato por año), semestrales (dos datos por año), trimestrales (4 datos por año), mensuales (12 datos por año), etc..

Cuanto menor es el tiempo transcurrido entre dos datos, se dice que mayor es la frecuencia de la serie.

1.2.2. Medición de las Series Temporales

La forma de medición de una serie temporal es un aspecto muy importante de considerar cuando se habla acerca de la modelización de una serie. Existen variadas formas de hacerlo y una de ellas es la medición en Niveles. A continuación se detallan las más relevantes.

TABLA 1
IMPORTACIONES AGRICOLAS AÑO 2002

MES	VALORES
Enero	31.828
Febrero	17.558
Abril	21.978
Mayo	17.500
Julio	17.500
Septiembre	18.507
Noviembre	14.400
Diciembre	27.500

1.2.2.1. Series medidas en Niveles

Se dice que una serie está medida en niveles cuando queda explícita la unidad de medida aplicada, esto en términos generales. Sin embargo, existen varias formas de medición según niveles, estas son:

Fuente: Banco Central Del Ecuador
Unidades: Miles de Dólares CIF
Elaborado por: V. Viquez

1.2.2.1.1. Variable de Flujo

Se tiene este caso cuando los valores que se obtienen para una variable son a un determinado periodo de

Los valores mostrados por la variable constituyen un acumulado de los valores adquiridos por ésta a lo largo de

tiempo, sin relación alguna con otros períodos de tiempo previos o con otras variables.

Por ejemplo en la Tabla 1 se observan las Importaciones Agrícolas realizadas durante los 12 meses del año 2002

TABLA 1
IMPORTACIONES AGRÍCOLAS AÑO 2002

MES	VALOR
Enero	31.828
Febrero	17.553
Marzo	21.979
Abril	27.396
Mayo	17.590
Junio	30.499
Julio	17.362
Agosto	18.207
Septiembre	18.587
Octubre	23.355
Noviembre	14.462
Diciembre	27.591

Fuente: Banco Central Del Ecuador
Unidades: Miles de Dólares CIF
Elaborado por: V. Vásquez

1.2.2.1.2. Variable Acumulada o "De Stock"

Los valores mostrados por la variable constituyen un acumulado de los valores adquiridos por ésta a lo largo de

un determinado período de tiempo y todos los anteriores al menos dentro de un marco temporal más amplio.

El total de Ingresos Corrientes y de Capital del Gobierno Central del Ecuador durante los meses del año 2003 constituye un ejemplo de variable acumulada y puede observarse en la Tabla 2.


TABLA 2
INGRESOS CORRIENTES Y DE CAPITAL
GOBIERNO ECUATORIANO AÑO 2003

MES	VALOR
Enero - Diciembre	4709,6
Enero	398,8
Febrero	312,8
Marzo	381,8
Abril	361,4
Mayo	362,1
Junio	489,2
Julio	425,9
Agosto	349,6
Septiembre	391,4
Octubre	488,5
Noviembre	320,9
Diciembre	427,3

Fuente: Ministerio de Economía y Finanzas
Información Estadística Mensual 1.823

Unidades: Millones de Dólares

Elaborado por: V. Vásquez



1.2.2.1.3. Saldo

Variable resultante de la agregación de un conjunto de variables de contenido diverso con cierta utilidad conceptual.

En este caso se puede mostrar en la Tabla 3 el total de exportaciones realizadas por el Ecuador durante los meses del año 2002. La variable exportaciones constituye un agregado de variables referentes a exportaciones petroleras (petróleo crudo y derivados), no petroleras (banano, café, camarón, etc..) y no tradicionales.

TABLA 3
EXPORTACIONES ECUATORIANAS AÑO 2002

MES	VALOR
Enero	350.163
Febrero	346.297
Marzo	405.990
Abril	447.954
Mayo	447.788
Junio	407.291
Julio	421.500
Agosto	443.682
Septiembre	447.007
Octubre	428.504
Noviembre	444.137
Diciembre	445.810

Fuente: Banco Central Del Ecuador
Unidades: Miles de Dólares FOB
Elaborado por: V. Vásquez

1.2.2.3 **1.2.2.1.4. Ratio** en Tasas de Crecimiento

Variable resultante de la razón comparada de dos magnitudes medidas en la misma unidad. Por ejemplo: el porcentaje de exportaciones realizadas por Ecuador hacia Estados Unidos, las tasas de mortalidad infantil, las tasas de crecimiento poblacional, etc..

1.2.2.2. Series medidas con Números Índices

En la Tabla 4, se cita como ejemplo la variación de las

Un número índice es una forma de medida adimensional que compara la magnitud de una variable en cada período con la magnitud de esa misma variable en un momento predeterminado del tiempo que se denomina base.

Por ejemplo se cita el Índice de Precios al Consumidor en el Ecuador.

Año	Índice
1999	101,5%
2000	99,4%
2001	97,0%
2002	95,2%

Fuente: Instituto Nacional de Estadística y Censos
Elaborado por: Y. Vasquez

1.2.2.3. Series medidas en Tasas de Crecimiento


Una serie se encuentra medida según tasas de crecimiento cuando cada valor expresa el incremento del valor de la serie respecto a un periodo anterior determinado. Existen tasas inter-periodo (intermensuales, intertrimestrales, etc..) y tasas interanuales. En ambas se compara el valor de un periodo con el periodo precedente o equivalente en tiempo.

En la Tabla 4, se cita como ejemplo la variación de las tasas de desocupación en el Ecuador durante los últimos 5 años.

TABLA 4
EVOLUCIÓN DEL DESEMPLEO EN EL ECUADOR
1998 – 2002

Condición	Desocupación Total
1.998	11,5%
1.999	14,4%
2.000	9,0%
2.001	10,9%
2.002	9,2%

Fuente: Instituto Nacional de Estadística y Censos
Elaborado por: V. Vásquez



Además cabe recalcar otro aspecto importante en cuanto a medición de una serie temporal, esto es conocer su **magnitud monetaria**. La más importante de considerar es si la serie económica se encuentra en términos constantes o corrientes

Una magnitud monetaria se dice que está expresada "en corrientes" si dicha magnitud se encuentra valorada a los precios del período en que se mide. Una magnitud se dice que está expresada "en constantes base X" si dicha magnitud se ha valorado a los precios de un determinado período X.

Así se puede resumir que una magnitud en constantes expresa el VOLUMEN de la magnitud medida, mientras que la magnitud en corrientes expresa el VALOR de esa misma magnitud.

En Macroeconomía, se usan siempre magnitudes en términos constantes para expresar el crecimiento REAL de los distintos agregados, sin considerar el efecto del movimiento de los precios. A la magnitud expresada en

términos corrientes se la suele denominar magnitud NOMINAL.

1.2.3. Técnicas y Métodos de Previsión

Tanto en la economía de la empresa como en el campo macroeconómico, se presenta el problema de la toma de decisiones, esto es elegir una opción entre varias alternativas. Cada opción dará lugar a un resultado distinto que puede ser medido de diversas maneras y que dependerá de situaciones que se puedan producir fuera del control de la persona encargada de tomar las decisiones.

Esta toma de decisiones se encuentra generalmente en un ambiente de incertidumbre respecto a los sucesos que se puedan producir en el futuro y que la persona desconoce, entonces se podrán lograr mejores resultados en la medida en que se logre reducir la incertidumbre sobre estos sucesos.

Precisamente a reducir la incertidumbre sobre el futuro están dirigidas las técnicas de previsión que se basan en el hecho de


realizar pronósticos lo más acertadamente posibles sobre sucesos que todavía no han tenido lugar. Estos pronósticos se los realiza basados en un análisis explícito de la información proporcionada por los sucesos ocurridos en un pasado más o menos inmediato.

A continuación se especifican diferentes métodos de previsión utilizados con el fin de realizar buenos pronósticos basados en información pasada.

GRÁFICO 1.1

MÉTODOS CUALITATIVOS DE PREVISIÓN

Los métodos de previsión se pueden agrupar en dos grandes bloques: métodos cualitativos o tecnológicos y métodos cuantitativos.



1.2.3.1. Métodos Cualitativos

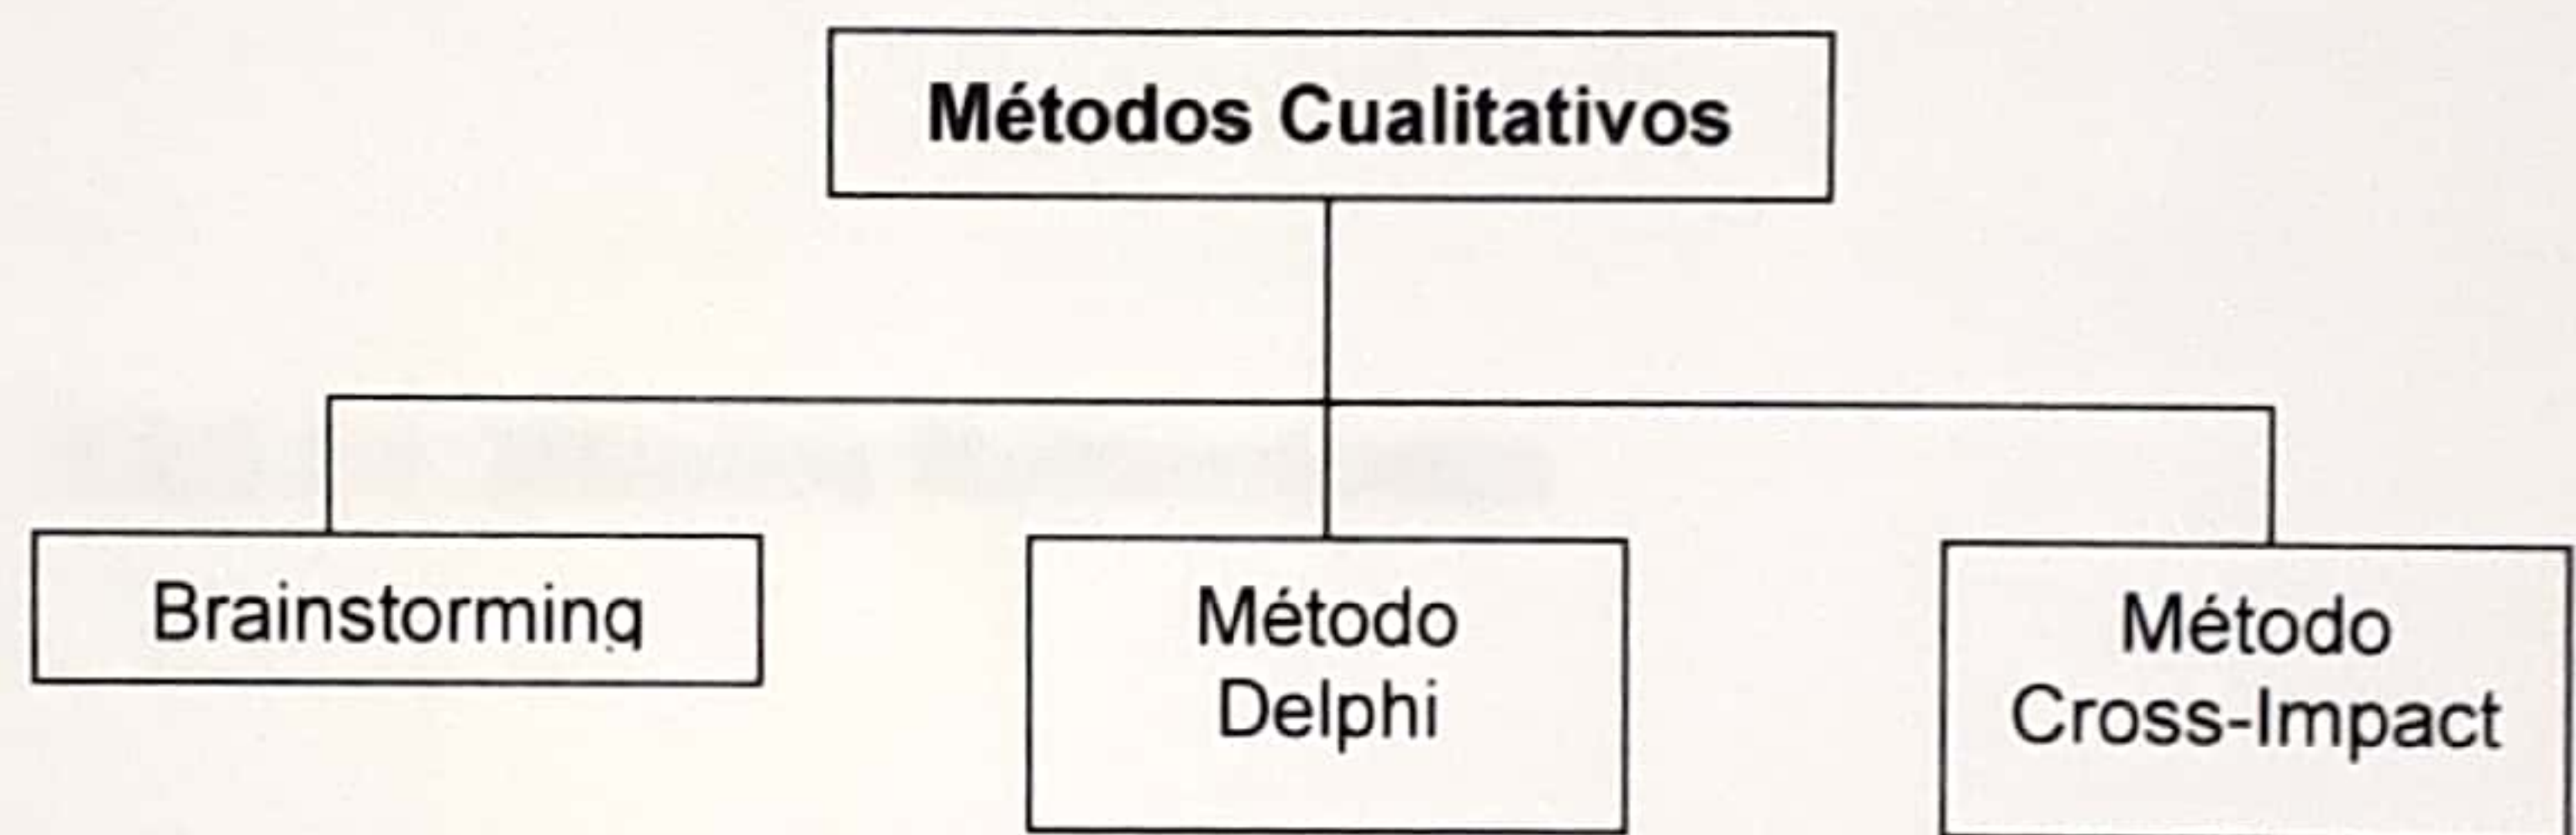
Los métodos cualitativos se utilizan en aquellos casos en los que el pasado no proporciona una información directa sobre el fenómeno considerado, por lo que es importante contar con un grupo de expertos que tengan un buen conocimiento tecnológico o especializado acerca del fenómeno cuya proyección en el futuro se trata de

analizar. En estos casos los métodos estadísticos juegan un papel secundario y se utilizarán simplemente para la organización de las ideas que generen los expertos.

Entre los múltiples métodos cualitativos se tienen: brainstorming (tormenta de ideas), Delphi y cross-impact.

GRÁFICO 1.1

MÉTODOS CUALITATIVOS DE PREVISIÓN



1.2.3.2. Métodos Cuantitativos

Dentro de los métodos de carácter cuantitativo se parte del supuesto de que se tiene información sobre el pasado acerca del fenómeno que se quiere estudiar, ésta información por lo general se encuentra registrada en

forma de series temporales. Entonces el objetivo es extraer toda la información posible contenida en los datos, y en base al patrón de conducta seguido en el pasado, realizar conjeturas sobre el futuro.

A los métodos cuantitativos se los puede clasificar de acuerdo a la información que utilizan en: Univariantes o de Series de Tiempo y en Multivariantes o Econométricos (Análisis Causal).

1.2.3.2.1. Métodos Multivariantes

Dentro de los métodos multivariantes o econométricos se trata de realizar un análisis causal para la explicación de la variable o variables objeto de estudio, así se logra definir el comportamiento de una o más variables en función de la evolución de otras variables llamadas explicativas.

Las variables explicadas por el modelo se denominan endógenas, mientras que las variables explicativas del modelo, pero no explicadas por él, se denominan

predeterminadas. Además entre las variables predeterminadas se tienen dos tipos: las exógenas y las endógenas retardadas. Las exógenas son aquellas que no son explicadas por el modelo en ningún momento del tiempo mientras que las endógenas retardadas a pesar de no ser explicadas por el modelo en el momento "t", lo fueron en un momento anterior. Así mismo, además de todas estas variables mencionadas, existe otra variable no observable (perturbación aleatoria) que recopila los efectos de diversos factores que desvían en mínimo el valor de la variable explicada respecto al valor esperado de acuerdo al modelo.

Debido a que los modelos multivariantes especifican de manera explícita la información que aportan las variables causales del fenómeno de interés de acuerdo con una determinada teoría económica, los resultados que se generan son más eficientes y poseen mayor poder explicativo que los modelos univariantes. Sin embargo, la principal desventaja que presentan los modelos multivariantes es que cuando se desean realizar predicciones de las variables explicadas por el modelo,

necesariamente se deben realizar predicciones para las variables explicativas, ya que se desconocen los valores futuros de estas variables. Entonces se incrementa el nivel de incertidumbre con que se realiza la predicción econométrica. Por otro parte, cuando el futuro puede suponer una alteración de tendencias de comportamiento respecto al pasado reciente, es recomendable utilizar estos modelos causales para predecir a mediano plazo (1 a 5 años).

especialmente dentro de los modelos multiecuacionales

Principalmente dentro de estos modelos multivariantes se distinguen dos grupos: el primero involucra a los modelos uniecuacionales en donde se tiene una variable endógena que puede ser explicada por una o varias variables predeterminadas.

variante a diferencia del causal, se trata de hacer provisiones de valores futuros de una variable.

utilizando como variable explicativa la contenida en

valores pasados de la serie temporal.

$$Y_t = \beta_0 + \beta_1 X_t + \beta_2 Y_{t-1} + \varepsilon_t$$

Y_t : variable explicada o endógena

X_t : variable exógena

Y_{t-1} : variable endógena retardada

ε_t : perturbación aleatoria



En el segundo grupo se ubican los modelos multiecuacionales que se utilizan cuando existe interdependencia entre la variable explicada por la ecuación y alguna de las variables explicativas, u otras variables endógenas de otras ecuaciones, entonces se debe formular un sistema de ecuaciones en el que se tengan en cuenta las diversas relaciones existentes entre esas variables, utilizando métodos de estimación diseñados especialmente dentro de los modelos multiecuacionales.

1.2.3.2.2. Métodos Univariantes

En el análisis univariante, a diferencia del causal, se trata de hacer previsiones de valores futuros de una variable, utilizando como información únicamente la contenida en valores pasados de la serie temporal.

En este enfoque no se necesita conocer ninguna relación de causalidad, explicativa del comportamiento de la variable endógena, ni en su defecto, ninguna información

relativa al comportamiento de otras variables explicativas, ya que en este caso no existe este tipo de variables. Es suficiente con conocer una serie temporal de la variable en estudio, para estimar el modelo que se utilizará para predecir.

La predicción univariante se utiliza, en problemas económicos, principalmente con dos objetivos:

- La predicción de algunas variables explicativas de un modelo causal, cuando se espera que en el futuro conserven algunas de las características de su evolución en el pasado.

- La predicción a corto plazo (de 1 a 4 trimestres), debido a su gran capacidad para recoger la dinámica en el comportamiento de la variable estudiada. Además, en condiciones normales, cuando no existen bruscas alteraciones respecto a la experiencia reciente de la variable, estos métodos pueden proporcionar buenas predicciones.

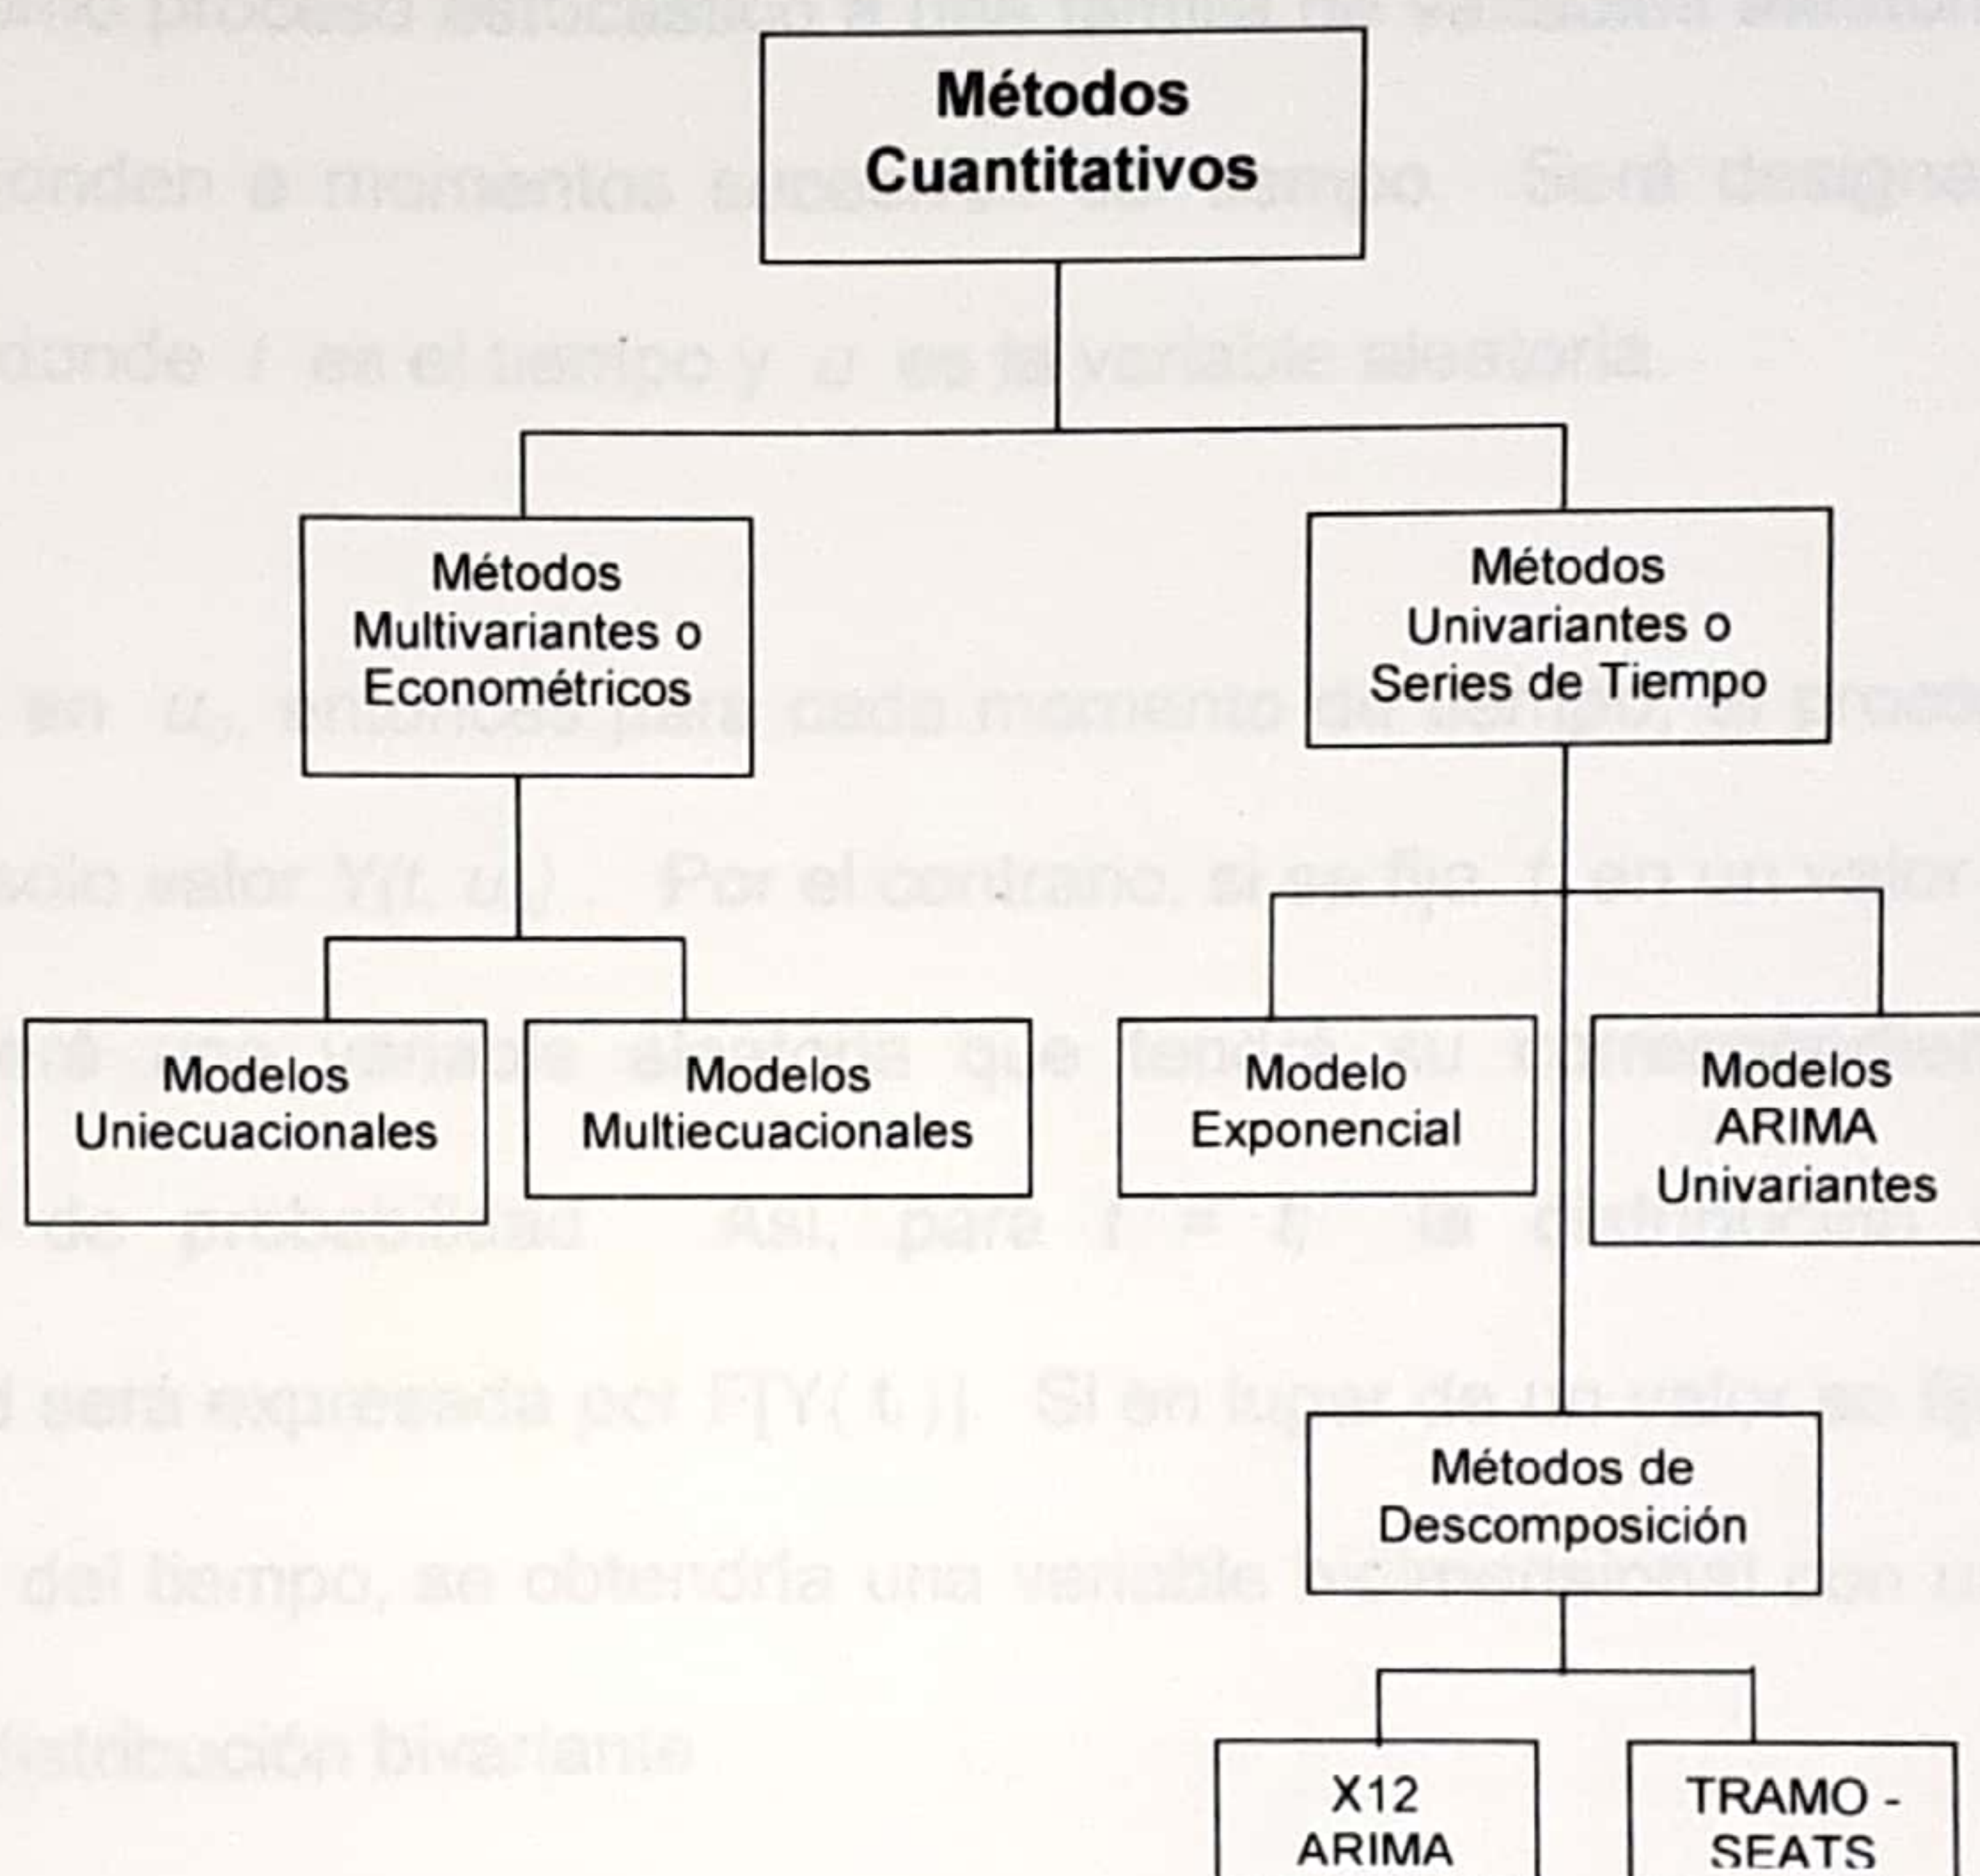
Entre las técnicas univariantes se tienen: el modelo autorregresivo de primer orden, el modelo de tendencia lineal o exponencial, los métodos de descomposición, entre otros. Además, una de las técnicas más rigurosas para la predicción univariante son las denominadas técnicas o modelos Box-Jenkins, o más específicamente modelos ARIMA, ya que las técnicas Box-Jenkins constituyen un conjunto más amplio, dentro del cual los modelos ARIMA univariantes son sólo una parte.

Por último, se encuentran los modelos de función de transferencia que reúnen características de los modelos univariantes y multivariantes.

En el gráfico 1.2 se muestra un esquema de clasificación de los Métodos Cuantitativos.

GRÁFICO 1.2

MÉTODOS CUANTITATIVOS DE PREVISIÓN



En el capítulo dos se explicará con mayor detalle en que consiste el método de descomposición de una serie de tiempo, dado que el método X12-ARIMA que se aplicará en el tratamiento de las Cuentas Nacionales del Ecuador durante el desarrollo del presente estudio, se refiere a este tipo de procedimiento.

1.3. Procesos Estocásticos

Se define como proceso estocástico a una familia de variables aleatorias que corresponden a momentos sucesivos del tiempo. Será designado por $Y(t,u)$, donde t es el tiempo y u es la variable aleatoria.

Si u se fija en u_0 , entonces para cada momento de tiempo, el proceso tomaría un solo valor $Y(t, u_0)$. Por el contrario, si se fija t en un valor t_0 , $Y(t_0, u)$ será una variable aleatoria que tendrá su correspondiente distribución de probabilidad. Así, para $t = t_i$ la distribución de probabilidad será expresada por $F[Y(t_i)]$. Si en lugar de un valor se fijan dos valores del tiempo, se obtendría una variable bidimensional con una función de distribución bivalente

$$F[Y(t_i), Y(t_j)]$$

En general, para un conjunto finito de valores del tiempo, se obtiene una función de distribución conjunta. Así para t_1, t_2, \dots, t_n la función de distribución conjunta sería:

$$F[Y(t_1), Y(t_2), \dots, Y(t_n)]$$

1.3.1. Caracterización

La determinación de las características de un proceso estocástico puede hacerse mediante dos formas, ya sea a partir de funciones de distribución conjunta como a través de los momentos.

Como momento de segundo orden respecto a la media del proceso

Se dice que un **proceso estocástico** está **perfectamente caracterizado** cuando se pueden determinar las funciones de distribución conjunta para cada conjunto finito de variables del proceso, es decir, para cada valor finito de n en

$$F[Y(t_1), Y(t_2), \dots, Y(t_n)]$$

La determinación de las características del proceso a partir de las funciones de distribución es en general un procedimiento complicado, por lo que se acostumbra a utilizar el método de los momentos. En una distribución de probabilidad se pueden calcular momentos de diverso orden, pero los más utilizados son los de primer y segundo orden.

En un proceso estocástico Y_t , la *media* o *momento de primer orden* se define de la siguiente manera:

$$\mu_t = E[Y_t]$$

El subíndice "t" señala que la media será en general distinta para cada periodo de tiempo.

Como *momento de segundo orden* respecto a la media es preciso considerar, además de la varianza, la covarianza entre variables referidas a distintos momentos de tiempo o autocovarianza a la que se designará por

$$\gamma_{t,s} = \text{cov}(Y_t, Y_s) = E(Y_t - \mu_t)(Y_s - \mu_s)$$

Cuando $s = t$ se tiene definida la varianza:

$$\gamma_{t,t} = \text{var}(Y_t) = E(Y_t - \mu_t)^2$$

Como forma alternativa de caracterización de un proceso estocástico se utilizan los coeficientes de autocorrelación


$$\rho_{t,s} = \frac{\text{cov}(Y_t, Y_s)}{\sqrt{\text{var}(Y_t)\text{var}(Y_s)}}$$

Las autocorrelaciones conjuntamente con las varianzas proporcionan idéntica información que las autocovarianzas. Sin embargo, es preferible utilizar las autocorrelaciones porque proporcionan unas medidas relativas a diferencia de lo que ocurre con las autocovarianzas que vienen afectadas por la escala que se utiliza.

La caracterización de un proceso estocástico mediante los momentos de primer y segundo orden es en principio más incompleta que cuando se hace mediante funciones de distribución. Sin embargo, si el **proceso** es **normal** éste queda perfectamente caracterizado a través de los dos primeros momentos.

1.3.2. Las Series Temporales desde el Contexto de los Procesos Estocásticos

Aunque en una serie temporal se dispone de una observación para cada periodo de tiempo, no se obtiene en general de forma determinista como sería el caso en una función exacta del tiempo. Una serie temporal en general tendrá un carácter aleatorio, y se



puede interpretar como una muestra de tamaño 1 tomada en periodos sucesivos de tiempo en un proceso estocástico. En este sentido, a una serie temporal se le considera como una realización de un proceso estocástico donde el dato extraído para un periodo concreto no será, en general, independiente de los datos extraídos para periodos anteriores y aunque se disponga de una serie muy larga, debe considerarse toda ella como una sola realización de un proceso estocástico.

Si se deseara comparar la relación entre una serie temporal y el proceso estocástico que la genera, se puede decir que es la misma que hay entre una muestra y la variable aleatoria de la que procede.

Las particularidades de una serie temporal (frente a una muestra) y de un proceso estocástico (frente a una variable aleatoria) son:

- Las series temporales y los procesos estocásticos están referidos a instantes de tiempo concretos, y
- los datos están ordenados desde el pasado hasta el presente.

En términos generales el objetivo del análisis de series temporales es inferir la forma del proceso estocástico a partir de las series temporales que genera.

Entonces para poder, a partir de una sola realización, efectuar inferencias sobre un proceso estocástico es preciso imponer restricciones a este último. Las restricciones impuestas habitualmente son que sea estacionario y ergódico.

1.3.3. Procesos Estacionarios y Ergódicos

1.3.3.1. Procesos Estacionarios

Para definir la estacionariedad de un proceso se pueden utilizar las funciones de distribución o alternativamente los momentos.

- Se dice que un **proceso estocástico es estacionario en sentido estricto** cuando al realizar un mismo desplazamiento en el tiempo de todas las variables de

cualquier distribución conjunta finita, resulta que esta distribución no varía.

Considerando la función de distribución conjunta

$$F(Y_{t_1}, Y_{t_2}, \dots, Y_{t_n})$$

Desplazándola m periodos de tiempo

$$F(Y_{t_1+m}, Y_{t_2+m}, \dots, Y_{t_n+m})$$

Se debe de verificar que:

$$F(Y_{t_1}, Y_{t_2}, \dots, Y_{t_n}) = F(Y_{t_1+m}, Y_{t_2+m}, \dots, Y_{t_n+m})$$

El análisis de estacionariedad es más complejo a partir de funciones de distribución que si se efectúa a partir de los momentos. En contrapartida, el concepto de estacionariedad es más limitado.

- Un proceso es **estacionario de primer orden** o en media si se verifica que:

$$E[Y_t] = \mu_t \quad \forall t$$

Por lo que si un proceso es estacionario en media, la esperanza matemática permanece constante a lo largo del tiempo.

- Un proceso es **estacionario de segundo orden** (o en sentido amplio) si se verifica:

$$\text{var } Y_t = E(Y_t - \mu)^2 = \sigma^2 < \infty \quad \forall t$$

$$E(Y_{t+k} - \mu_t)(Y_t - \mu) = \gamma_k \quad \forall t$$

Al definir un proceso estacionario en sentido amplio, se tiene en cuenta implícitamente que el proceso es también estacionario en media. Además si un proceso es estacionario en sentido estricto también será estacionario en sentido amplio, lo contrario no necesariamente ocurre. Igualmente se verifica que si un proceso es estacionario

en sentido amplio y además *normal*, el proceso será estacionario en sentido estricto.

Además en un proceso estocástico estacionario las autocorrelaciones vienen dadas por:

$$\rho_k = \frac{\gamma_k}{\gamma_0} \quad k \geq 0$$

1.3.3.2. Procesos Ergódicos

Cuando los valores de la serie temporal alejados en el tiempo están muy correlacionados, es decir, cuando ρ_k se mantiene en unas cotas elevadas para un k grande, sucederá que al aumentar el tamaño de la muestra se añade poca información nueva. La consecuencia de este hecho en el plano estadístico será que los estimadores no serán consistentes.

Una condición necesaria, aunque no suficiente, de la ergodicidad es

$$\lim_{k \rightarrow \infty} \rho_k = 0$$

Cuando se verifica la ergodicidad se pueden obtener estimadores consistentes que caractericen al proceso en cuestión.

1.3.4. Procesos Lineales

Una clase especial de los procesos estacionarios y ergódicos son los procesos lineales. Estos procesos se caracterizan porque se pueden representar como una combinación lineal de variables aleatorias.

Se tienen los siguientes tipos de procesos lineales:

1.3.4.1. Proceso Puramente Aleatorio o Ruido Blanco

Se expresa de la siguiente forma:

$$\varepsilon_t = Y_t$$

donde ε_t satisface las siguientes propiedades:



$$E[\varepsilon_t] = 0 \quad \forall t$$

$$E[\varepsilon_t^2] = \sigma^2 \quad \forall t$$

$$E[\varepsilon_t \varepsilon_\tau] = 0 \quad t \neq \tau$$


1.3.4.2. Proceso Autorregresivo de Orden "p": AR (p)

Fue introducido por primera vez por Yule (1927). Se lo denota como AR(p) y se lo expresa de la siguiente manera:

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

como puede verse en un proceso AR(p), aparece un "ruido blanco" ε_t referido al momento actual y la variable desfasada para distintos periodos, siendo p el retardo máximo que aparece en el proceso. La denominación de autorregresivo procede de que Y_t se obtiene mediante regresión sobre valores desfasados de la propia variable.

Si en la ecuación de Y_t se utiliza el operador de retardos:



$$\phi(L) = 1 - \phi_1 L + \phi_2 L^2 + \dots + \phi_p L^p$$

El modelo autorregresivo se puede expresar de forma compacta así:

$$\phi(L)Y_t = \varepsilon_t$$

1.3.4.2.1. Características del Proceso AR (p)

- Para que el proceso sea estacionario se requiere que las raíces de la ecuación polinomial

$$1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p = 0$$

Se encuentren fuera del círculo unidad.

- Si en el modelo autorregresivo se incluye un término independiente

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

Entonces bajo el supuesto de estacionariedad, tomando esperanzas en Y_t y denominando

$$E[Y_t] = \mu, \quad \forall t, \text{ se tiene que}$$

$$\mu = \phi_1 \mu_1 + \phi_2 \mu_2 + \dots + \phi_p \mu_p$$

Por lo tanto,

$$\mu = \frac{\delta}{1 - \phi_1 - \phi_2 - \dots - \phi_p}$$

En lo sucesivo se hace el supuesto, sin pérdida de generalidad, de que $\delta=0$.

- Multiplicando ambos miembros del modelo autorregresivo original por $Y_{t-\tau}$ y tomando esperanzas se tiene que las autocovarianzas quedan definidas de la siguiente forma

$$\gamma_t = \phi_1 \gamma_{t-1} + \phi_2 \gamma_{t-2} + \dots + \phi_p \gamma_{t-p} + E[\varepsilon_t Y_{t-\tau}]$$

Por lo tanto la varianza, donde $\tau=0$ es la siguiente:

$$\gamma_0 = \phi_1 \gamma_1 + \dots + \phi_p \gamma_p + \sigma_\varepsilon^2$$


Para valores de $\tau > 0$ el resultado obtenido es el siguiente

$$\gamma_\tau = \phi_1 \gamma_{\tau-1} + \phi_2 \gamma_{\tau-2} + \dots + \phi_p \gamma_{\tau-p} \quad \tau > 0$$

- Dividiendo ambos miembros de esta última ecuación para γ_0 se obtiene la ecuación en diferencias de orden p relativa a las autocorrelaciones:

$$\rho_\tau = \phi_1 \rho_{\tau-1} + \phi_2 \rho_{\tau-2} + \dots + \phi_p \rho_{\tau-p}$$

Tomando ρ_0, ρ_1, \dots y ρ_{p-1} como condiciones iniciales determinadas a partir de los coeficientes $\phi_1, \phi_2, \dots, \phi_p$, la solución de la ecuación de autocorrelaciones permite calcular los valores de ρ_τ para $\tau \geq p$.



Particularizando, la ecuación de autocorrelación se obtiene el sistema de ecuaciones de Yule-Waker

$$\rho_1 = \phi_1 + \phi_2 \rho_1 + \dots + \phi_p \rho_{p-1}$$

$$\rho_2 = \phi_1 \rho_1 + \phi_2 + \dots + \phi_p \rho_{p-2}$$

.....

$$\rho_p = \phi_1 \rho_{p-1} + \phi_2 \rho_{p-2} + \dots + \phi_p$$

- Si en la ecuación original del proceso autorregresivo se multiplican ambos miembros por $\phi^{-1}(L)$ se obtiene

$$Y_t = \phi^{-1}(L)\varepsilon_t = \frac{1}{\phi(L)}\varepsilon_t$$

De esta forma se ha pasado de un modelo AR(p) a un modelo MA(q).

1.3.4.3. Proceso de Medias Móviles de Orden "q": MA (q)

La introducción de estos procesos también se debe a Yule (1921, 1926). Se lo denota como MA(q) y viene dado por:

$$Y_t = \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q}$$

La expresión de medias móviles hace referencia a que la variable Y_t se obtiene como un promedio de variables de "ruido blanco" (en este caso $q+1$), siendo las θ_i los coeficientes de ponderación; como las variables que forman parte de este promedio varían a lo largo del tiempo, reciben el apelativo de móviles.

Utilizando el operador de retardos,

$$\theta(L) = 1 - \theta_1 L - \theta_2 L^2 - \dots - \theta_q L^q$$

El modelo de medias móviles se puede expresar de forma compacta:

$$Y_t = \theta(L) \varepsilon_t$$

1.3.4.3.1. Características del Proceso MA (q)

- Si en el modelo de medias móviles se incluye un término constante

$$Y_t = \delta + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q}$$

Entonces al tomar esperanzas matemáticas en la expresión anterior resulta

$$E[Y_t] = \delta$$

Así pues, en los modelos de medias móviles, la media del proceso coincide con el término independiente, que aparece en el segundo miembro.

Por lo tanto en el modelo original se tiene que la media es cero cualesquiera sean los valores de θ_i .



- Si en la ecuación inicial del modelo se multiplican ambos miembros por $Y_{t-\tau}$ y se toman esperanzas se obtienen los siguientes resultados para la varianza,

$$\gamma_0 = (1 + \theta_1^2 + \dots + \theta_q^2) \sigma_\varepsilon^2$$

y para las autocovarianzas

1.3.4.4. Proceso Mixto Autorregresivo - Medias Móviles de

Orden "p,q": ARMA (p,q)


$$\gamma_\tau = \begin{cases} (-\theta_\tau + \theta_1\theta_{\tau+1} + \dots + \theta_{q-\tau}\theta_q) \sigma_\varepsilon^2 & \tau = 1, 2, \dots, q \\ 0 & \tau > q \end{cases}$$

Mediante la combinación de un proceso autorregresivo y un proceso de medias móviles se obtiene un proceso

- En cuanto a los coeficientes de autocorrelación autorregresivo y q, señala el correspondiente a la parte

de las medias móviles. La divulgación y popularización de este tipo de procesos se fundamenta en la obra de Box y Jenkins (1976), aunque fueron estudiados con anterioridad por Wold (1938) y Bartlett (1946).

En general los coeficientes de autocorrelación de un MA (q) están acotados.



- Para que un proceso MA(q) sea invertible se requiere que las raíces de la ecuación polinomial

$$1 - \theta_1 L - \theta_2 L^2 - \dots - \theta_q L^q = 0$$

Se ubiquen fuera del círculo unidad.

1.3.4.4.1. Características del Proceso ARMA (p,q)

1.3.4.4. Proceso Mixto Autorregresivo - Medias Móviles de Orden "p,q": ARMA (p,q)

Mediante la combinación de un proceso autorregresivo y un proceso de medias móviles se obtiene un proceso ARMA(p,q), donde p indica el retardo máximo de la parte autorregresiva y q señala el correspondiente a la parte de las medias móviles. La divulgación y popularización de este tipo de procesos se debe fundamentalmente a la obra de Box y Jenkins (1976), aunque fueron estudiados con anterioridad por Wold (1938) y Barlett (1946).

La expresión del ARMA(p,q) es la siguiente:

$$Y_t = \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q}$$

Utilizando los operadores polinomiales de retardo, el modelo queda expresado en forma compacta del siguiente modo:

$$\phi(L)Y_t = \theta(L)\varepsilon_t$$

1.3.4.4.1. Características del Proceso ARMA (p,q)

- Para que el modelo ARMA(p,q) sea estacionario se requiere que las raíces de la ecuación polinomial

$$\phi(L) = 1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p = 0$$

caigan fuera del círculo unidad.

Si se cumplen las condiciones de estacionariedad, el modelo se puede expresar como un MA(∞), pudiendo representarse de la siguiente forma:

$$Y_t = \frac{\theta(L)}{\phi(L)} \varepsilon_t = \psi(L)\varepsilon_t$$

A partir de la identidad

$$\phi(L)\psi(L) = \theta(L)$$

se pueden deducir un conjunto de ecuaciones que permiten obtener los valores de ψ_i .

- Para que el modelo ARMA(p,q) sea invertible, se requiere que las raíces de la ecuación polinomial

$$\theta(L) = 1 - \theta_1 L - \theta_2 L^2 - \dots - \theta_q L^q = 0$$

caigan fuera del círculo unidad.

Si se cumplen las condiciones de invertibilidad, el modelo ARMA(p,q) se puede expresar mediante un AR(∞):

$$\varepsilon_t = \frac{\phi(L)}{\theta(L)} Y_t = \pi(L) Y_t$$



Los coeficientes del operador polinomial $\pi(L)$ deben cumplir la siguiente igualdad:

$$\pi(L)\theta(L) = \phi(L)$$

- En el modelo ARMA originalmente presentado la media es cero. Pero si se añade al segundo miembro un término constante δ , la media del proceso se deduce a partir de la siguiente expresión:

$$E[\phi(L)Y_t] = \delta + E[\theta(L)\varepsilon_t]$$

Por lo tanto

$$\phi(L)E(Y_t) = \delta$$

Si el proceso es estacionario entonces $E[Y_t] = \mu_t \quad \forall t$, con lo que

$$\mu = \frac{\delta}{1 - \phi_1 L - \dots - \phi_p L^p} = \frac{\delta}{1 - \phi_1 - \dots - \phi_p}$$

- 1.3.3. Proceso
- Si en el modelo inicial ARMA se multiplican ambos miembros por $Y_{t-\tau}$, se toman esperanzas y además se considera en la evaluación de las esperanzas del segundo miembro que

$$E[\varepsilon_t Y_{t'}] = 0 \quad t' < t$$

Entonces se verifica que,

$$\gamma_\tau - \phi_1 \gamma_{\tau-1} - \dots - \phi_p \gamma_{\tau-p} = 0 \quad \tau > q$$

Esta ecuación en diferencias permite obtener las autocovarianzas.

- Dividiendo esta última ecuación para γ_0 , se obtiene la ecuación en diferencias para generar los coeficientes de autocorrelación para $\tau > q$. En la determinación de los q primeros valores interviene la parte de medias móviles del modelo.

$$\rho_\tau - \phi_1 \rho_{\tau-1} - \dots - \phi_p \rho_{\tau-p} = 0$$



1.3.5. Procesos No Estacionarios

Para el estudio de series económicas a las que se busque ajustar a alguno de los procesos anteriormente estudiados (AR, MA o ARMA) se ha impuesto como restricciones la estacionariedad y/o invertibilidad, sin embargo en muchas ocasiones las series económicas no cumplen con dichas restricciones. Por lo tanto para obtener un tratamiento de estas series basado en la teoría de los procesos estocásticos es necesario ampliar el campo para incluir los procesos no estacionarios.

La idea es considerar cierto tipo de procesos no estacionarios que sean adecuados para describir el comportamiento de las series económicas, y al mismo tiempo, sean fácilmente transformables en procesos estacionarios con motivo de utilizar las ventajas que ofrecen estos últimos.

Así si se tiene un proceso no estacionario Y_t y se toman diferencias de orden k se llegará al proceso w_t que es estacionario, entonces es posible realizar los análisis requeridos en base a la nueva serie obtenida. Luego si se integra el proceso

w_t se obtiene el proceso Y_t , con el cual se emiten las conclusiones finales.

En general, se denominan modelos no estacionarios homogéneos a todos aquellos modelos que se pueden transformar en estacionarios mediante la toma de diferencias de un determinado orden, o dicho de otra forma, modelos integrados son aquellos que se pueden obtener mediante suma o integración de un proceso estacionario.

Los modelos no estacionarios homogéneos fueron estudiados inicialmente por Tintner (1940), Tintner y Rao (1963) y Yanglom (1955). Sin embargo, Box y Jenkins son aquellos últimos autores que han influido en la divulgación de estos modelos.

El modelo que a continuación se presenta pertenece a la clase de modelos integrados:

1.3.3.1. Modelos ARIMA

$$Y_t = Y_{t-1} + \varepsilon_t$$

Es claro que el modelo anterior definido como un AR (1) con coeficiente $\phi_1 = 1$ no es estacionario, dado que no cumple con la

condición de estacionariedad $|\phi_1| < 1$ y además se puede comprobar que su varianza no es finita. Sin embargo, este proceso puede transformarse en un proceso estacionario aplicando la toma de diferencias.

$$w_t = Y_t - Y_{t-1} = \Delta Y_t$$

$$w_t = \Delta Y_t = \varepsilon_t$$

Es decir al tomar la primera diferencia en el proceso inicial Y_t se obtiene como proceso transformado w_t un "ruido blanco", que es un tipo de proceso estacionario definido anteriormente, por lo que se le da igual tratamiento.

Al modelo integrado w_t se le conoce con el nombre de "Paseo Aleatorio" y constituye una clase de estos modelos integrados.

1.3.5.1. Modelos ARIMA

La metodología de los modelos ARIMA fue formalizada por Box y Jenkins en 1976, por eso también se les denomina modelos Box-Jenkins.

El nombre de estos modelos procede de las siglas en inglés de Autorregresive, Integrated and Moving Average. Su significado es Modelos integrados (I), Autorregresivos (AR) y de Medias Móviles (MA).

A un proceso integrado Y_t se le denomina ARIMA(p,d,q) si tomando diferencias de orden d se obtiene un proceso estacionario w_t del tipo ARMA(p,q).

Así pues se tiene que

$$w_t = \Delta^d Y_t = (1-L)^d Y_t$$

$$(1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p) w_t = (1 - \theta_1 L - \theta_2 L^2 - \dots - \theta_q L^q) \varepsilon_t$$

Reemplazando ecuaciones y escribiendo en forma más compacta, el modelo ARIMA(p,d,q) se define así:

$$\phi(L)(1-L)^d Y_t = \theta(L)\varepsilon_t$$

Los modelos ARIMA constituyen una clase particular de procesos no estacionarios. Sin embargo, en muchos

casos son suficientes para representar el comportamiento de muchas series económicas gracias a que aplicando transformaciones de tipo no lineal muchas series pasan a ser representables a través de estos modelos.

No obstante debe considerarse que cuando una serie económica se observa a lo largo de un periodo dilatado de tiempo ocurre con frecuencia que también la varianza viene afectada por una tendencia, y esta tendencia no desaparece al tomar diferencias. Cuando se presenta esta situación la transformación adecuada puede consistir en tomar logaritmos.

1.3.5.2. Proceso ARIMA

Los estadísticos Box y Cox definieron una transformación instantánea de carácter general,

$$Y_t^{(\lambda)} = \begin{cases} \frac{(Y_t^\lambda - 1)}{\lambda} & \lambda \neq 0 \\ \ln Y_t & \lambda = 0 \end{cases}$$

Cuando el parámetro es $\lambda = 1$, la transformación consiste prácticamente en tomar valores originales.



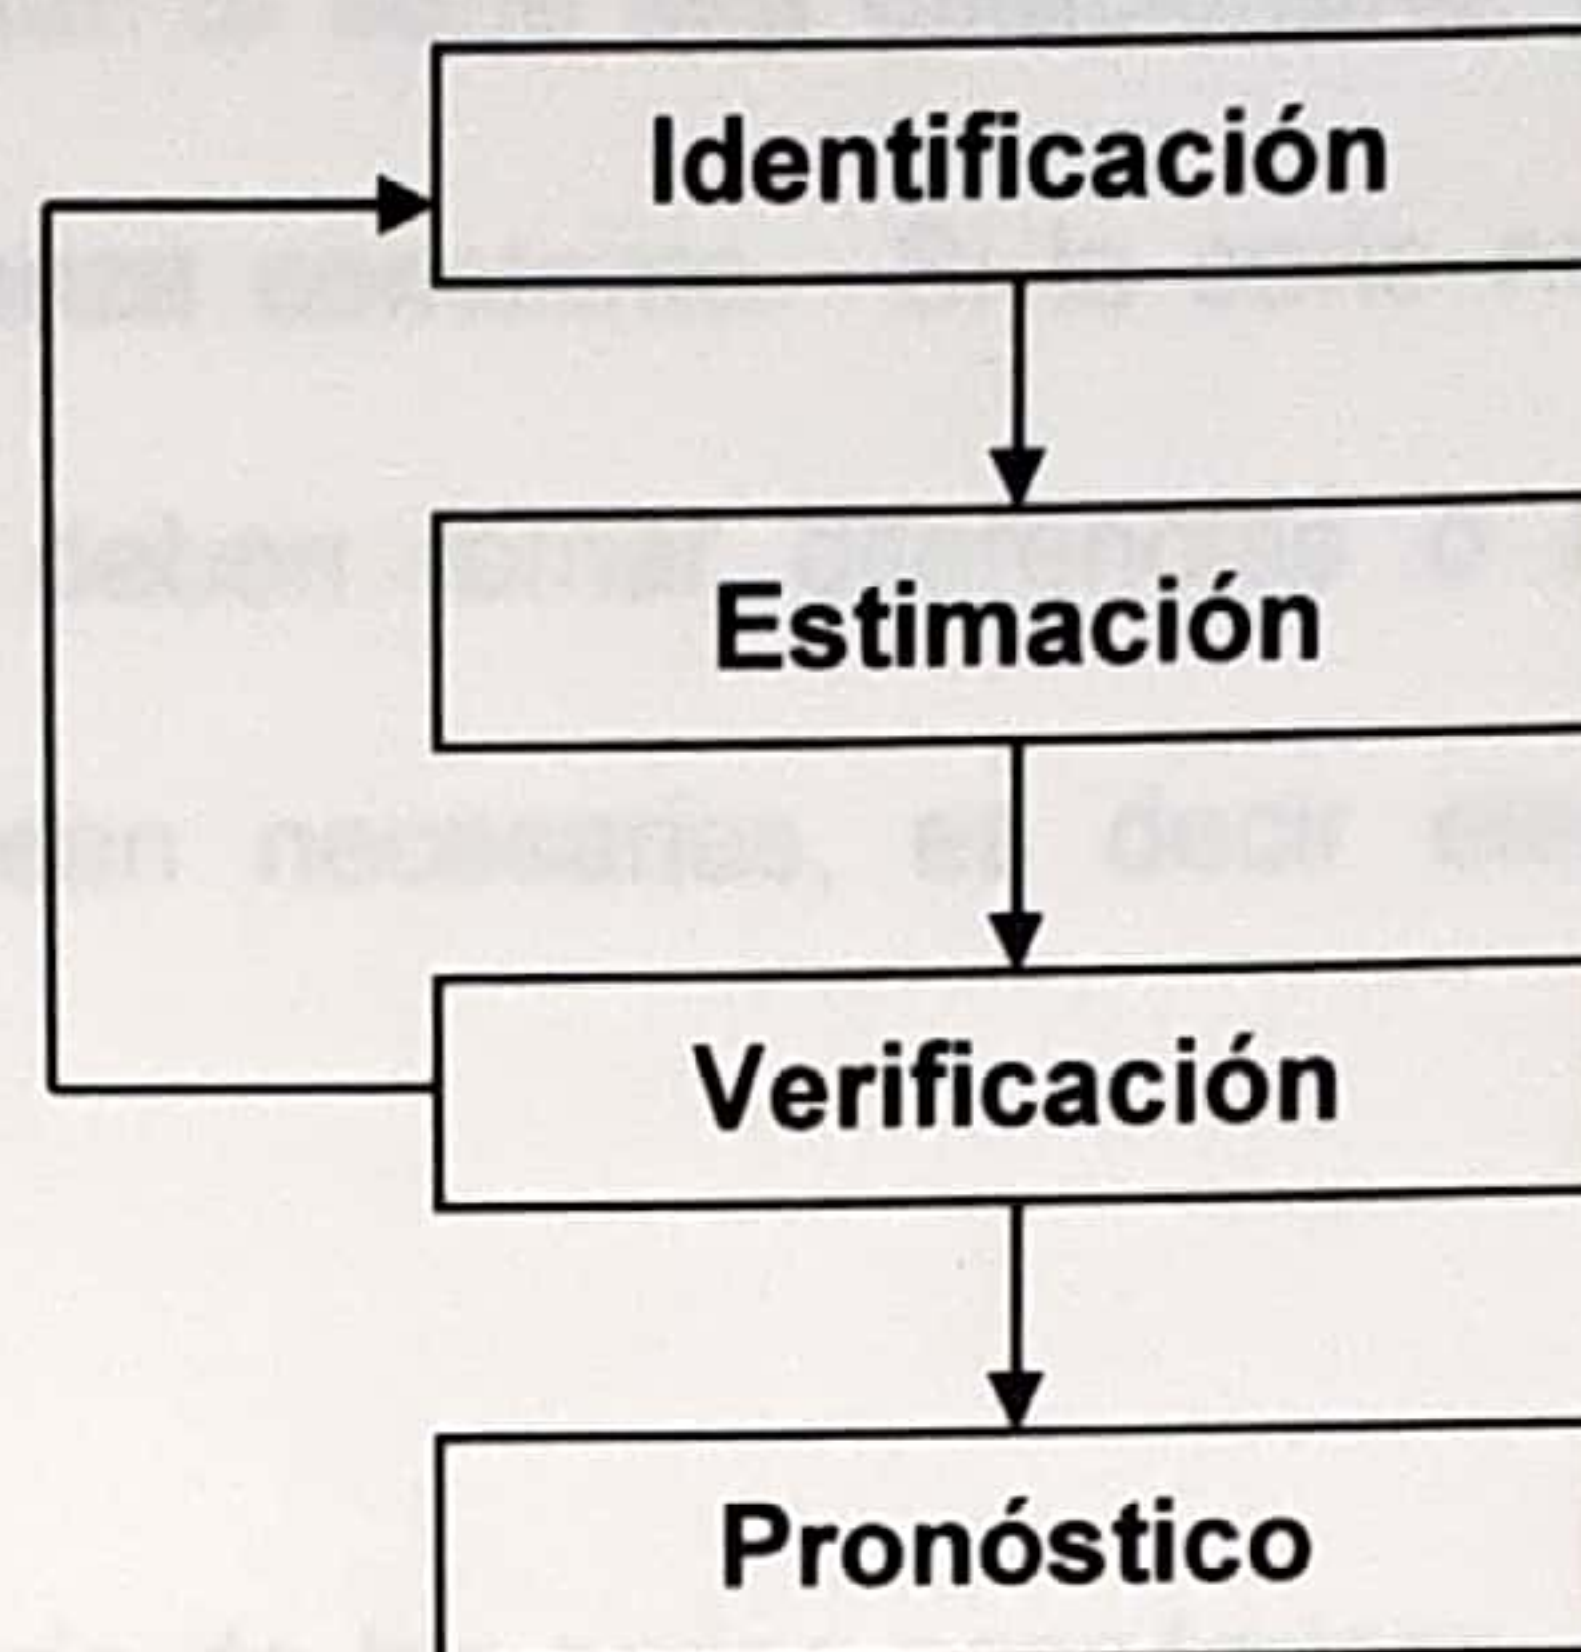
Además se puede combinar una diferencia con la toma de logaritmos y se obtiene la transformación $\Delta \ln Y_t$, conocida como Tasa de Variación Natural (fluctuación estacionaria). Esta sirve para el estudio de muchas series económicas dado que se define como una aproximación a la tasa de variación relativa que por lo general resulta ser no estacionaria.

$$\Delta \ln Y_t \approx \frac{\Delta Y_t}{Y_{t-1}}$$

1.3.5.2. Proceso ARIMA

Las etapas que se siguen en la elaboración de un modelo ARIMA con fines predictivos son las siguientes: identificación, estimación, verificación y pronóstico.

El gráfico 1.3 muestra un esquema organizado de las etapas antes mencionadas.

GRÁFICO 1.3**ETAPAS DE ELABORACIÓN DE UN MODELO ARIMA**

En primer lugar se busca identificar el proceso estocástico que ha generado los datos, luego estimar los parámetros que caracterizan dicho proceso y verificar que se cumplan las hipótesis que han permitido la estimación de dichos parámetros. Si los supuestos no se cumplen, la fase de verificación sirve como retroalimentación para una nueva fase de identificación. Cuando se satisfagan las condiciones iniciales, se puede utilizar el modelo para pronosticar.

1.3.5.2.1. Identificación

Se requiere que la serie sea estacionaria, esto es posea media y varianza constante. Si la serie no cumple este requisito, se deben tomar diferencias o logaritmos las veces que sean necesarias, es decir elegir un d y λ adecuados.

Para la mayoría de las series económicas, la experiencia muestra que la estacionariedad se logra después tomar una diferencia o una diferencia de logaritmos.

Además como una segunda etapa dentro de la Fase de Identificación se deben determinar los valores de p y q del modelo w_t finalmente estacionario, a través de las funciones de autocorrelación y autocorrelación parcial estimadas (FACE y FACPE).



1.3.5.2.2. Estimación

En esta etapa se obtienen los valores estimados de los coeficientes del modelo, de esta manera al concluir la fase se conocerá el proceso que hipotéticamente ha generado la serie transformada w_t .

$$\hat{\phi}_1, \hat{\phi}_2, \dots, \hat{\phi}_p$$


$$\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_q$$

$$\hat{\sigma}_\varepsilon^2, \hat{\mu}_w \text{ media estimada del proceso ARMA}$$

Finalmente la serie w_t se puede expresar como:

$$\phi(L)(w_t - \mu_w) = \theta(L)\varepsilon_t$$

Al estimar el modelo que genera la serie w_t es necesario también considerar si el modelo incluye variables de intervención, esto es, fenómenos que afectan el comportamiento original de la serie y deben ser evaluados e incorporados al modelo para evitar errores en las



estimaciones de los parámetros. Posteriormente, en el capítulo dos, se analizarán los Modelos ARIMA con Análisis de Intervención y Efectos de Calendario.

1.3.5.2.3. Verificación

Una vez estimado el modelo ARIMA, se debe comprobar si este cumple con las hipótesis planteadas inicialmente.

La principal prueba de adecuación, entre los datos y el modelo, es la de comprobar si los residuos ϵ_t forman un Ruido Blanco, dado que conociendo los parámetros de w_t se puede estimar la serie de residuos.

Sin embargo, no se deben descuidar otras pruebas tales como: el análisis de la bondad del ajuste del modelo estimado y el análisis de los parámetros del modelo (condiciones de estacionariedad e invertibilidad, significancia de los parámetros).



1.3.5.2.4. Predicción

Una vez identificado el proceso ARIMA que genera la serie temporal de interés, estimados los parámetros del modelo ARIMA correspondiente y haber pasado la etapa de verificación, se utiliza el modelo para realizar pronósticos, con el menor error de predicción posible.

1.3.6. Funciones de Autocorrelación y Autocorrelación Parcial: Teórica y Estimada

Dentro de la etapa de identificación de un proceso estacionario es de vital importancia el análisis de la función de autocorrelación estimada (FACE) y la función de autocorrelación parcial estimada (FACPE).

Dentro de la definición de las características de un proceso estacionario se mencionó a los coeficientes de autocorrelación ρ_τ , estos se los fija como teóricos dado que se los determina dentro del análisis exhaustivo de una población. Sin embargo cuando



sólo se realiza el estudio de una muestra es necesario hablar de coeficientes de autocorrelación estimados r_τ .

La representación gráfica de los coeficientes ρ_τ recibe el nombre de Correlograma (Función de Autocorrelación Teórica: FACT), mientras que la secuencia de los coeficientes de autocorrelación estimados r_τ constituye la Función de Autocorrelación Estimada (FACE) muy útil para identificar el proceso generador de la serie.

Por otra parte, la Función de Autocorrelación Parcial Teórica (FACPT) se basa en la representación gráfica de los coeficientes ϕ_i de un modelo AR (p) en base a los valores ρ_i . La FACPE es una estimación de la FACPT.

1.3.6.1. Función de Autocorrelación Estimada (FACE)

Una estimación de la FACT es la FACE.

Lo ideal es calcular a partir de una muestra de tamaño N de valores de una serie estacionaria w_t los coeficientes de

autocorrelación muestral de orden " τ ", a través del siguiente estimador:

$$r_{\tau} = \frac{\sum_{t=\tau+1}^N (w_t - \bar{w})(w_{t-\tau} - \bar{w})}{\sum_{t=1}^N (w_t - \bar{w})^2}$$

Pueden utilizarse otros estimadores para los coeficientes de autocorrelación, sin embargo el anteriormente mencionado es el que tiene menor sesgo.

La secuencia de valores de r_{τ} para $\tau = 1, 2, 3, \dots$ constituye el correlograma estimado o **FACE**. Nótese que a medida que crece el orden del retardo disminuye el número de sumandos del numerador de la fórmula propuesta para r_{τ} , esto hace que se pierda eficiencia en la estimación y por tanto no se recomienda calcular coeficientes de autocorrelación para tamaños superiores a un tercio o a un cuarto del tamaño de la muestra.

La FACE es muy útil para identificar si un proceso es generado a partir de un MA(q) dado que los coeficientes de autocorrelación teóricos son iguales a cero para $\tau > q$.

Así se hace necesario definir si los coeficientes de autocorrelación estimados son estadísticamente significativos, bajo el supuesto que $\rho_\tau = 0$ sigue asintóticamente una distribución normal con media 0. Entonces para que sean significativos distinto de cero, para un nivel de confianza del 95%, se debe verificar que

$$\left| \frac{r_\tau}{\sqrt{\text{Var}(r_\tau)}} \right| > 1.96$$

Otra forma de verificar esta propiedad es a través de las gráficas de Bandas de Confianza, donde se pueden definir los siguientes intervalos de confianza (95%) dado que r_τ tiene una distribución aproximadamente normal

$$\left(-1.96 \sqrt{\text{Var}(r_\tau)} , +1.96 \sqrt{\text{Var}(r_\tau)} \right)$$



Donde se define la varianza empírica de los coeficientes de autocorrelación de la siguiente manera, bajo el supuesto de que $\rho_k = 0 \quad \forall k \geq \tau$.

$$\text{Var}(r_\tau) \approx \frac{1}{N} \left(1 + 2 \sum_{k=1}^{\tau-1} r_k^2 \right)$$

Los coeficientes son estadísticamente significativos si caen fuera de la banda de confianza.

Conviene considerar que los coeficientes de autocorrelación están correlacionados entre sí (según fórmulas de varianza y covarianzas aproximadas por Barlett) y por tanto este tipo de relaciones pueden aparecer en la FACE en forma de ciertas ondulaciones que no corresponden al comportamiento teórico del modelo. Por lo tanto y en especial cuando los valores de los coeficientes de autocorrelación son elevados se puede esperar que la FACE converja a cero más lentamente que la FACT (Jenkins y Watts).

1.3.6.2. Función de Autocorrelación Parcial Teórica y Estimada

A diferencia de lo que ocurre con los procesos MA, en los AR de cualquier orden, la función de autocorrelación teórica (correlograma) empieza a decrecer a partir de un determinado retardo, pero nunca se hace cero. Debido a esto es difícil determinar con la ayuda de la FACT el orden de un proceso AR. Precisamente, ante esta dificultad, es que se utilizan los coeficientes de autocorrelación parcial. Por medio de las ecuaciones de Yule-Walker se pueden calcular los coeficientes de un proceso AR(p) " ϕ_i " a través de los coeficientes de autocorrelación " ρ_i ":

$$\begin{bmatrix} \phi_1 \\ \phi_2 \\ \cdot \\ \cdot \\ \phi_p \end{bmatrix} = \begin{bmatrix} 1 & \rho_1 & \dots & \rho_{p-1} \\ \rho_1 & 1 & \dots & \rho_{p-2} \\ \dots & \dots & \dots & \dots \\ \rho_{p-1} & \rho_{p-2} & \dots & 1 \end{bmatrix}^{-1} \begin{bmatrix} \rho_1 \\ \rho_2 \\ \dots \\ \rho_p \end{bmatrix}$$

La dificultad radica en que cuando se trabaja con series reales "a priori" se desconoce el valor de p.


Si el sistema anterior se resuelve sucesivamente para $AR(1)$, $AR(2)$, ... se obtienen los siguientes coeficientes

$$\begin{aligned} AR(1) & \quad \phi_{11} \\ AR(2) & \quad \phi_{21}, \phi_{22} \\ AR(3) & \quad \phi_{31}, \phi_{32}, \phi_{33} \\ & \dots \end{aligned}$$

$$\begin{aligned} AR(p) & \quad \phi_{p1}, \dots, \phi_{pp} \\ AR(p+1) & \quad \phi_{p+1,1}, \dots, \phi_{p+1,p}, \phi_{p+1,p+1} \end{aligned}$$

De estos resultados obtenidos se toma el último coeficiente de cada uno de los procesos $\phi_{11}, \phi_{22}, \dots, \phi_{pp}, \dots$. De esta manera se obtiene la **Función de Autocorrelación Parcial Teórica (FACPT)**.

Los coeficientes, bajo el supuesto de que p es el orden del proceso AR, serán distintos de cero para retardos iguales o inferiores a p , debido a que por hipótesis los coeficientes ϕ_1, ϕ_2, \dots y ϕ_p son distintos de cero. En cambio, para retardos superiores a p serán iguales a cero.



Por otro lado la FACPE se define como el instrumento empírico que se usa para estimar la FACPT y se puede calcular de tres maneras:

- Mediante las ecuaciones de Yule-Walker, procedimiento similar al antes explicado pero donde se utilizan los estimadores de los coeficientes de autocorrelación r_i en las matrices dispuestas

$$\hat{\phi}_{11} = r_1 \Rightarrow \hat{\phi}_{11}$$

$$\begin{bmatrix} \hat{\phi}_{21} \\ \hat{\phi}_{22} \end{bmatrix} = \begin{bmatrix} 1 & r_1 \\ r_1 & 1 \end{bmatrix}^{-1} \begin{pmatrix} r_1 \\ r_2 \end{pmatrix} \Rightarrow \hat{\phi}_{22}$$

$$\begin{bmatrix} \hat{\phi}_{31} \\ \hat{\phi}_{32} \\ \hat{\phi}_{33} \end{bmatrix} = \begin{bmatrix} 1 & r_1 & r_2 \\ r_1 & 1 & r_1 \\ r_2 & r_1 & 1 \end{bmatrix}^{-1} \begin{pmatrix} r_1 \\ r_2 \\ r_3 \end{pmatrix} \Rightarrow \hat{\phi}_{33}$$

.....

El inconveniente es demasiados cálculos para al final

encontrar solo un valor $\hat{\phi}_{ii}$ para $i = 1, 2, \dots, p$

- Procedimiento de Durban: es el método recursivo

$$\hat{\phi}_{kk} = \frac{r_k - \sum_{j=1}^{k-1} \hat{\phi}_{k-1,j} r_{k-j}}{1 - \sum_{j=1}^{k-1} \hat{\phi}_{k-1,j} r_j}$$

$$\hat{\phi}_{kj} = \hat{\phi}_{k-1,j} - \hat{\phi}_{kk} \hat{\phi}_{k-1,k-j} \quad j = 1, 2, \dots, k-1$$

El inconveniente de utilizar este método es que al ser recursivo acumula errores de redondeo.

- La última alternativa consiste en obtener los coeficientes mediante regresión

$$\hat{Y}_t = \hat{\phi}_{11} Y_{t-1}$$

$$\hat{Y}_t = \hat{\phi}_{21} Y_{t-1} + \hat{\phi}_{22} Y_{t-2}$$

$$\hat{Y}_t = \hat{\phi}_{k1} Y_{t-1} + \hat{\phi}_{k2} Y_{t-2} + \dots + \hat{\phi}_{kk} Y_{t-k}$$

Si se trata de un proceso AR(p) el coeficiente $\hat{\phi}_{kk}$ estará próximo a cero cuando $k > p$. Para $k \leq p$ el coeficiente $\hat{\phi}_{kk}$ tendrá valor significativamente distinto de cero, si el tamaño de la muestra es significativamente grande (mayor a 50 o 60 observaciones).

En un proceso AR(p), los coeficientes $\hat{\phi}_{kk}$ tienen una distribución normal con media cero y varianza:

$$\text{Var}\left(\hat{\phi}_{kk}\right) \approx \frac{1}{N} \quad k > p$$

GRÁFICO 1.4

De esta manera queda definida la Función de Autocorrelación Parcial Estimada (FACPE).

A continuación se muestra un cuadro resumen del comportamiento de los coeficientes en las funciones de autocorrelación:

TABLA 5
RESUMEN FUNCIONES DE AUTOCORRELACIÓN

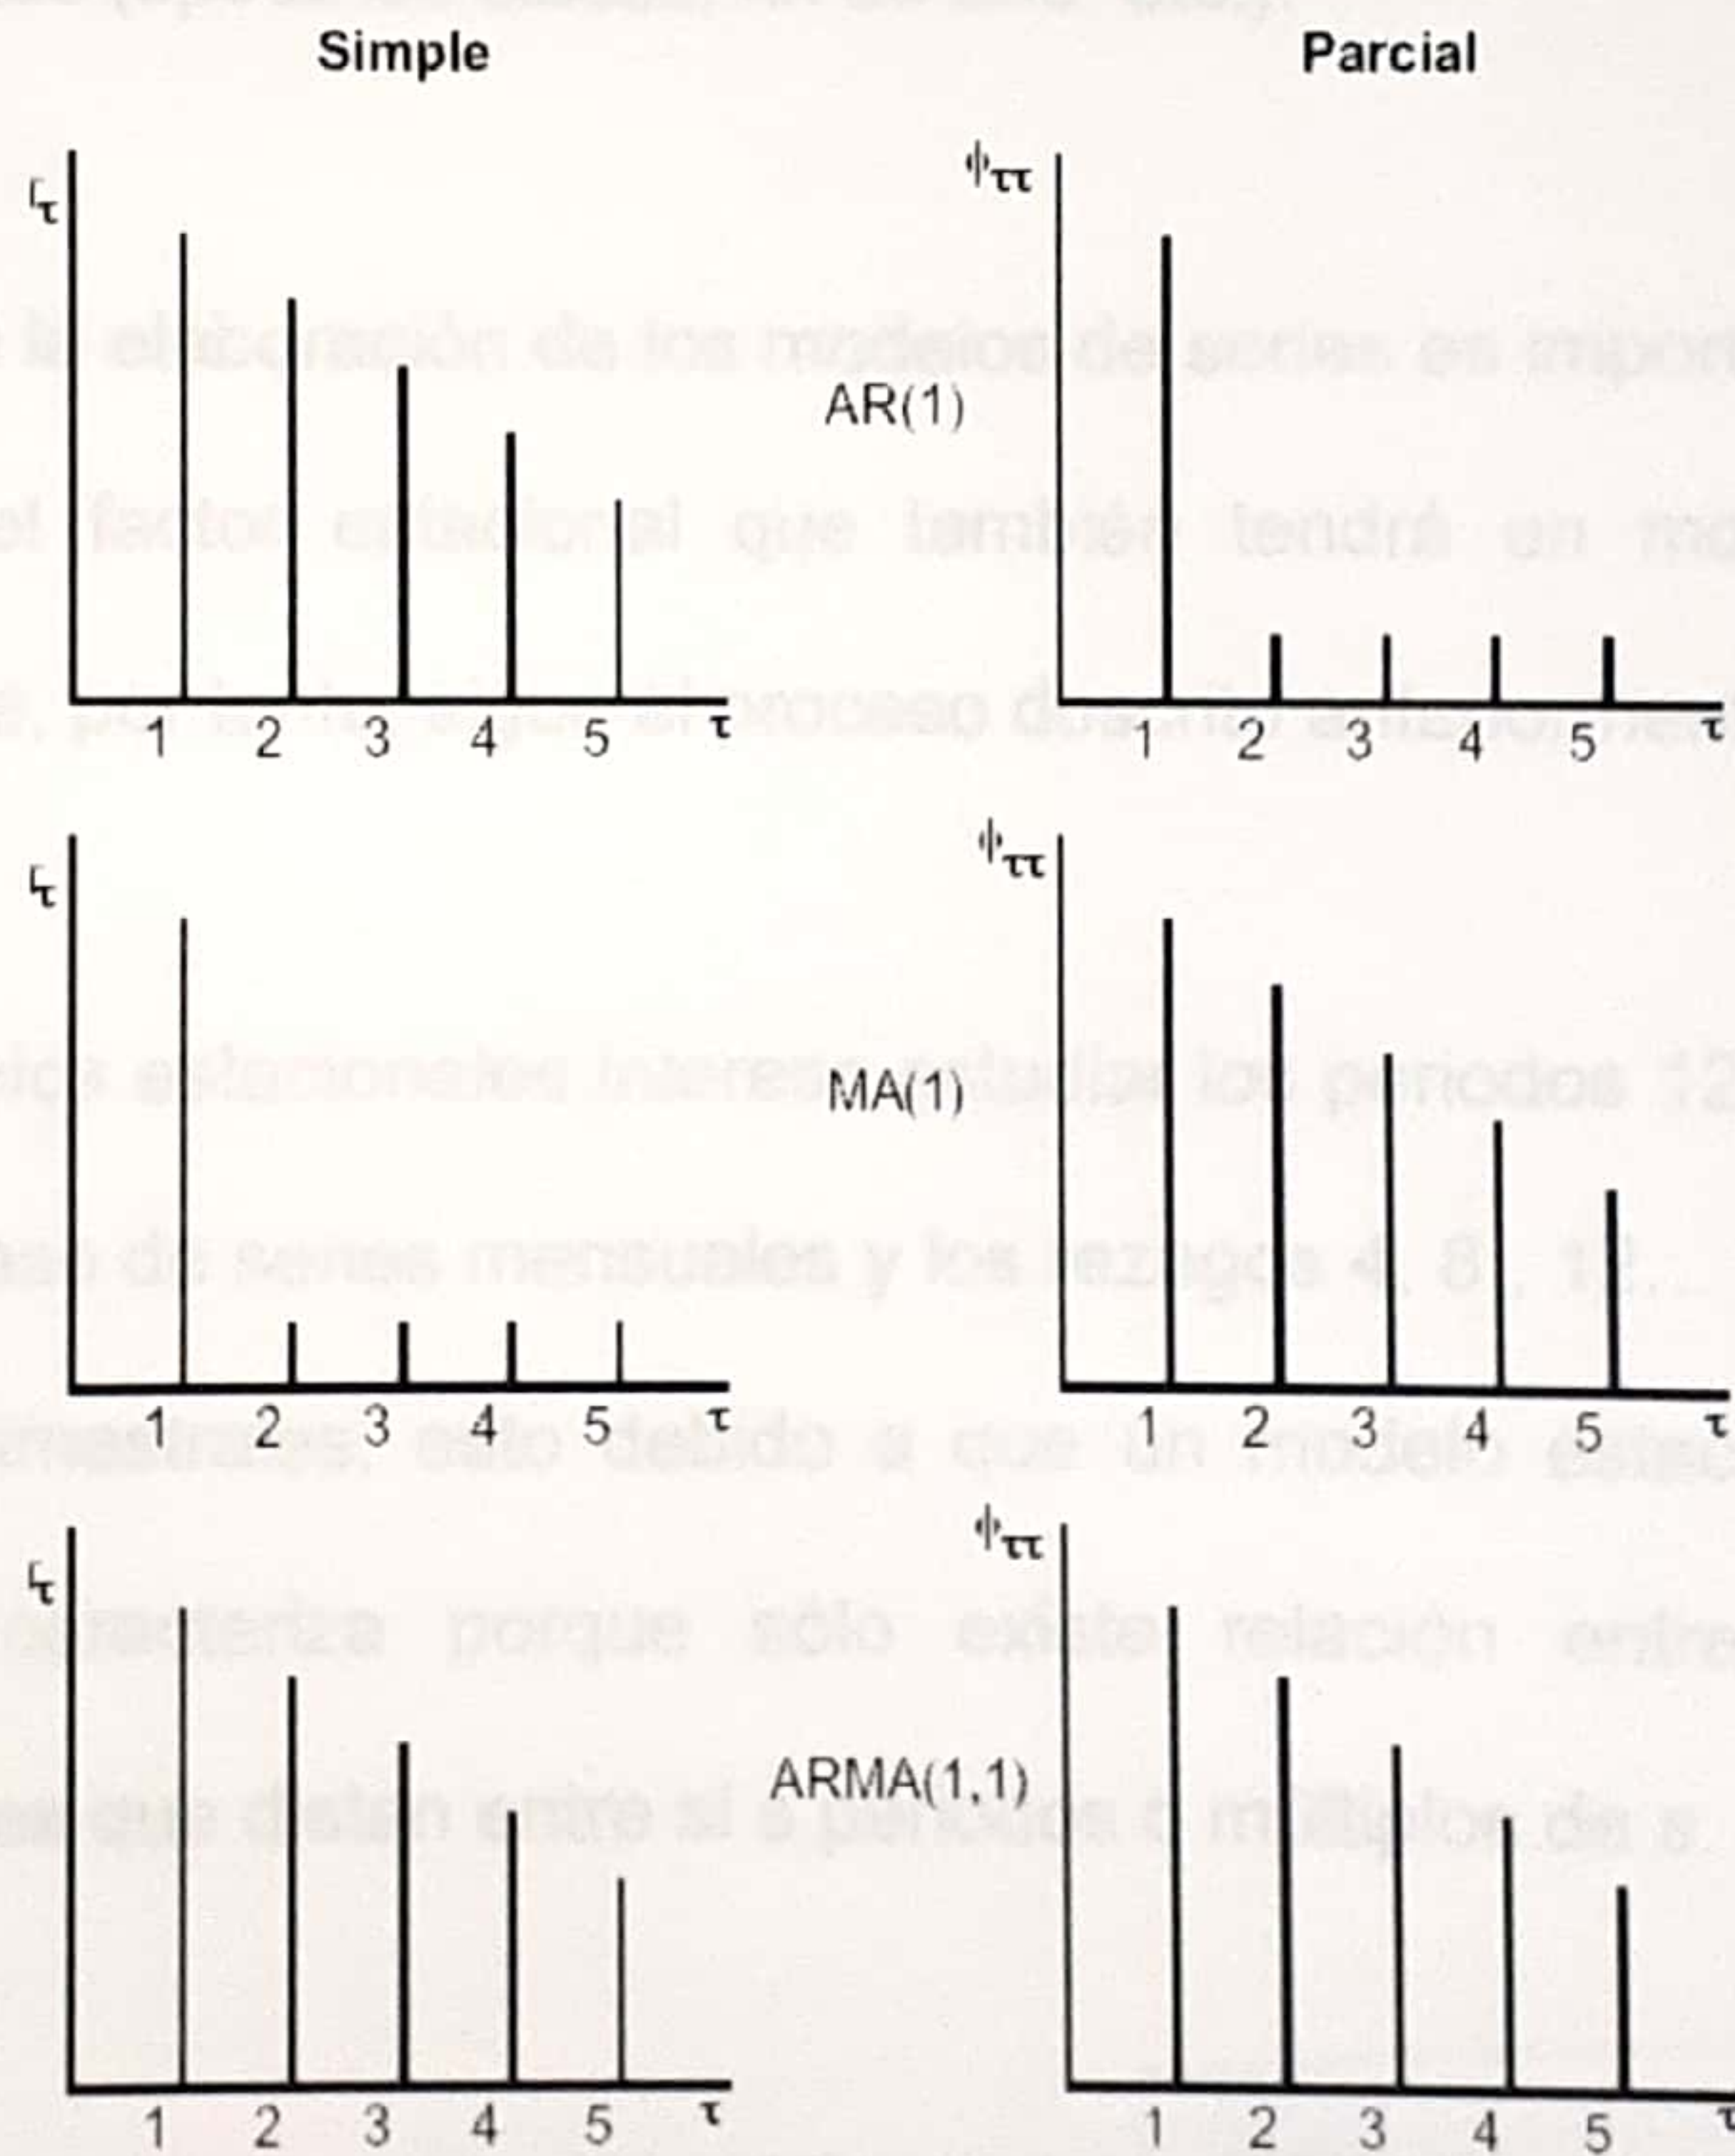
	N° de Barras		
	AR(p)	MA(q)	ARMA(p,q)
FACT	∞	q	∞
FACPT	p	∞	∞

Elaborado por: V. Vásquez

En el siguiente gráfico presenta, como guía, la forma general de los correlogramas simple y parcial (FACE y FACPE) para diferentes modelos autorregresivos y de medias móviles:

GRÁFICO 1.4

FUNCIONES DE AUTOCORRELACIÓN FACE Y FACPE




1.3.7. Modelos Estacionales: SARIMA

Todos los modelos de series temporales anteriormente citados corresponden a la parte regular del modelo ARIMA. Sin embargo, muchas de las series de tiempo presentan un elevado componente estacional, es decir tienen oscilaciones periódicas donde el periodo es igual o inferior a un año. Estas oscilaciones pueden atribuirse a diversas causas físicas (estaciones, épocas de lluvia, etc.) y sociales (época de clases, fin de año, etc.).

Entonces en la elaboración de los modelos de series es importante considerar el factor estacional que también tendrá un modelo ARIMA y que, por tanto, sigue el proceso descrito anteriormente.

En los modelos estacionales interesa estudiar los periodos 12, 24, 36,.. en el caso de series mensuales y los rezagos 4, 8, 12... para las series trimestrales, esto debido a que un modelo estacional teórico se caracteriza porque sólo existe relación entre las observaciones que distan entre sí s periodos o múltiplos de s .

A modo general la notación del modelo ARIMA con parte estacional es la siguiente:



SARIMA (p,d,q)(P,D,Q)_s

Donde:

p: Número de parámetros autorregresivos.

d: Número de diferenciaciones para que la serie sea estacionaria.

q: Número de parámetros de medias móviles.

P: Número de parámetros autorregresivos en la parte estacional.

D: Número de diferenciaciones para que la serie sea estacionaria, en la parte estacional.

Q: Número de parámetros de medias móviles en la parte estacional.

s: Periodicidad de serie (s=12 serie mensual, s=4 serie trimestral)

La forma de los modelos sARIMA es:

$$\phi(L)\Delta^d \Phi_s(L)\Delta_s^D Y_t = \theta(L)\Theta_s(L)\varepsilon_t$$

CAPITULO 2

2. MODELOS BASADOS EN LA EXTRACCIÓN DE LA SEÑAL.

2.1. Introducción

El proceso de extracción de señales tiene como propósito obtener series desestacionalizadas, esto con el fin de contar con información que permita estimar de manera correcta los movimientos intra-anales de las series y además tener un historial base para futuras predicciones y tomas de decisiones.

Inicialmente la extracción de señales de una serie consistía en la eliminación de su componente estacional; sin embargo, debido a los avances en el área de la estadística y la informática actualmente a través de este proceso se pueden aislar otros componentes que ocasionan ruido dentro de la serie, por ejemplo: efecto de feriados



móviles (semana santa), efecto por días de trabajo (o hábiles) y componente irregular. De esta manera, la desestacionalización se convierte en un concepto más amplio donde como resultado se obtendrá una señal más clara de la tendencia y por lo tanto una interpretación más confiable y oportuna. Esta es una de las principales razones por las que la extracción de señales de una serie de tiempo se ha difundido ampliamente, es necesario entender la situación presente para luego ajustar los pronósticos.

Este tipo de análisis es muy aplicado, especialmente en el área económica, debido a la necesidad de realizar análisis trimestrales o anuales de series y además estudiar los ciclos económicos que acontecen en la actividad económica de un país. Estas investigaciones no se pueden llevar a cabo si la componente estacional no ha sido identificada y estimada, pues las variaciones intra-anales no proveen indicaciones precisas del movimiento de las componentes tendencia y ciclo en el corto plazo.

Con este propósito, la extracción de señales de series económicas se ha convertido en una práctica casi universal y miles de series temporales son procesadas de esta forma frecuentemente. Tanto los analistas como los investigadores económicos hacen un amplio uso de

series desestacionalizadas, con la certeza de que esto facilita la interpretación y la construcción de modelos.

2.2. Análisis de Intervención

Existen modelos ARIMA con variables de intervención, en los cuales las series económicas son afectadas por fenómenos externos, tales como cambios tecnológicos, huelgas, cambios en medidas políticas o económicas, cambios en la legislación o escala de algún impuesto, cambios metodológicos en la medición de las estadísticas, etc. Estos fenómenos son llamados intervenciones debido a que interfieren en el comportamiento original de la serie, y por lo tanto se debe evaluar su efecto e incorporarlo al modelo ARIMA a través de variables artificiales binarias (análisis de intervención).

Se recurre a variables que explican la presencia de fenómenos exógenos en la serie de tiempo. Se incorporan como variables dummy en la forma de impulsos y escalones que se utilizan para representar cambios temporales o permanentes en el nivel de las series debidos a eventos especiales, estas variables por lo general toman valores de

cero o uno. Adicionalmente existen los Efectos Calendario, Efecto de Semana Santa o Pascua y Días de Comercio.

Desde el punto de vista estadístico estos componentes son de naturaleza determinística, en el sentido de que no pueden ser aproximados por un modelo probabilístico porque su ocurrencia no obedece a la naturaleza propia del fenómeno sino a eventos, que seguramente, no se repetirán de igual forma en el futuro.

La mayoría de veces a primera instancia no se conocen los fenómenos exógenos que afectan la serie de tiempo y más bien se utiliza una primera aproximación del modelo ARIMA para determinar la presencia de valores extraños (outliers) que son posteriormente incorporados al modelo. La no-incorporación de variables artificiales conduce a sesgos en las estimaciones de los parámetros, a elevar el error estándar residual y a errores en la especificación del modelo ARIMA.


A continuación se describen las principales variables de intervención:

- **Variables Impulso:** Recoge el efecto de fenómenos que intervienen en la serie en un único momento T_0 . Esto se traduce

en una variable que contiene un uno en T_0 y ceros en el resto. Afecta el componente irregular de la serie.

GRÁFICO 2.1


VARIABLE IMPULSO



- **Variable Escalón:** Recoge el efecto de un cambio en el nivel en la serie, es decir, que contiene ceros hasta el momento T_0 y unos en adelante. Afecta el componente tendencia de la serie.

GRÁFICO 2.2


VARIABLE ESCALÓN



- **Variable Tendencia o rampa:** Estas contienen ceros en un tramo de la serie hasta un momento T_0 , a partir del cual empieza a crecer en forma ascendente. Afecta la tendencia de la serie.

GRÁFICO 2.3

VARIABLE TENDENCIA



- **Efecto Calendario:** Este efecto se refiere al hecho de que cabe esperar un mayor nivel de actividad en aquellos meses con mayor número de días laborales, por lo cual hay que tomar en cuenta no solo el número de días de cada mes, sino también su diferente composición porcentual en términos de lunes, martes, etc., en cada mes.
- **Efecto de la Semana Santa o Pascua (Easter Effect):** Con este efecto se intenta representar la influencia que la festividad



móvil de semana santa ejerce sobre la actividad económica en los meses de marzo y abril.

- **Días de comercio (Trading-Days):** Consiste en el ciclo semanal que se presenta cuando los días de la semana tienen un nivel de actividad distinto, unido a la distinta longitud de los meses; de tal modo que por ejemplo, un mes en particular podría tener un nivel de ventas superior a otro, debido a que posee un mayor número de días.

De esta manera el modelo de la serie se representa por una parte determinística D_t y otra estocástica o aleatoria N_t .

$$Y_t = D_t + N_t$$

donde t denota al tiempo, $t = 1, 2, 3, \dots$

Las intervenciones se incluyen en la parte determinística de la serie y el modelo ARIMA en la parte estocástica. La idea principal es detectar, estimar y posteriormente eliminar los valores deterministas de la serie para luego proceder a una correcta estimación del modelo ARIMA que



se ajuste a la serie de datos. El proceso de descomposición de la serie se realiza sobre el modelo ARIMA finalmente estimado.

2.3. Componentes de una Serie de Tiempo

El propósito del ajuste estacional es aislar los componentes de una serie de tiempo.

En general una serie de tiempo, en su parte estocástica, se puede descomponer en cuatro componentes que no son directamente observables y de los cuales únicamente se pueden obtener estimaciones a partir de datos históricos.

Estos cuatro componentes son:

1. **Tendencia (T):** representa los movimientos de larga duración de la serie, también se le conoce como evolución subyacente de una serie. La tendencia representa una variación regular y gradual durante un largo período de años (por lo general superior a 32 trimestres u 8 años), a través de los cuales se logra observar la

dirección del movimiento de la serie el cual puede ser creciente o decreciente.

En consecuencia, se considerará tendencia aquellas oscilaciones cuya frecuencia (w), expresada en radianes, se encuentre comprendida entre 0 y $2\pi/32$ (período superior a ocho años). Cabe destacar que dentro de esta banda, el límite inferior, $w=0$ corresponde a oscilaciones de período infinito. Este elemento se denomina "tendencia pura o absoluta".

El componente tendencia de una serie suele asociarse con los determinantes del crecimiento económico.

2. **Ciclo (C):** caracterizado por oscilaciones regulares (sin discontinuidades ni fluctuaciones erráticas) de la serie alrededor de la tendencia con una duración aproximada de dos a ocho años. El ciclo, al igual que la tendencia, es un componente de baja frecuencia, pero originado por factores diferentes, entre los que predominan los aspectos de corto plazo o ajuste hacia las vías de crecimiento económico. Por lo general, esta clase de movimientos pueden ser caracterizados como respuesta de los



agentes económicos a shocks exógenos de diferente naturaleza, considerando como instrumentos precios o cantidades.

Por lo tanto se considerará ciclo aquellas oscilaciones cuya frecuencia, en radianes, se encuentre en el rango de $2\pi/32 \leq w \leq 2\pi/8$ (periodo comprendido entre 2 y 8 años)

Es importante señalar que en la práctica es difícil estimar las componentes de tendencia y ciclo de manera separada, debido a la cortedad de la mayoría de las series macroeconómicas y a la complejidad del diseño de los Filtros desarrollados para estimar de forma excluyente estos componentes (Baxter-King y Hodrick-Prescott).

Por otro lado, desde un punto de vista teórico, se admite que muchos de los factores que afectan la tendencia son responsables también del comportamiento cíclico, de forma que no es conveniente imponer una diferenciación excesivamente estricta.

Así se logra definir un solo componente denominado tendencia-ciclo (c_t) que se caracteriza por periodos alternados de

expansión y recesión que generalmente duran entre tres y siete años, a estos periodos se los denomina fase y su duración e intensidad varía en cada ocasión.

3. **Estacionalidad (s_t):** son los movimientos intra-anales (mensuales, trimestrales, etc.) que se repiten año tras año.

Las principales causas que producen una estacionalidad dentro de una serie de tiempo pueden ser climáticas, institucionales (Navidad, cierre fiscal) e inducidas (producción de juguetes en septiembre y octubre) que evolucionan de forma suave desde una perspectiva de largo plazo.

Usualmente, dada la constancia a corto plazo de los mencionados factores, no es el componente más relevante para el análisis de la coyuntura, aunque puede dirigir sobre aspectos estructurales.

Así pues, se denominará estacionalidad a la oscilación cuya frecuencia, en radianes, es $\pi/2$ (período de un año) y su armónico π (período de dos trimestres).

Por conformidad, la estacionalidad se anula cada año y como resultado de ello las series anuales no pueden contener estacionalidad, sin embargo si existe una evolución que se atribuye a factores tecnológicos, institucionales y de cambio en la composición de la serie.

4. **Irregularidad (i_t):** son movimientos erráticos y residuales de la serie que no siguen un patrón específico y que por lo tanto distorsionan la relación lineal entre la serie observada y sus componentes estructurales (estacionalidad y tendencia-ciclo).

La irregularidad en una serie obedece a causas diversas y por ello es prácticamente impredecible, algunos de estos factores son: acontecimientos inusuales (huelgas, sequías, desbordamiento de ríos), errores de medición de la serie (errores de muestreo, falta de respuesta, tratamiento de datos), errores en la toma de decisiones (variaciones en el mercado bursátil), entre otros.

Además cabe citar algunos determinantes de la irregularidad de las series, estos son:

- **Naturaleza de la variable:** algunas variables son esencialmente volátiles, como las exportaciones; mientras que otras se comportan de manera regular, como la población.
- **Nivel de agregación de la serie:** para una variable dada, las series nacionales tienden a ser menos irregulares que las provinciales.
- **Frecuencia de la serie:** las series anuales son generalmente menos irregulares que las series trimestrales y mensuales.
- **Fiabilidad de la fuente de datos:** las series provenientes de una encuesta son más erráticas que las series que se originan en censos o en fuentes administrativas; las series basadas en modelos son por lo general más regulares, por construcción.


Por consiguiente, se define la irregularidad de una serie como aquellos movimientos de frecuencia estrictamente inferior a $\pi/2$, excluyendo el armónico estacional asociado a la frecuencia π .

A estos cuatro componentes no observables se les suman los componentes de días laborales y Feriados Móviles (anteriormente citados en el Análisis de Intervenciones para su detección) que son totalmente deterministas.

5. **Componente de días laborales (r_t):** Es el efecto creado por la diferente distribución de los días de la semana que cambia de acuerdo al mes y está presente cuando los días de la semana tienen distintos niveles de actividad e importancia relativa. Las tasas diarias permiten controlar la proporción de la actividad semanal que ocurre en cada día de la semana.

6. **Componente de Feriados Móviles (h_t):** El efecto de feriados de fecha móvil que corresponde a las variaciones debidas a que algunos feriados cambian de fecha de año a año, lo cual desplaza la actividad de un mes a otro. El caso más evidente es el Feriado de Semana Santa.

La Pascua de Resurrección tiene dos efectos sobre la actividad económica de los meses de marzo y abril: el primero es el inmediato que afecta la actividad en los dos días feriados correspondientes a la Pascua y el segundo es el efecto gradual



donde la actividad afecta en días previos a la celebración del Feriado (movimiento de los viajeros por ejemplo).

En el campo de la economía se ha encontrado que la detección de los componentes observables y no observables de una serie de tiempo añade valor a los análisis que de ella se efectúen. El conocimiento de las variaciones del componente estacional que se han presentado a través del tiempo, resulta de mucha utilidad para conocer si las variaciones actuales de una serie de tiempo se deben a un aumento (o disminución) del nivel medio de la serie o realmente al efecto del fenómeno estacional. Así mismo, el análisis de la tendencia resulta fundamental para evaluar el crecimiento subyacente de una serie económica, aislado de otros movimientos erráticos o sistemáticos. En cuanto al fenómeno irregular, puede muchas veces resultar muy útil en la evaluación de aquellos fenómenos exógenos que habrían afectado a la serie de tiempo y en la estimación de la magnitud del impacto.

Específicamente si se habla del sector real una economía, una de las principales características de las series temporales es que presentan un comportamiento de largo plazo, generalmente de crecimiento (tendencia). Además de este componente las series económicas presentan fluctuaciones de mediano plazo alrededor de la tendencia

(ciclos). Los ciclos económicos consisten por tanto en expansiones de la actividad económica seguidas por recesiones que culminan con contracciones, para volver a empezar una nueva fase de expansión, lo que resulta de gran importancia en la determinación del panorama económico y por tanto de la política económica.

A continuación se describen los diferentes modelos.

Además del comportamiento de mediano y largo plazo, las series económicas presentan por lo general una conducta sistemática dentro de cada año (componente estacional). Así por ejemplo, la actividad comercial presenta una marcada estacionalidad alcanzado la mayor actividad en el mes de Diciembre de cada año. También, las series económicas presentan un componente de carácter completamente impredecible o aleatorio (componente irregular). La detección de este componente es clave para la validación del modelo, este término no debe contener información de la serie puesto que esto permitiría definir como no válida la interpretación de los otros componentes. En general y en términos estadísticos se debe conseguir que el componente irregular resultante de la aplicación del modelo de descomposición presente todas las características de un Ruido Blanco, esto permitirá reconocer la validación del modelo aplicado.

De esta manera se ha descrito de manera explicativa la relación entre los diferentes componentes de una serie, sin embargo para poder determinar la etapa del ciclo económico en la que se encuentra una actividad particular es necesario aislar sus componentes.

A conseguir este objetivo se encaminan los diferentes modelos desarrollados para la extracción de señales (componentes). El aislar el componente tendencia-ciclo del estacional e irregular muestra de una mejor forma la evolución de la variable, sin embargo, en otros estudios es más adecuado utilizar la serie desestacionalizada ya que tiene un menor error de revisión. La revisión consiste en que cada vez que se actualiza la serie, los componentes se modifican varios periodos hacia atrás. Cuanto más cambian mayor es el error de revisión.

2.4. Modelos de Descomposición

Para poder mostrar de manera explícita la relación existente entre los diferentes componentes de una serie de tiempo existen dos modelos básicos:



1. **Modelo Aditivo:** se utiliza cuando los componentes de la serie son independientes entre sí, esto significa que cada componente evoluciona en forma independiente con respecto a los demás.

Así por ejemplo, la amplitud de la estacionalidad es independiente del nivel de tendencia-ciclo, por lo que un aumento en el nivel de la tendencia-ciclo no ocasiona un aumento en la amplitud estacional.

Además también se recomienda utilizar este modelo cuando se presentan valores negativos o ceros dentro de la serie.

$$Y_t = c_t + s_t + r_t + h_t + i_t$$

Las componentes están expresadas en unidades. En el caso de la serie desestacionalizada (o ajustada) se tiene la siguiente expresión:

$$Y_t^{\text{des}} = Y_t - s_t - r_t - h_t = c_t + i_t$$

2. **Modelo Multiplicativo:** se utiliza cuando los componentes son dependientes entre sí o cuando el nivel de las series es muy

cambiante. Es decir a través de este modelo se puede captar el aumento o disminución de la amplitud estacional debido al aumento o disminución del nivel tendencia- ciclo.

$$Y_t = c_t \times s_t \times r_t \times h_t \times i_t$$

Las componentes estacional, irregular, variaciones de días laborables y el efecto de Pascua se expresan en porcentaje.

En este modelo, la serie desestacionalizada (o ajustada) se obtiene por medio de un cociente:

$$Y_t^{\text{des}} = \frac{Y_t}{s_t \times r_t \times h_t} = c_t \times i_t$$

Entonces se tiene que si la amplitud del componente estacional varía en forma proporcional a la tendencia media anual, el modelo apropiado será el multiplicativo; y, por otro lado, si el componente estacional permanece constante ante variaciones en la tendencia, el modelo más adecuado es el aditivo, es decir la estacionalidad de la serie es independiente de su tendencia.

2.3 En general la mayoría de las series de tiempo económicas siguen un modelo multiplicativo y es claro que el modelo multiplicativo puede ser transformado en aditivo, tomando logaritmos.

El modelo de descomposición suele determinar la necesidad de transformación de la serie original. Si el modelo adecuado es el multiplicativo, entonces se tiende a considerar necesario aplicar una transformación logarítmica; en caso de que el modelo apropiado sea el aditivo entonces se suele utilizar la serie sin transformaciones.

La aplicación del modelo correcto es particularmente importante en series que han sufrido cambios significativos de tendencia-ciclo, ya que el ajuste estacional utilizando un modelo no apropiado puede llevar no sólo a una sobre o sub-estimación del componente estacional, sino también a la no detección o aparición de falsos puntos de retorno ("turning points") en la tendencia-ciclo (Huot y Gait, 1985).

Los modelos aditivos y multiplicativos están disponibles en aplicaciones computacionales.

2.5. Desestacionalización de Series de Tiempo


La desestacionalización de una serie consiste en la combinación de dos de sus componentes originales: tendencia-ciclo e irregular. Es decir la desestacionalización de una serie se da cuando a la serie original se la ha descompuesto y privado de la componente estacional, las variaciones por días laborables y los feriados de fecha móvil.

El propósito fundamental de la desestacionalización es suprimir las fluctuaciones intra-anales sistemáticas para revelar los movimientos subyacentes de la tendencia-ciclo.

La importancia de desestacionalizar una serie radica en que de esta manera el analista económico puede realizar comparaciones entre meses consecutivos o no consecutivos y realizar inferencias que resulten válidas.

- **Comparaciones mes a mes:** resultan inválidas en series con estacionalidad o con variaciones de días laborables significativas.

- **Comparaciones con el mismo mes del año anterior:** estas comparaciones no son válidas cuando el efecto de estacionalidad



y de días laborables está presente en la serie. Por ello no resulta adecuada la inferencia que se realice acerca de la evolución de la serie en el último año, que por lo general es el periodo más importante para el análisis de coyuntura.


2.5.1. Métodos de Desestacionalización de Series

Existen dos métodos para realizar la desestacionalización de series: el directo y el indirecto.

Cuando se tiene una variable compuesta por diferentes partes surge la pregunta si es mejor desestacionalizar la serie por el método directo o el indirecto.

El *método de desestacionalización indirecto* consiste en desestacionalizar cada uno de los componentes y luego agregarlos de acuerdo con algún criterio preestablecido; mientras que con el método directo se desestacionaliza la serie totalmente.

Es decir, a través del método indirecto se genera la serie desestacionalizada total que es exactamente igual a la suma de sus componentes desestacionalizados, mientras que con el



método directo no necesariamente la suma de las componentes desestacionalizadas coincide con el total desestacionalizado.

La desestacionalización directa presenta las siguientes ventajas:

a favor:

- Desde el punto de vista operativo, es más rápido y menos costoso.
- Es posible que exista un efecto de cancelación entre los movimientos intra-anales de los componentes estacionales de las partes, sobre todo cuando en algunas de las partes se presentan cambios frecuentes.
- No queda estacionalidad residual pues ésta se corrige cambiando la longitud de las medias móviles.
- Provee los datos desestacionalizados sin importar si las partes están actualizadas o no a la misma fecha.

Del método directo la principal desventaja es que la suma de las

- Si en alguno de los componentes no se detecta estacionalidad, el método indirecto incorpora las series en términos originales; este hecho se convierte en una

desventaja de ese método y una ventaja si se utiliza el directo.

Por otro lado, el *método indirecto* tiene los siguientes argumentos a favor:

- Genera una serie desestacionalizada total que es exactamente la suma de sus componentes desestacionalizadas.
- Provee una herramienta analítica que es la de atribuir los cambios en la variable, a las variaciones en los respectivos componentes.
- Permite el ajuste estacional a un nivel de desagregación, donde la estacionalidad está mejor identificada y muestra un patrón relativamente más simple.

Del método directo la principal desventaja es que la suma de las componentes desestacionalizadas no coincide con el del total desestacionalizado, mientras que la desventaja que presenta el

método indirecto es que en algunas ocasiones la serie desestacionalizada puede contener estacionalidad residual.

Para escoger entre ambos métodos, es recomendable seleccionar el que produzca una serie más suave o menos irregular. Existe un indicador (incorporado en el Método X11-ARIMA) del grado de suavidad " R_1 " basado en el error cuadrático medio, el cual se refiere a la suma de cuadrados de las primeras diferencias de la serie desestacionalizada. Esto es:


$$R_1 = \frac{\sum (w_t - w_{t-1})^2}{n}$$

Donde,

w_t : serie desestacionalizada ya sea con el método directo o con el indirecto

n : número de observaciones

Al comparar los resultados de las diferentes series desestacionalizadas aplicando ambos métodos, la que posea el menor valor de R_1 corresponde a la serie w_t más suave o menos errática. También, es usual presentar estos mismos resultados



como raíces cuadradas (raíz del error cuadrático medio), los cuales se interpretan de igual manera.

Adicionalmente, se calcula el cambio porcentual entre los resultados de ambos métodos de la siguiente manera:

$$R_1 = \frac{R_1(\text{directo}) - R_1(\text{indirecto})}{R_1(\text{directo})} \times 100$$

Los cambios porcentuales positivos indican que la serie desestacionalizada que brinda el método indirecto es más suave que el directo, en el caso contrario, la serie desestacionalizada que produce el método directo es más suave que el indirecto.

Además del indicador R_1 , el X11-ARIMA incorpora una segunda medida de suavidad R_2 basada en el Filtro de Henderson utilizado para aislar el componente tendencia-ciclo de la serie de datos. Este indicador tiene igual interpretación que el R_1 antes explicado.

2.6. Métodos de Extracción de Señales

El proceso de descomposición de series de tiempo en sus cuatro componentes se conoce también como extracción de señales. Para este fin, se cuenta con diversos grupos de métodos que son utilizados rutinariamente por instituciones académicas, centros de investigación, institutos de estadística, bancos centrales, empresas privadas, agencias gubernamentales, entre otros.

1. **Métodos Empíricos (no paramétricos):** se basan en promedios móviles (filtros) para lograr la descomposición de la serie en sus cuatro principales componentes. El objetivo de utilizar promedios móviles es remover o reducir la fuerza con que ciertos ciclos afectan a las series de datos, a través de la sucesiva aplicación de filtros hasta lograr una serie más suave.

Estos métodos aunque son capaces de extraer características comunes de una gran cantidad de series, no tienen un modelo definido para sus componentes y por tanto se limita la capacidad de análisis y de diagnóstico de los resultados.

La principal desventaja de este tipo de métodos radica en que las componentes estimadas sufren modificaciones cada vez que un nuevo dato se incorpora a la serie original.

Los principales métodos basados en promedios móviles son:

- **Familia X11:** versiones Census I y Census II, desarrollado por la Oficina del Censo de los Estados Unidos: U.S. Bureau of the Census
- **X11-ARIMA (1980):** de la Agencia de Estadísticas de Canadá: Statistics Canada
- **X12-ARIMA (1996):** del U.S. Bureau of the Census, basado en X11-ARIMA de Statistics Canada

La principal diferencia en resultados entre los métodos de la familia X11 radica en las técnicas que se utilicen para tratar los datos finales de la serie temporal, esto es, si se utilizan filtros simétricos, asimétricos o en su defecto primero se extrapolan las series y luego se aplican filtros simétricos sobre las series extendidas.

2. **Métodos basados en Modelos (paramétricos):** suponen que la señal de la serie sigue un modelo ARIMA. Estos métodos utilizan estimadores que son variables aleatorias con todas sus propiedades y bandas de confianza. La principal ventaja radica en que procuran adaptarse a las características estocásticas de la serie evitando el riesgo de añadir a las estimaciones propiedades falseadas debido a uso de filtros inapropiados.

Estos métodos permiten efectuar un diagnóstico amplio de las estimaciones y esta característica es precisamente la que los hace superiores. Entre otras cosas permiten definir con qué error se estima la estacionalidad y la tendencia-ciclo; además de conocer cuáles son los intervalos de confianza de los factores estacionales.

Los métodos mencionados a continuación son los más importantes desarrollados dentro la metodología basada en modelos:

- **TRAMO-SEATS (1998):** de Agustín Maravall y Victor Gómez, recomendado y adoptado por Eurostat.



- **STAMP (Harvey 1989):** Métodos basados en modelos estructurales que asumen un modelo estocástico para cada componente

Sin embargo, de todos los modelos presentados los más difundidos y utilizados son: el método basado en promedios móviles X12-ARIMA y el método basado en modelos TRAMO-SEATS. En el capítulo tres del presente trabajo se hará hincapié en la metodología X12-ARIMA.

Finalmente es de añadir que existen diferentes programas computacionales para el desarrollo de los métodos de extracción de señales, entre los cuales destacan:

- **DEMETRA** en versión 2.0 desarrollado por EUROSTAT, que ofrece una interface de usuario para los dos principales métodos de ajuste estacional: X12-ARIMA Y TRAMO-SEATS. Este programa es muy utilizado en la Unión Europea.
- El sistema desarrollado por U.S. Bureau of the Census para la aplicación del X12-ARIMA. Este software es utilizado por las Agencias Gubernamentales de Estados Unidos y otros países,

así como empresas privadas; a pesar de que se encuentra bajo un ambiente DOS de trabajo.

2.6.1. Medias Móviles

Las medias o promedios móviles proveen de un método simple para suavizar (reducir la amplitud de las oscilaciones) una serie, la que se considera pasa por un grupo de filtros hasta lograr una mayor regularidad. Las medias móviles son una herramienta fundamental en la estimación de los componentes de una serie a través del programa X11-ARIMA.

EL procedimiento básico para aplicar promedios móviles a una serie temporal consiste en definir un grupo de pesos de longitud $m_1 + m_2 + 1$, así:

$$W_{-m_1}, W_{-(m_1-1)}, \dots, W_{-1}, W_0, W_1, \dots, W_{m_2-1}, W_{m_2}$$

Donde un grupo simétrico de pesos tiene $m_1 = m_2$ y por tanto $w_j = w_{-j}$.



De esta manera un valor filtrado en el tiempo t puede ser calculado por:

$$z_t = \sum_{j=m_1}^{m_2} w_j y_{t+j}$$

Donde y_t describe el valor de la serie original en el tiempo t .

Por ejemplo si se tiene el grupos de datos 10, 12, 8, 10, 12, 14, 6, 10 y se aplica un simple filtro simétrico de 3 términos ($m_1=m_2=1$ y todos los pesos son $1/3$), el primer término de la serie alisada será:

$$\frac{1}{3} * 10 + \frac{1}{3} * 12 + \frac{1}{3} * 8 = 10$$

Aplicando el filtro sucesivamente se obtiene la siguiente serie alisada: 10, 10, 10, 12, 10.3, 10.


Nótese la reducción de términos, la serie original tiene 8 términos y la serie obtenida 6. Esto se debe a la insuficiencia de datos al final de la serie para aplicar el filtro simétrico. Por esta razón los filtros anotados no pueden utilizarse en los últimos datos de la

serie y se recomienda en este caso usar filtros asimétricos para calcular una estimación regular en esta área. Los filtros asimétricos calculan el promedio añadiendo más datos de un lado que del otro según lo consideren conveniente. Alternativamente, se puede usar alguna técnica estadística para extrapolar la serie y posteriormente aplicar filtros simétricos sobre la serie extendida.

2.5.2 Todo este proceso es implementado en los diferentes programas desarrollados para extraer las señales de una serie a través de promedios móviles, incluso algunos softwares traen definidos ciertos promedios móviles (los de Henderson por ejemplo), que tienen formas particulares de analizar las series de tiempo pero el objetivo que persiguen es el mismo.

En general, las medias móviles poseen cierto tipo de propiedades, entre las cuales se anotan:

- Pueden reproducir polinomios localmente: ciertas medias móviles son equivalentes a estimar localmente una recta o una parábola.



- Ciertas medias móviles eliminan la estacionalidad.
- Reducen el "ruido" de la serie, es decir las fluctuaciones irregulares (suavizado): cuanto más larga la media móvil más reduce la irregularidad presente en la serie, cuanto menos flexible sea la media móvil (recta vs. parábola) menor será la reducción del ruido.

2.6.2. Familia de los Modelos X11

Los métodos de ajuste estacional basados en promedios móviles generalmente son conocidos como los métodos del estilo X11 y son basados en el procedimiento de promedios móviles descrito en 1931 por Fredrick R. Macaulay, del National Bureau of Economic Research de los Estados Unidos.

En general la forma en la que operan los métodos X11 es la siguiente:

1. Estiman la tendencia a través de los promedios móviles.

2. Remueven la tendencia de la serie original, dejándola definida en términos de los componentes estacional e irregular.
3. Estima el componente estacional usando promedios móviles, dejando fuera al componente irregular.

La estacionalidad generalmente no puede identificarse hasta que la tendencia sea conocida, sin embargo una buena estimación de la tendencia no puede hacerse hasta que la serie haya sido desestacionalizada. Por consiguiente, los modelos X11 usan un acercamiento reiterativo para estimar los componentes de una serie de tiempo.

2.6.2.1. Modelo X11 (Census I y II)

El método X11 del U.S. Bureau of the Census fue desarrollado en 1967 como la automatización de un método manual basado en medias móviles (MA).




El X11 versión Census I ajusta los datos estacionalmente y posteriormente calcula el resto de componentes de la serie. El programa X11 versión Census II constituye una extensión y refinamiento del Census I, esta última versión contiene muchas ventajas sobre el análisis de los componentes de una serie de tiempo, siendo las principales: ajuste por efecto días de trabajo y efecto pascua, estimación del componente irregular, eliminación parcial o total de valores extremos y suavizamientos múltiples.

En términos generales el X11 Census II efectúa el siguiente procedimiento:

1. Estimación de una media móvil centrada que elimina la Estacionalidad
2. La diferencia o el cociente (modelo aditivo o multiplicativo) de la serie observada y la suavizada (en el paso 1) aísla el componente estacional

3. El componente estacional es entonces calculado como el promedio de cada observación en la estación.
4. La serie ajustada estacionalmente se obtiene restando (o dividiendo) el componente estacional obtenido en el paso tres a la serie original
5. La tendencia-ciclo se obtiene aplicando promedios móviles centrados y ponderados (mayor ponderación en el centro y ponderación decreciente conforme se aproxima a los extremos) en forma sucesiva a la serie ajustada por estacionalidad
6. El componente irregular puede ser aislado restando (o dividiendo) el componente de tendencia-ciclo de la serie ajustada por estacionalidad
7. Adicionalmente el X11 ajusta la serie por el efecto días de trabajo, efecto pascua y por valores extremos

Es de recordar, en este punto, que la principal complicación que tienen los analistas al utilizar los



modelos X11 es la falta de observaciones futuras para centrar la media y estimar los datos más recientes de la serie. Entonces como solución el programa pronostica las observaciones futuras necesarias, pero, estas observaciones a medida que transcurre el tiempo van siendo reemplazadas por observaciones originales, con lo que los pronósticos se van modificando y por tanto la serie desestacionalizada también. Esto es lo que se conoce como el problema de las revisiones, que tanto preocupa dentro del análisis coyuntural y hacia donde van dirigidos los esfuerzos de reducción de las Oficinas de Estadística utilizando filtros de mínimo desfase.

Con este razonamiento se deduce que la aplicación de promedios móviles es útil para conocer la situación presente de una economía, más no para realizar cálculos futuros sobre el comportamiento de la serie.

2.6.2.2. Modelo X11-ARIMA

El X11-ARIMA, desarrollado por Statistics Canada, fue presentado en 1980 y posteriormente se le hicieron mejoras en las versiones de 1988 y 2000.

Este método combina las versiones Census I y II de X11 y adicionalmente incorpora un módulo de extrapolación, desarrollado en 1970, utilizando la metodología ARIMA, metodología basada en los trabajos de Box-Jenkins.

Básicamente la incorporación de los modelos ARIMA, para extender la serie de tiempo y poder utilizar medias móviles centradas, tiene como objetivo reducir el error de revisión en las series desestacionalizadas por efecto de la agregación de datos.

El procedimiento utilizado por el X11-ARIMA para la estimación de los componentes de una serie de tiempo se resume en los siguientes cinco pasos:

1. Ajusta la serie original por la presencia de valores anómalos o cambios en el nivel de la serie,

incluyendo la eliminación de los efectos de días de trabajo y pascua, con el fin de suavizar la serie antes de extraer sus componentes.

2. Ajusta la serie a un modelo ARIMA, especificado por el usuario o elegido en forma automática por el programa.
3. Una vez estimado el modelo ARIMA, se realizan dos transformaciones a la serie original: (1) se reemplazan los valores extremos por valores filtrados eliminándose la posible distorsión, y (2) se predice un cierto número de períodos (típicamente 2 años) fuera de cada extremo de la muestra y se añaden los valores predichos a la serie original. El objetivo de esto último es contribuir al mejor cálculo del componente estacional.
4. Se estima el componente de tendencia de la serie transformada en el punto anterior utilizando los llamados promedios móviles de Henderson.
5. Se efectúa el ajuste estacional (en 12 pasos) a partir del cálculo de promedios móviles centrados

sobre la serie extendida. También extrae los componentes tendencia ciclo e irregular.

De esta manera se pueden definir las principales funciones del programa X11-ARIMA como:

- Estimación iterativa de las componentes de la serie a través de la aplicación de distintas medias móviles.
- Elaboración de proyecciones de hasta 3 años de las observaciones, utilizando alguno de los 5 modelos ARIMA que están incorporados en el programa o cuando ninguno de estos modelos es el adecuado, utilizando un modelo provisto por el usuario.
- Composición de series originales y ajustadas por estacionalidad mediante: adición, diferenciación, multiplicación o división.

Revisando las diferentes versiones del método X11-ARIMA se puede observar su progreso en cuando a la desestacionalización de series de tiempo:


• **X12-ARIMA (2000):** En la última versión de este

- **X11-ARIMA (1980):** Extiende la serie con las extrapolaciones obtenidas usando un modelo ARIMA y luego desestacionaliza la serie usando el método X11. Esto disminuye el error de revisión en un 20% durante la estimación de las componentes de la serie, claro cuando la estacionalidad evoluciona rápidamente.

Estacional

- **X11-ARIMA (1988):** Se introdujeron varias mejoras sobre el modelo X11-ARIMA del año 1980, en ésta versión se incluye la estimación y eliminación de la componente de días de trabajo antes de la estimación del modelo ARIMA, Proyecciones del pasado de la serie, Ajuste por el Efecto Pascua, Ajustes temporarios y permanentes a priori del ajuste estacional, Mejores medias móviles y Selección por el usuario

extender la serie en ambas extremas, lo




de las tablas a imprimir. Además se desarrolla la versión para PC.

- **X12-ARIMA (2000):** En la última versión de esta metodología se introducen nuevos formatos de entrada y salida de datos, nuevo ajuste de totales anuales, tabla resumen de estadísticas básicas, nuevos gráficos.

2.6.3. Incorporación de Modelos ARIMA al Proceso de Ajuste Estacional

El método X11-ARIMA trabaja sobre la base del método X11 Census II, el cual consiste en la aplicación sucesiva de promedios móviles que permiten la identificación y estimación de cada uno de los componentes de una serie.

El método X11-ARIMA incorpora a la metodología anterior un modelo del tipo ARIMA, el cual permite hacer pronósticos hacia delante y hacia atrás (forecasting y backcasting). Esto da lugar a extender la serie en ambos extremos, lo que a su vez hace



posible la aplicación de filtros simétricos (tal es el caso de los promedios móviles centrados con que opera el método).

En este sentido es muy importante que el filtro utilizado no desplace en el tiempo los componentes del resultado que corresponden a la información básica. Es decir, el filtro no debe generar cambios de fase y en este aspecto los promedios móviles centrados tienen la propiedad de no introducir desplazamientos temporales con respecto a los componentes de la serie original. Así mismo, los modelos ARIMA permiten extender la serie a ambos lados antes de efectuar el ajuste estacional, con el objetivo de que los coeficientes estacionales calculados en los extremos de las series sean más estables.

La estabilidad de los coeficientes estacionales es un aspecto muy importante, sobre todo en los extremos, ya que sin un modelo ARIMA que genere buenos pronósticos estos coeficientes serían muy inestables, lo que implicaría que al agregar nuevas observaciones las estimaciones previas de los componentes, variarían mucho, haciendo el método poco confiable para el análisis de coyuntura, que es para lo que se requiere



La selección del método de extrapolación para extender la serie original constituye un paso fundamental en la mejora del ajuste estacional realizado por el método X11. En ese sentido, la elección de modelos ARIMA fue hecha de acuerdo a los siguientes requerimientos:

1. El método debe ser simple, es decir no debe involucrar variables explicativas. Esto significa que la serie debe ser descrita simplemente por sus valores pasados y por perturbaciones aleatorias rezagadas. Este requerimiento es necesario para facilitar la incorporación del método de extrapolación en el programa X11.

2. El modelo identificado debe ser resistente a la incorporación de uno o dos años de información adicional, y los valores extrapolados correspondientes no deben cambiar significativamente ante pequeñas variaciones en los valores de los parámetros. Esta condición es necesaria para evitar cambios frecuentes de modelos y revisiones muy grandes de los resultados, lo cual generaría confusión.

3. El método debe producir valores extrapolados que reproduzcan el movimiento intra-anual de la serie, aunque no necesariamente pronostiquen el nivel con exactitud. Esta condición refleja el hecho de que los pronósticos dentro del método tienen el propósito de mejorar el ajuste estacional y no el de formular expectativas para la toma de decisiones.
4. El método debe generar valores extrapolados óptimos de acuerdo al criterio de minimización de la media del cuadrado de los residuos.
5. El modelo debe ser controlado en el número de parámetros.

Este conjunto de condiciones llevó a la selección de un método univariado de pronóstico y, dentro de los métodos actualmente disponibles, los modelos ARIMA fueron los escogidos. Esto se debió a que, empíricamente, los modelos ARIMA han probado ser herramientas poderosas de pronóstico para una gran cantidad de series.

2.6.4. Selección del Modelo ARIMA

En cuanto a la selección del modelo ARIMA a ser utilizado en el proceso de desestacionalización, este puede ser proveído por el usuario o ser seleccionado en forma automática por el programa. En el caso de seleccionar la opción automática, el programa X11-ARIMA sigue la metodología de Box y Jenkins para la identificación del modelo.

Para determinar si el modelo seleccionado se ajusta bien a la serie, se emplean tres criterios:

1. La prueba de ajuste desarrollada por Box y Pierce, con la corrección de varianza para muestras pequeñas introducida por Ljung y Box. Con ella la hipótesis nula de aleatoriedad de los residuos es probada al 5% de nivel de significancia.
2. La media absoluta de los residuos expresados como porcentajes de los pronósticos de los últimos tres años debe ser menor o igual a 15%.

3. En los parámetros no debe haber evidencia de sobrediferenciación.

Automáticamente el X11-ARIMA prueba, en el orden que se presentan, cada uno de los siguientes cinco modelos y el primero que se ajuste a la serie, de acuerdo a los criterios señalados arriba, es el seleccionado.

1. $L(0,1,1) (0,1,1)_s (0,1,1) (0,1,1)_s$
2. $L(0,1,2) (0,1,1)_s (0,1,2) (0,1,1)_s$
3. $L(2,1,0) (0,1,1)_s (2,1,0) (0,1,1)_s$
4. $L(0,2,2) (0,1,1)_s (0,2,2) (0,1,1)_s$
5. $(2,1,2) (0,1,1)_s (2,1,2) (0,1,1)_s$

En donde L = transformación logarítmica.

El número limitado de modelos para seleccionar en el programa se debe a una serie de estudios empíricos realizados con series económicas y en los cuales se llegó a la conclusión de que estos cinco modelos logran ajustar y pronosticar bien al 90% de de las series económicas. El objetivo de un procedimiento automático es encontrar modelos adecuados para una gran variedad de


series a un bajo costo. En este contexto eso implica tener un número pequeño de modelos que cubran una gran cantidad de series económicas.

2.6.5. Método X12-ARIMA

El método X12-ARIMA es el programa de ajuste estacional del U.S. Bureau of the Census presentado en los últimos años de la década de 90 (1996 específicamente).

Este método provee las siguientes principales ventajas con respecto al X11-ARIMA de Statistics Canada:

- Usa modelos regARIMA (modelos de regresión con errores ARIMA) para permitirle al usuario extender las series (hacia el pasado o el futuro) incluyendo variables de regresión para las variaciones de días de trabajo, el Efecto Pascua, cambios de nivel de la serie, eventos inusuales, outliers, efecto de años bisiestos, etc. Además utiliza también estos modelos para la selección del mejor modelo que se ajusta a la serie.



- La serie temporal puede ser corregida por los efectos antes mencionados en una etapa anterior a la de desestacionalización.

El escoger un método de extracción de señales, en general, depende de

- Efectúa nuevos diagnósticos de calidad y estabilidad de los ajustes realizados, bajo la selección de ciertas opciones del programa.

- Incorpora una nueva interfaz de usuario con formas para facilitar el procesamiento de grandes números de series.

y TRAMO SEATS (Gómez y Ramírez), debido a su reciente

Para conocer más acerca de la forma de procesamiento de las series a través del modelo X12-ARIMA se puede remitir al Capítulo 3 del presente estudio.


2.7. Elección de un Método

Resulta evidente la importancia que tiene para las decisiones de política económica poder separar aquellos movimientos temporales de las variables económicas de sus componentes estacionales, tanto para interpretar los datos como para evaluar el efecto de las políticas. Ello

sugiere la necesidad de comparar la eficiencia y calidad de los métodos de desestacionalización.

El escoger un método de extracción de señales, en general, depende de los objetivos que se pretendan alcanzar al realizar el modelamiento de la serie, además esta elección siempre implicará en el sacrificio de alguna otra ventaja mostrada por los métodos no seleccionados.

Se han hecho numerosas comparaciones entre los métodos de extracción de señales, especialmente entre el X12- ARIMA (Capítulo 3) y TRAMO SEATS (Gómez y Maravall), debido a su reciente incorporación en el tratamiento de las series económicas. Sin embargo se ha llegado a la conclusión de que no es posible decidir sobre la superioridad de uno de los dos métodos. La elección depende esencialmente de los hábitos del usuario y su preferencia por usar métodos con enfoques empíricos o basados en modelos, los primeros tienen como principal desventaja que no se adaptan a través del tiempo, lo que implica que el proceso de estimación debe volver a iniciarse frente al conocimiento de un nuevo dato. Esto no ocurre con los métodos basados en modelos además de otras ventajas antes citadas.



CAPITULO 3

3. EL MÉTODO X12 - ARIMA

Es de vital importancia analizar la estacionalidad de las series económicas, dado que ésta influye en las propiedades estadísticas de las series temporales. Un incorrecto manejo de las series de datos puede acarrear errores en la especificación de los modelos econométricos, lo que posteriormente se traduce en malas predicciones. Es más, las variaciones que poseen las series en el corto plazo pueden alterar el análisis de coyuntura por lo que resulta más conveniente estudiar la trayectoria de las series sin su componente estacional y preocuparse por los puntos de inflexión.

En nuestro país muchos son los factores que influyen en el comportamiento, a corto y largo plazo, de las series económicas. Por este motivo se hace necesario y es recomendable ajustar estacionalmente cada serie económica de las variaciones periódicas

recurrentes infra-anales, solo así se podrá conocer la real naturaleza de los ciclos económicos en los diferentes sectores de la economía del país.

El objetivo del presente capítulo es explicar en qué consiste la metodología X12-ARIMA, rutina seguida para desestacionalizar las Cuentas Nacionales del Ecuador.

Es importante conocer que la familia de programas X11/X12-ARIMA domina el ajuste estacional a nivel mundial, son usados en más del 90% de los datos ajustados por estacionalidad publicados en el mundo. Recientemente la Oficina de Estadística de la Unión Europea, EUROSTAT, seleccionó oficialmente el X12-ARIMA del U.S. Bureau of the Census y el TRAMO/SEATS del Banco de España como los programas oficiales de ajuste estacional para todas las series de la Unión Europea.

3.1. Introducción

El X12-ARIMA es el último programa de ajuste estacional del U.S. Bureau of the Census. Pertenece a la línea metodológica de los programas X11 de U.S. Bureau of the Census (1967) y X11-ARIMA

en sus diferentes versiones (1975, 1988 y 2000) del Statistics Canada.

Estos métodos estiman la estacionalidad mediante la aplicación sucesiva de filtros de promedios móviles a versiones modificadas de las series originales de datos. Estas modificaciones pueden incluir ajuste por valores extremos, por efectos de días de trabajo y feriados móviles que también son estimados por los programas. Los filtros que se aplican son escogidos en base a un grupo determinado de filtros de promedios móviles incluidos y mejorados en las diferentes versiones de los programas, desde X11 hasta X12-ARIMA.

En el capítulo dos se explica la forma en que se procesan los datos en el programa X11-ARIMA y en base a este conocimiento se tiene que las mayores ventajas que ofrece X12-ARIMA son principalmente:

- Capacidad de ajuste para efectos estacional, de feriados móviles y días laborales, que incluye ajustes para la estimación de efectos con regresiones definidas por el usuario, opciones para filtros de tendencia y estacionalidad, y

una alternativa de descomposición estacional-tendencia-irregular.

- Nuevos diagnósticos de la calidad y estabilidad de los ajustes logrados según las opciones seleccionadas por el usuario.
- Capacidad para la modelización de la serie extendida y la selección del modelo adecuado, este fin lo logra con la ayuda de modelos de regresión lineal con errores ARIMA.

- Una nueva interfaz de usuario con características para facilitar el procesamiento de gran número de series.


3.2. La Extracción de Señales con X12 – ARIMA

El método de ajuste estacional X12-ARIMA es producto de las mejoras sucesivas realizadas dentro de la familia de los modelos X11.

En 1965 el U.S. Bureau of the Census introduce al mercado el primer método de ajuste estacional computarizado X11, producto de

varios años de desarrollo comenzando con X11 Census I y Census II. Entre las principales características que contribuyeron a la popularidad del método X11 se anotan: su tratamiento para las observaciones atípicas (extremas), su variedad de promedios móviles para el desarrollo de la estimación de las componentes tendencia y estacional, sus refinados promedios móviles asimétricos para usarlos cerca de la parte final de las series temporales, y su método para la estimación del Efecto Días Laborales.

El siguiente paso se dio en 1980 con el programa de ajuste estacional X11-ARIMA de Statistics Canada, que contenía todas las capacidades de X11 y otras características adicionales. X11-ARIMA incluía la habilidad para extender la serie hacia delante y hacia atrás con la ayuda de los modelos ARIMA antes de que se efectuara el ajuste estacional, esto contribuía a solucionar el problema de "error de revisión" presente hasta X11. Otra ventaja de X11-ARIMA serían sus diagnósticos sistemáticos y enfocados para la evaluación de la calidad de sus ajustes estacionales, por ejemplo ofrecía diagnósticos para comparar los ajustes estacionales de series por el método directo e indirecto.

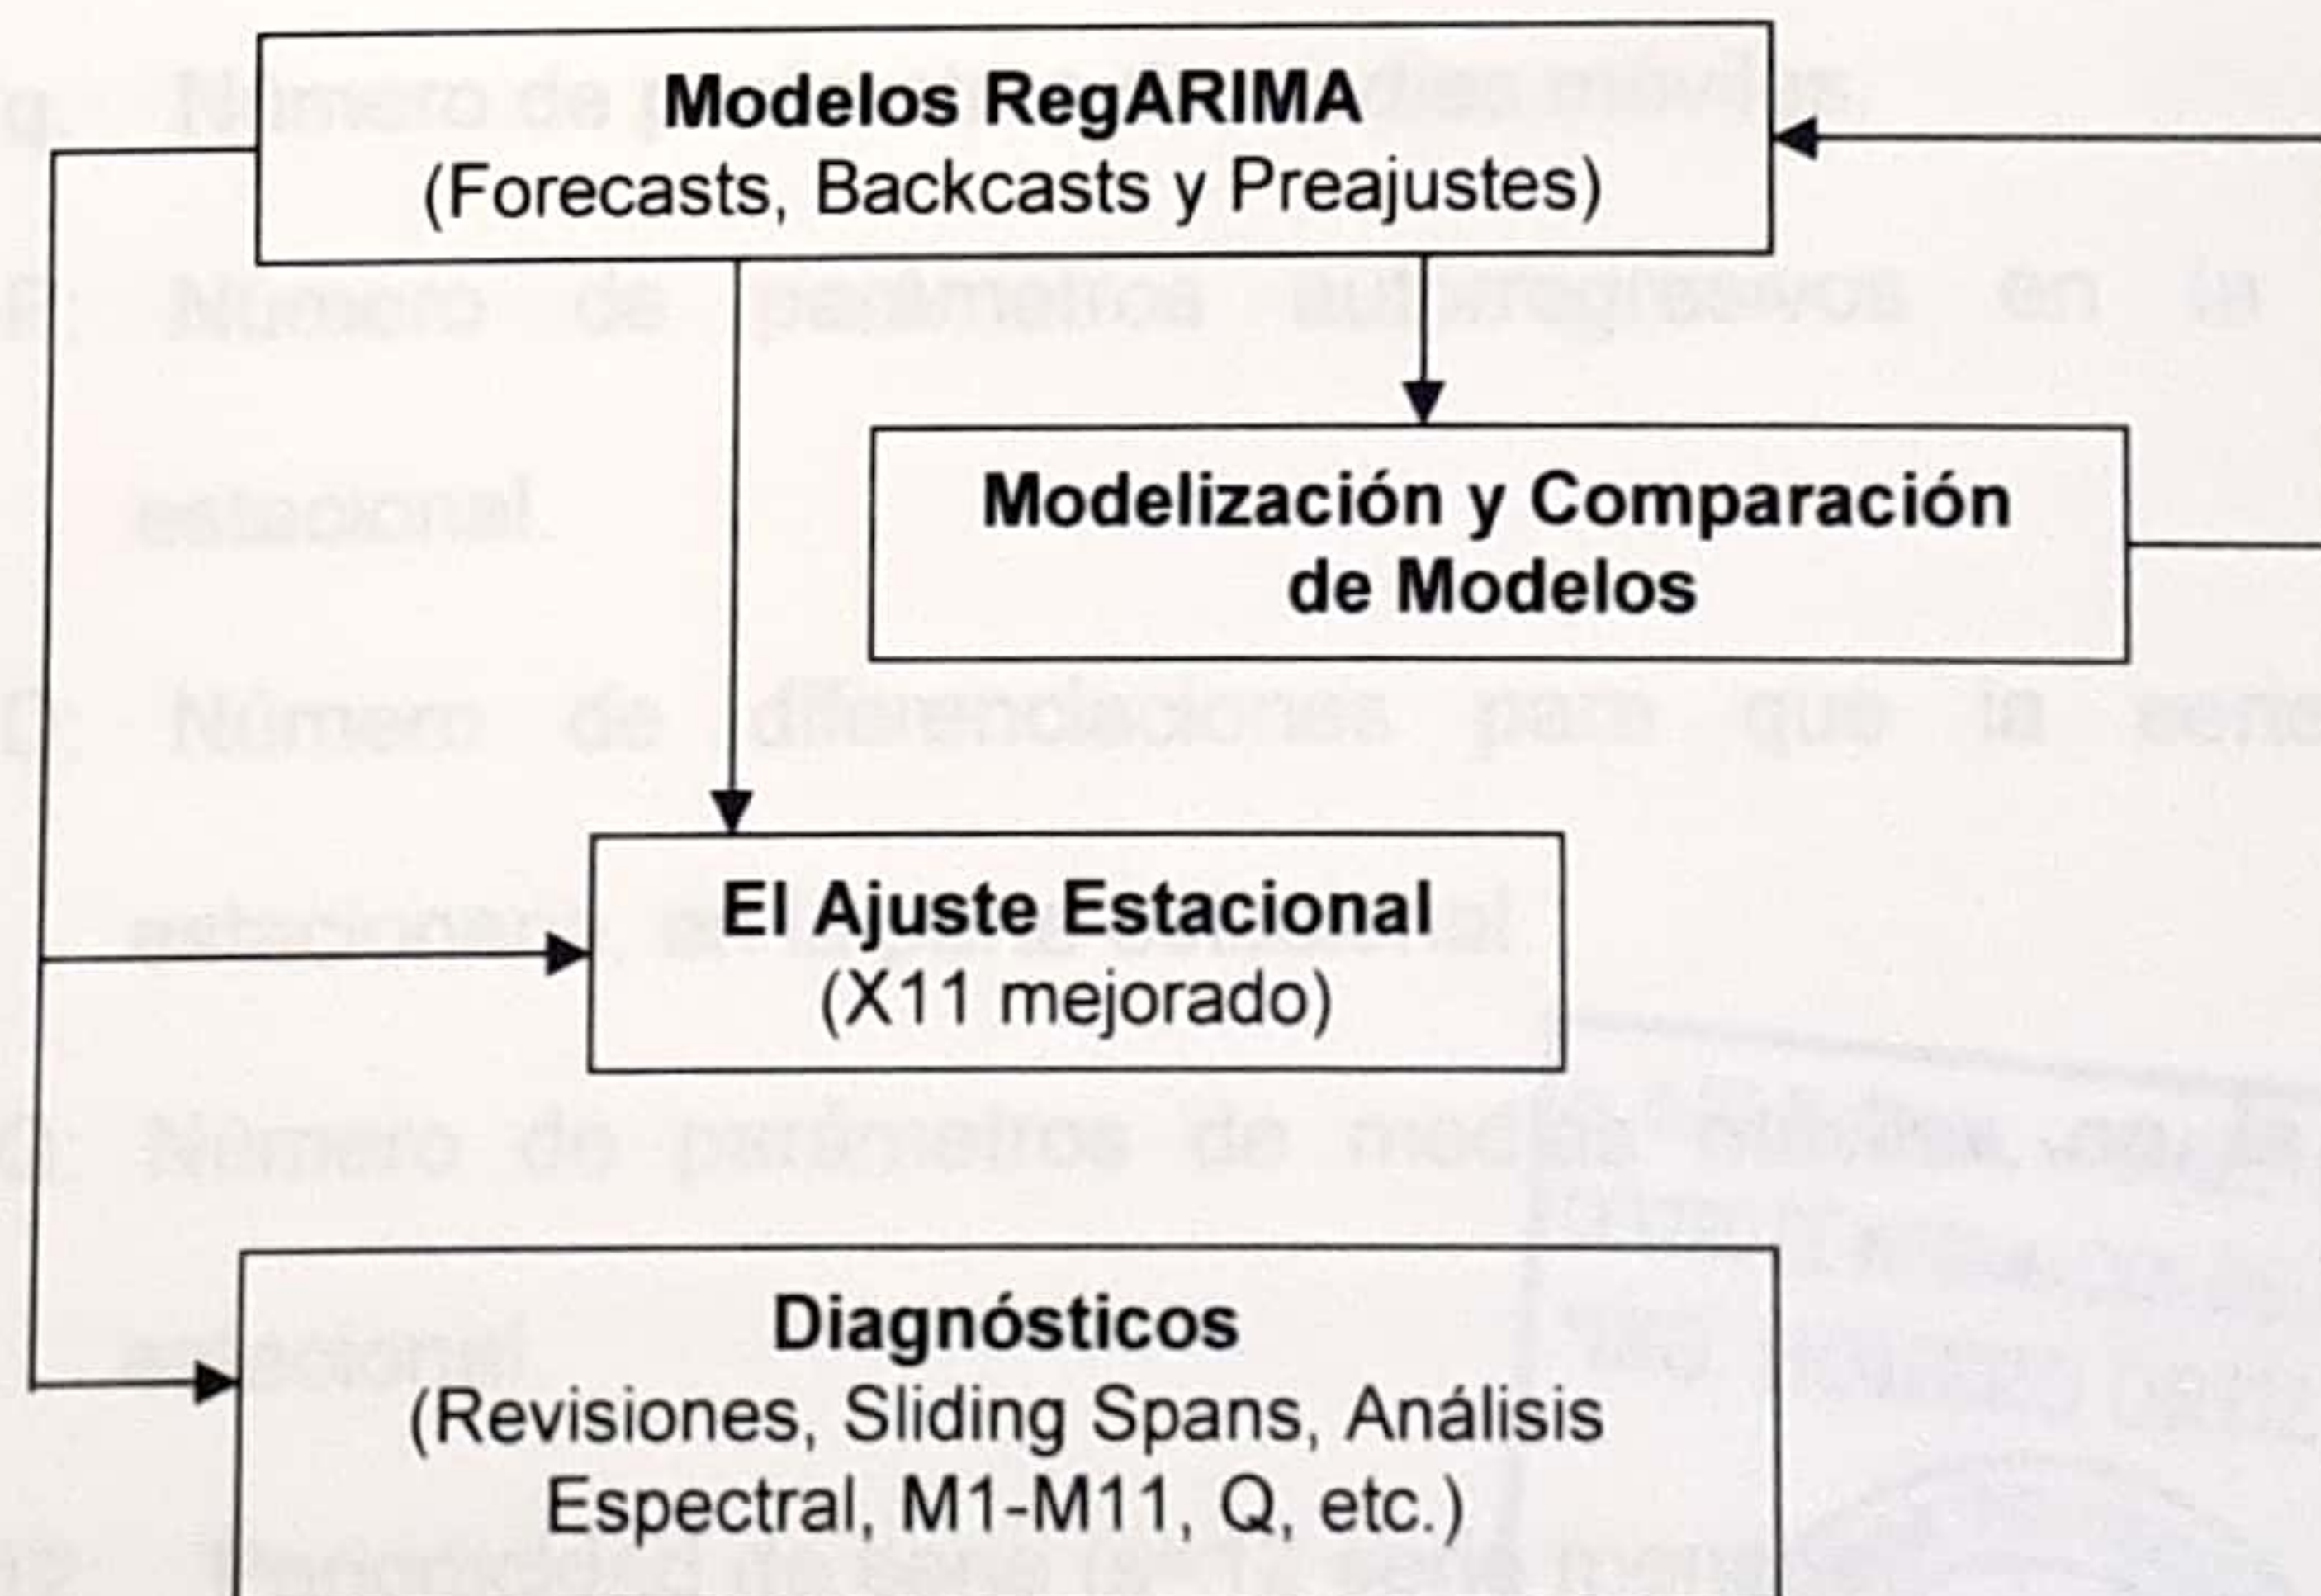


X12-ARIMA de U.S. Bureau of the Census incluye todas las capacidades ofrecidas por X11-ARIMA (en sus diferentes versiones) y X11, y además brinda adicionales ventajas dentro del ajuste estacional de las series tales como las anotadas anteriormente y enfocadas en cuatro puntos principales: alternativas dentro de la descomposición de las series, nuevos diagnósticos de calidad del ajuste, nueva metodología para la modelización de las series y nueva interfaz de usuario.

La figura 3.1 muestra el esquema general que utiliza el método X12-ARIMA para lograr el objetivo de ajuste estacional de las series temporales.

GRÁFICO 3.1

DIAGRAMA PARA EL AJUSTE ESTACIONAL CON X12-ARIMA



3.2.1. Modelos regARIMA

El modelado RegARIMA es el primer paso dentro del procesamiento de las series con la metodología X12-ARIMA. En él se estima un modelo ARIMA estacional (SARIMA) de la forma $(p,d,q)(P,D,Q)_{12}$ para la serie objeto de estudio o en su defecto para la transformación (logarítmica) realizada, cuando es posible hacerla.

SARIMA $(p,d,q)(P,D,Q)_{12}$

p: Número de parámetros autorregresivos.

d: Número de diferenciaciones para que la serie sea estacionaria.


q: Número de parámetros de medias móviles.

P: Número de parámetros autorregresivos en la parte estacional.

D: Número de diferenciaciones para que la serie sea estacionaria, en la parte estacional.

Q: Número de parámetros de medias móviles en la parte estacional.

12: Periodicidad de serie (s=12 serie mensual)



El modelo estimado se usa para extrapolar los valores finales de la serie a fin de extender el número de observaciones (predicción) o estimar valores anteriores al primer valor observado (retroproyección), cuando las observaciones son pocas; y detectar y estimar directamente diferentes efectos calendarios en la serie para preajustarla por ellos (días hábiles, pascua y valores extremos). Todo esto se realiza para mejorar la estimación posterior de los factores estacionales.

Para explicar con mayor detalle la modelización regARIMA, se va a suponer que se requiere modelar la serie Y_t . A menudo es necesario tomar transformaciones no lineales de la serie, $y_t = f_t(Y_t)$, para obtener una que pueda ser ajustada por un modelo regARIMA. Por ejemplo, si Y_t es una serie de valores positivos con movimientos estacionales en los diferentes niveles de la serie, lo usual sería tomar logaritmos,

$$y_t = \log \left(\frac{Y_t}{d_t} \right) = \log Y_t - \log d_t$$

Donde d_t es alguna secuencia adecuada de divisores, por ejemplo: factores de tendencia, estacionales o efectos

combinados de días de trabajo y feriados móviles obtenidos de un modelo de regresión de la componente irregular de Y_t en corridas previas; otro posible divisor puede ser definido por el usuario de acuerdo a sus estimaciones de los efectos inusuales de los eventos económicos.

La transformación de la serie original, previo a la estimación del modelo regARIMA, puede incluir también la estabilización de su varianza. Esto se logra a través de la aplicación de transformaciones que cambian rápidamente el valor de λ , por ejemplo puede ser usada la transformación instantánea definida por los estadísticos Box-Cox

$$y_t^{(\lambda)} = \begin{cases} \frac{Y_t}{d_t}, & \lambda = 1 \\ \lambda^2 + \left[\left(\frac{Y_t}{d_t} \right)^\lambda - 1 \right] / \lambda, & \lambda \neq 0, 1 \\ \log \left(\frac{Y_t}{d_t} \right), & \lambda = 0 \end{cases}$$

El programa permite utilizar algunos valores de λ para propósitos de obtener valores hacia delante y hacia atrás de la

serie original, pero para obtener preajustes de regresión para el ajuste estacional que realiza X12-ARIMA, λ debe ser 0 o 1.

Si $LY_t = Y_{t-1}$, el modelo regARIMA para valores de $\lambda=0$ o $\lambda=1$ es:

$$\phi_p(L)\Phi_P(L)(1-L)^d(1-L^s)^D(y_t - L'X_t) = \theta_q(L)\Theta_Q(L^s)\varepsilon_t$$

Donde $\Phi_p(L)$ y $\Phi_P(L^s)$ son los polinomios autorregresivos en L y L^s de grado p y P respectivamente con las raíces fuera del círculo unitario, $\theta_q(L)$ y $\Theta_Q(L^s)$ son los polinomios de medias móviles de grado q y Q respectivamente con las raíces fuera del círculo unitario, d y D son el orden de las diferencias regulares y estacionales respectivamente, s es el parámetro estacional que puede ser igual a 12 o 4, X_t es la matriz de regresiones, y ε_t es un ruido blanco con media 0 y varianza σ^2 .

A esto sigue que

$$w_t = (1-L)^d(1-L^s)^D(y_t - L'X_t)$$

Es una covarianza de la serie temporal estacionaria que satisface:

$$\phi_p(L)\Phi_P(L)w_t = \theta_q(L)\Theta_Q(L^s)\varepsilon_t$$

Por lo que el modelo regARIMA original puede ser expresado de la siguiente forma:

$$(1-L)^d(1-L^s)^D y_t = \sum_{i=1}^r \beta_i \left\{ (1-L)^d(1-L^s)^D x_{it} \right\} + w_t$$

Este es un modelo de regresión para y_t diferenciada con errores ARMA estacionarios w_t . Si se asume que ε_t tiene una distribución $N(0, \sigma^2)$, todos los parámetros del modelo pueden ser estimados mediante la maximización de la función de probabilidades.

Cabe resaltar que el modelo X12-ARIMA puede calcular la serie transformada y_t de tres maneras: automáticamente, con opciones especificadas por el usuario dentro del programa o

leyendo información de un archivo especificado por el usuario acerca de los divisores d_t .

Adicionalmente el programa tiene para agregar automáticamente variables de regresión referentes a la detección de outliers aditivos (AO) y cambios de nivel en la serie (level shift LS), al grupo de variables de regresión en el modelo. De esta manera, los coeficientes estimados del modelo regARIMA son muy robustos ante alguna clase de outliers o cambios repentinos en el nivel de la serie. El usuario puede opcionalmente elegir tener tales outliers y cambios de nivel identificados automáticamente y removidos de la serie de datos, junto con otros efectos de regresión especificados, antes de que el procedimiento del modelo X11 sea aplicado en la siguiente etapa del programa. A través de tales preajustes, los factores estacionales que son usados para ajustar la serie de datos originales pueden ser protegidos de la distorsión.

El tratamiento de valores extremos dentro del procedimiento de X11-ARIMA proporciona alguna protección en contra de los outliers aditivos para los factores estacionales. Sin embargo, los filtros de tendencia aplicados en el curso de obtener los


factores estacionales no pueden seguir repentinamente, grandes cambios de nivel de las series. Así, la estimación de los cambios de nivel junto con el preajuste de ellos, es una capacidad importante de X12-ARIMA.

3.2.2. Modelización y Comparación de Modelos

En cuanto a la selección del modelo ARIMA a ser utilizado en el proceso de desestacionalización, este puede ser proveído por el usuario o ser seleccionado en forma automática por el programa. En el caso de seleccionar la opción automática, el programa X12-ARIMA sigue la metodología de Box y Jenkins para la identificación del modelo.

Para determinar si el modelo seleccionado se ajusta bien a la serie, se emplean tres criterios:

- La prueba de ajuste desarrollada por Box y Pierce, con la corrección de varianza para muestras pequeñas introducida por Ljung y Box. Con ella la hipótesis nula de



La aleatoriedad de los residuos es probada al 5% de nivel de significancia.


- La media absoluta de los residuos expresados como porcentajes de los pronósticos de los últimos tres años debe ser menor o igual a 15%.

- En los parámetros no debe haber evidencia de sobrediferenciación.

Automáticamente el X11-ARIMA prueba, en el orden que se presentan, cada uno de los siguientes cinco modelos y el primero que se ajuste a la serie, de acuerdo a los criterios señalados arriba, es el seleccionado.

1. $L(0,1,1) (0,1,1)_s (0,1,1) (0,1,1)_s$
2. $L(0,1,2) (0,1,1)_s (0,1,2) (0,1,1)_s$
3. $L(2,1,0) (0,1,1)_s (2,1,0) (0,1,1)_s$
4. $L(0,2,2) (0,1,1)_s (0,2,2) (0,1,1)_s$
5. $L(2,1,2) (0,1,1)_s (2,1,2) (0,1,1)_s$

En donde L = transformación logarítmica.



La otra opción es que el usuario puede especificar un grupo alternativo de modelos. Así como también, especificar otras variables de regresión para incluir en los modelos o incorporar criterios en el programa para decidir si los efectos de días de trabajo, outliers aditivos y cambios de nivel deberían ser incluidos con alguna regresión específica.

Para la situación en la cual ninguno de los modelos probados automáticamente es el adecuado, o el usuario espera identificar o chequear un modelo determinado, X12-ARIMA tiene opciones para producir diagnósticos de modelización estándar. Además, siempre se proporcionan diagnósticos del modelo seleccionado, a los que el usuario puede remitirse en caso de tener dudas respecto al modelo al que se ha adecuado la serie.

El observar la insignificancia de los estimadores de los coeficientes del modelo o los gráficos de las funciones de autocorrelación simple y parcial estimadas de los residuos, puede sugerir que es necesario cambiar el modelo seleccionado a otro más adecuado y para ello existen diferentes criterios a seguir.

3.2.2.1. Comparación de Diferentes Transformaciones

Dentro de la etapa de identificación y selección del modelo, otro problema que se presenta con mucha frecuencia es la comparación de modelos regARIMA, cuya transformación de datos originales difiere.

Esta diferencia entre transformaciones se puede atribuir al uso de distintos divisores d_t en la transformación log de la serie de datos original o al elegir diferentes valores de λ en la transformación de Box-Cox. Si se elige $\lambda=0$ se sugiere que el método de descomposición, en el ajuste estacional de los datos, sea multiplicativo; por el contrario, si se escoge $\lambda=1$ este debería ser aditivo.

Para ayudar a decidir el tipo de transformación adecuada para los datos existen diferentes criterios. Se puede decidir entre analizar manualmente los diagnósticos que proporciona el programa o usar el criterio AIC (Akaike) incorporado en el programa X12-ARIMA. Según este criterio, el modelo con el más

pequeño valor AIC es el más adecuado para Y_t . (ver Akaike (1973), Findley (1985) y Brockwell y Davis (1987) para mayores detalles técnicos).

En cuanto a la situación en la que el modelo ARIMA usa diferentes valores de λ , uno puede examinar un intervalo de valores e identificar el valor de λ maximizando la función de probabilidades logaritmo de la verosimilitud (log).

Adicionalmente, se puede citar que el criterio de Akaike es también utilizado en el momento de decidir si incluir o no el ajuste para el efecto de días de trabajo en el modelo regARIMA de la serie. En la mayoría de los casos, este criterio es más fuerte que el usar la típica Prueba F incluida en el programa X11.

3.2.3. El Ajuste Estacional

En el capítulo dos se explica con detalle la forma en la que trabaja el modelo X11-ARIMA para lograr la



desestacionalización de las series de datos. A breves rasgos, sabemos que se pueden usar dos tipos de métodos de descomposición: el aditivo y el multiplicativo. Dependiendo de cual se ajuste mejor a la serie de datos, el factor estacional será eliminado mediante una diferencia (método aditivo) o una división (método multiplicativo) entre las componentes de tendencia-ciclo, irregular y estacional.

$$Y_t = c_t + s_t + i_t$$

MODELO ADITIVO

$$Y_t^{\text{des}} = Y_t - s_t = c_t + i_t$$

$$Y_t = c_t s_t i_t$$

MODELO MULTIPLICATIVO

$$Y_t^{\text{des}} = \frac{Y_t}{s_t} = c_t i_t$$

Siendo Y_t^{des} la serie desestacionalizada; es decir, la serie original a la que se le ha quitado el componente estacional.

El método X12-ARIMA incluye la descomposición básica multiplicativa y aditiva. Y además, al igual que X11-ARIMA, puede calcular un segundo método de descomposición multiplicativo llamado modelo de descomposición log-aditivo.

Este método se utiliza con mayor frecuencia para propósitos de investigación debido a que requiere una corrección para sus estimaciones de tendencia (debido a las diferencias entre las medias geométricas y aritméticas), así como diferentes calibraciones para la identificación de los valores extremos basadas en la distribución log normal.

$$\text{Log } Y_t = c_t + s_t + i_t$$

$$Y_t^{\text{des}} = \exp (c_t + i_t)$$

MODELO LOG-ADITIVO

Cabe indicar que, siguiendo la línea de los modelos X11, el esquema predeterminado que sigue X12-ARIMA para descomponer la serie en sus tres componentes básicos: tendencia-ciclo, estacional e irregular, es un procedimiento de tres fases. En cada una de las cuales va mejorando la estimación de los componentes, a través de la aplicación de diferentes promedios móviles, tanto para la tendencia como para la estacionalidad. En cada fase la estimación de los componentes es más refinada, y especial atención se pone al componente irregular para detectar y corregir valores extremos.

En general la forma en la que operan los métodos X11 es la siguiente:

1. Estiman la tendencia a través de los diferentes promedios móviles (incorporados y mejorados en las distintas versiones, desde X11 hasta X12-ARIMA)
2. Remueven la tendencia de la serie original, dejándola definida en términos de los componentes estacional e irregular.
3. Estima el componente estacional usando promedios móviles, dejando fuera al componente irregular.

La estacionalidad generalmente no puede identificarse hasta que la tendencia sea conocida, sin embargo una buena estimación de la tendencia no puede hacerse hasta que la serie haya sido desestacionalizada. Por consiguiente, en general, los modelos X11 usan un acercamiento reiterativo para estimar los componentes de una serie de tiempo.

Por otra parte, durante el proceso de descomposición de la serie, el método X11 incorpora en cada una de las etapas una herramienta especial para la identificación y corrección de valores extremos. En particular se realiza una estimación robusta de su desvío estándar móvil. Esta estimación del error típico se hace en dos pasos con el fin de refinarla.

A cada observación del componente irregular se le adjudica un peso W_t , en términos del desvío estándar calculado y de acuerdo a la siguiente tabla 6:

TABLA 6
PESOS PARA COMPONENTE IRREGULAR

$W_t = 1$	Cuando $ I_t - \bar{I} \leq 1.5 s_t^{II}$
$W_t = \frac{2.5 s_t^{II} - I_t - \bar{I} }{2.5 s_t^{II} - 1.5 s_t^{II}}$	Cuando $1.5 s_t^{II} < I_t - \bar{I} \leq 2.5 s_t^{II}$
$W_t = 0$	$2.5 s_t^{II} \leq I_t - \bar{I} $

Elaborado por: V. Vásquez

Los pesos W_t finales es otra salida que muestra el Ajuste estacional de X11.

Otro importante punto de diferencia entre el modelo X12-ARIMA y los modelos X11 y X11-ARIMA, es la manera en que se estiman los efectos de Días de Trabajo, Feriados Móviles u otros efectos.

Otra preocupación y ventaja del modelo X12-ARIMA, en esta fase del proceso, es la estimación del Efecto Calendario y otros efectos por medio de modelo de regresión para el componente irregular. En los modelos X11 y X11-ARIMA el efecto de Días de Trabajo es calculado de la misma manera como calcular un componente más de la serie. En X12-ARIMA existe la posibilidad de generar un modelo de regresión para la componente irregular, el cual ofrece variables de regresión para efectos Calendario y de Pascua, así como también variables indicadoras para identificar irregularidades extremas y disminuir su influencia cuando otros efectos dentro de la regresión están siendo estimados. Esto es lo que concierne a la parte automática, pero el usuario puede también definir modelos de regresión para ser estimados.

En general, la serie irregular, que es el componente residual de la serie luego de separar los componentes de tendencia-ciclo y




estacional, es una serie natural en la cual se pueden estimar algunos otros componentes.

Alternativamente, cabe recordar que el modelo X12-ARIMA puede, y de hecho lo hace, calcular todos estos efectos a través de los modelos regARIMA en la etapa previa al proceso de desestacionalización.

Finalmente, y luego de una serie de procedimientos seguidos para lograr la descomposición de la serie de datos, el programa dará al usuario diferentes tablas en las que se muestran, en general, las series: tendencia-ciclo, irregular, la serie ajustada por la estacionalidad, la serie original, la serie transformada, entre otras.

Las tablas que se muestren dependen del software X12-ARIMA que se este utilizando, en el capítulo cuatro se analizarán y mostrarán los resultados obtenidos del análisis de las series de las Cuentas Nacionales del Ecuador utilizando el software DEMETRA de EUROSTAT.



3.2.4. Diagnósticos

X12-ARIMA muestra las tablas de diagnósticos de X11 y X11-ARIMA, como: los estadísticos de control de calidad M1-M11 de X11-ARIMA.

Adicionalmente se incluyen importantes diagnósticos, tales como:

- Análisis espectral, para revelar la presencia de efectos estacional o por Días de trabajo
- Los estadísticos M y Q, para indicar ciertas propiedades del ajuste que a menudo están relacionadas con ajustes de baja calidad.
- Y, dos tipos de diagnósticos de estabilidad: sliding spans y las historias de revisiones.

3.2.4.1. Análisis Espectral

Para determinar si los efectos estacionales o de días de trabajo están presentes en una serie es necesario utilizar diagnósticos muy sensibles. Y esto es más importante aún si se desea detectar efectos residuales en series que ya han sido ajustadas para efectos estacionales y de días de trabajo. Cuando una serie ha sido ajustada por la aplicación directa del método X12-ARIMA, los residuos de estacionalidad pueden ser el resultado de errores en el procedimiento de ajuste escogido o dificultades para estimar el efecto estacional en las series.

Como los efectos estacionales y de calendario son aproximadamente periódicos, es adecuado usar estimaciones espectrales para detectar su presencia. Así, por ejemplo, dado que el periodo que define el efecto estacional es un año, para series mensuales, el efecto estacional puede ser descubierto a través de la existencia de picos prominentes en alguno de los ciclos de frecuencia por mes.

Siempre que el ajuste estacional es realizado (con o sin ajuste para el efecto de días de trabajo), X12-ARIMA estima automáticamente dos espectros:

1. El espectro de las diferencias mes a mes de las series ajustadas modificadas para valores extremos.
2. El espectro de la componente irregular final ajustada para valores extremos.

Con la ayuda de ambos se revelan significantes efectos de estacionalidad o de días de trabajo, y, en el caso que se identifiquen anomalías automáticamente se muestra un mensaje de advertencia que da el número de picos "significativamente visibles" encontrados en frecuencias estacionales o de días de trabajo.

El más conocido estimador espectral para detectar componentes periódicas no variables es el Periodograma, incluido en los gráficos de diagnóstico de X12-ARIMA.

3.2.4.2. Diagnósticos de Calidad del Ajuste Estacional

Un ajuste estacional que deja detectables efectos residuales, estacionales o de calendario, en una serie ajustada es usualmente catalogado como insatisfactorio. Aún cuando los efectos residuales no sean detectados, el ajuste será insatisfactorio si los valores ajustados sufren muchas modificaciones cuando ellos son recalculados como futuros valores de series temporales disponibles. Es más el simple hecho, de que se realicen sustanciales revisiones, puede causar en los usuarios de los datos la pérdida de confianza en la utilidad de los datos ajustados y en el método seguido.

La presencia de inestabilidad en los ajustes estacionales, de hecho, debería ser objeto de estudio por parte de los entes adecuados. Claro, dependiendo si la inestabilidad es atribuible a la gran presencia de efectos variables de estacionalidad o de tendencia en las series, o a errores evitables en la selección de opciones disponibles en el programa.

Más información acerca de las 11 medidas de control de calidad de ajuste estacional, designadas desde M1 hasta M11, y las dos medidas resumen denominadas Q1 y Q2, se puede encontrar en el Anexo 1.

3.2.4.3. Diagnósticos de Estabilidad del Ajuste Estacional

X12-ARIMA incluye dos tipos de diagnósticos de calidad: sliding spans y las historias de revisión.

3.2.4.3.1. Sliding Spans

Los diagnósticos sliding spans despliegan y proveen estadísticos resumidos, para las diferentes salidas (resultados) obtenidas de correr el programa X12-ARIMA, sobre cuatro subspans de la serie. Para cada mes, estos diagnósticos analizan la diferencia entre los ajustes más grandes y más pequeños de los datos del mes, obtenidos de los diferentes spans. Además también analizan los más grandes y más pequeños

cambios de las estimaciones mes a mes, y, otros estadísticos de interés.

Este tipo de diagnóstico en X12-ARIMA considera los importantes estudios han comprobado la importancia del uso de los sliding spans como herramienta complementaria para realizar diagnósticos tempranos para:

mas temprano de los datos de la serie especialmente cuando se está en su parte final y el

- Determinar si la serie está siendo ajustada adecuadamente.

- Decidir entre un ajuste directo o indirecto de una serie agregada.

tendencia. A este conjunto de revisiones, calculadas

- Confirmar las opciones escogidas, por ejemplo la elección del tamaño de los promedios móviles estacionales. O, simplemente, mostrar otras opciones que pueden ser consideradas.

es el hecho de que pueden ser

número adecuado de estaciones

serie y además indicar si los datos

usados en la parte final, son



3.2.4.3.2. Historia de Revisión

Este tipo de diagnóstico en X12-ARIMA considera las revisiones asociadas con el ajuste estacional continuo sobre un periodo de años. La más básica revisión calculada en el programa, es la diferencia entre el ajuste más temprano de los datos de la serie especialmente cuando se está en su parte final y el posterior ajuste basado en todos los futuros datos disponibles en el tiempo de análisis del diagnóstico.

Similares revisiones son obtenidas para cambios de mes a mes, estimaciones de tendencia o cambios de tendencia. A este conjunto de revisiones, calculadas sobre un grupo consecutivo de puntos en el tiempo, se les llama revisiones históricas.

Otro beneficio que se puede citar de estas revisiones es el hecho de que pueden sugerir al usuario el número adecuado de extensiones hacia delante de la serie y además indicar si los filtros de Henderson, usados en la parte final, son lo suficientemente

estables para servir como una alternativa para el ajuste estacional.

Con el análisis de los diagnósticos proporcionados por el programa X12-ARIMA y la corrección de los problemas detectados en el ajuste estacional, finaliza el proceso de desestacionalización de una serie de tiempo.


4. APLICACION DEL METODO X12-ARIMA AL TRATAMIENTO DE LAS SERIES ECONOMICAS DE LAS CUENTAS NACIONALES DEL ECUADOR

En el capítulo cuatro se muestra la aplicación de esta técnica a las Cuentas Nacionales del Ecuador.

El objetivo del presente capítulo es mostrar al lector la aplicación del método X12-ARIMA al tratamiento de las Series Económicas del Ecuador, básicamente a las Cuentas Nacionales.

Esta demanda se explica la importancia del análisis a estas series económicas, ya que constituyen la estructura conceptual organizativa en la que se introduce la información estadística económica de la que dispone un país.

Esta es la meta que se pretende conseguir con el tratamiento de las series a través de uno de los métodos de desestacionalización más



CAPITULO 4

4. APLICACION DEL METODO X12-ARIMA AL TRATAMIENTO DE LAS SERIES ECONOMICAS DE LAS CUENTAS NACIONALES DEL ECUADOR

El objetivo del presente capítulo es mostrar al lector la aplicación del modelo X12-ARIMA al tratamiento de las Series Económicas del Ecuador, básicamente a las Cuentas Nacionales.

Está demás el explicar la importancia del análisis a éstas series económicas, ya que constituyen la estructura conceptual organizada en la que se introduce la información estadística económica de la que dispone un país.

Ésta es la meta que se pretende conseguir con el tratamiento de las series a través de uno de los métodos de desestacionalización más




conocidos y aplicados en el mundo por diferentes Oficinas de Estadística, el X12-ARIMA.

4.1. Selección del Periodo de Análisis y las Series Económicas

Las series a ser procesadas durante este estudio corresponden a un flujo continuo de información referente a qué se produce en el país, cuánto se produce, para quién o para qué se produce, cuánto ingreso se genera con el proceso productivo y cuál es el destino que se da a ese ingreso, cómo se satisface la demanda de bienes y servicios de consumo final y de inversión y cómo se financia el gasto interno.

Todos estos aspectos se condensan en tres áreas básicas: importaciones (bienes de consumo, materias primas, combustibles y lubricantes, bienes de capital, entre otros), exportaciones (petroleras, no petroleras tradicionales y no petroleras tradicionales) y series de manufactura (producción artesanal)

Todas las series, contenidas en estos tres aspectos, fueron proporcionadas por el Banco Central del Ecuador. Son series



trimestrales medidas con números índices en periodos comprendidos entre los años 1990 y 2002 para las 21 variables de exportaciones, periodo 1987 – 2002 para las 19 variables de importaciones y años 1984 – 2002 para las 13 variables de manufactura.

Es importante mencionar que entre más amplio sea el periodo de análisis, se tendrá mayor criterio para identificar la presencia de estacionalidad y, por tanto, para mejorar el estudio sobre este componente. Es por ello que se justifica la presente investigación.

Además, como recomendación, esta indagación presentada sobre las Cuentas Nacionales debería constituir una base a considerar por parte de entes como el Banco Central del Ecuador, dado que el conocimiento de la estructura y la forma en que opera la economía es fundamental para la toma de decisiones y la programación de acciones tanto en el ámbito de las instituciones públicas como para el sector privado, dentro de los procesos de globalización y búsqueda de oportunidades para promover el desarrollo económico.

4.2. Programa Computacional Utilizado

Para el procesamiento de las series económicas objeto de estudio se ha utilizado el software DEMETRA 2.0 Service Pack 1 (Mayo 2002), desarrollado por EUROSTAT (Oficina de Estadística de la Unión Europea) con la participación de Jens Dossé y Servais Hoffmann, Pierre Kelsen, Christophe Planas y Raoul Depoutot


Este software implementa en una plataforma gráfica, similar a la de las diferentes aplicaciones de Windows, los dos principales métodos de ajuste estacional: X12-ARIMA (U.S. Bureau of the Census) y TRAMO-SEATS (V. Gómez y A. Maravall). De esta manera, se garantiza el fácil acceso al programa de usuarios especialistas y no especialistas en el análisis de series de tiempo.

Adicionalmente al tipo de método de desestacionalización que se escoja, se puede elegir el módulo de procesamiento de la serie que se desee hacer, esto es, una estimación de las componentes tendencia y estacional a través de un procedimiento automático (para usuarios con poca experiencia o para series temporales de gran escala) o un procedimiento de análisis detallado con ayuda del usuario.

El módulo automático permite un tratamiento totalmente instintivo para grandes grupos de series, mientras que el módulo de análisis detallado facilita la comparación entre los resultados correspondientes a los variados modelos especificados para una sola serie temporal.

DEMETRA incluye las más importantes características de Tramo-Seats y X12-ARIMA: módulo de preajuste con detección automática y corrección de outliers, remoción del efecto calendario de las series, identificación y selección automática de un modelo que se ajuste a la serie de datos, Predicciones, Ajuste Estacional y estimación de la Tendencia, Análisis de revisiones históricas y Sliding Span, y demás Diagnósticos para evaluar la calidad del Ajuste Estacional.

Para el presente análisis realizado a las Cuentas Nacionales del Ecuador, se ha utilizado el Módulo Automático, que incluye todas las especificaciones necesarias para el tratamiento de las series y la obtención de importantes resultados. Sin embargo, en algunas ocasiones de acuerdo al conocimiento del usuario acerca de la serie fue necesaria su intervención.



Más adelante se muestran ciertas pantallas del software DEMETRA, capturadas durante el procesamiento de las Series Económicas de las Cuentas Nacionales del Ecuador.

4.3. Tratamiento de las Series Económicas

4.3.1. Módulo Automático

A continuación se especifican los parámetros elegidos para el análisis de las series económicas con la ayuda del software DEMETRA, esto dentro del proceso de Preajuste de las series y posteriormente en la elección del método de descomposición. Esta sección se incluye, para el usuario principiante, como guía de uso del software.

1. *Elección del módulo de procesamiento:* automático o manual. Para efectos de esta investigación, se optó por el módulo automático.
2. *Selección del tipo de archivo a utilizar para descargar las series económicas.* Además se pueden definir los tiempos de descarga de las series (si existe uno en especial) y

escoger las series a ser estudiadas de todas las disponibles en el archivo de descarga.

3. *Elección de los resultados a almacenar de las series que resulten aceptadas durante el ajuste estacional.* Los tipos de resultados que se pueden almacenar están relacionados con las componentes finales o sus predicciones. Se puede elegir, como en este caso, grabar la Tendencia Final y la Serie Ajustada Estacionalmente Final.

Cabe resaltar que cada resultado elegido para almacenar, en el archivo definido para la serie, tiene un nombre específico dentro del software. Así se puede citar que el nombre de la Componente Tendencia Final es .ft y el de la Serie Ajustada Estacionalmente Final




es .fa. Mayores referencias se pueden encontrar en el Manual del Usuario de DEMETRA (1).

4. *Selección del archivo destino*, donde se grabarán los resultados de las series producidos por el método de ajuste estacional definido. Este paso tiene significado si se elige un archivo diferente al especificado inicialmente como descarga de las series. De lo contrario se define la misma ruta para grabar.
5. Este paso es muy importante. Dentro del módulo automático, el usuario puede definir las reglas que permitirán chequear la calidad del ajuste estacional realizado.

Efectivamente, DEMETRA puede detectar automáticamente resultados insatisfactorios (de acuerdo a las reglas definidas por el usuario o las

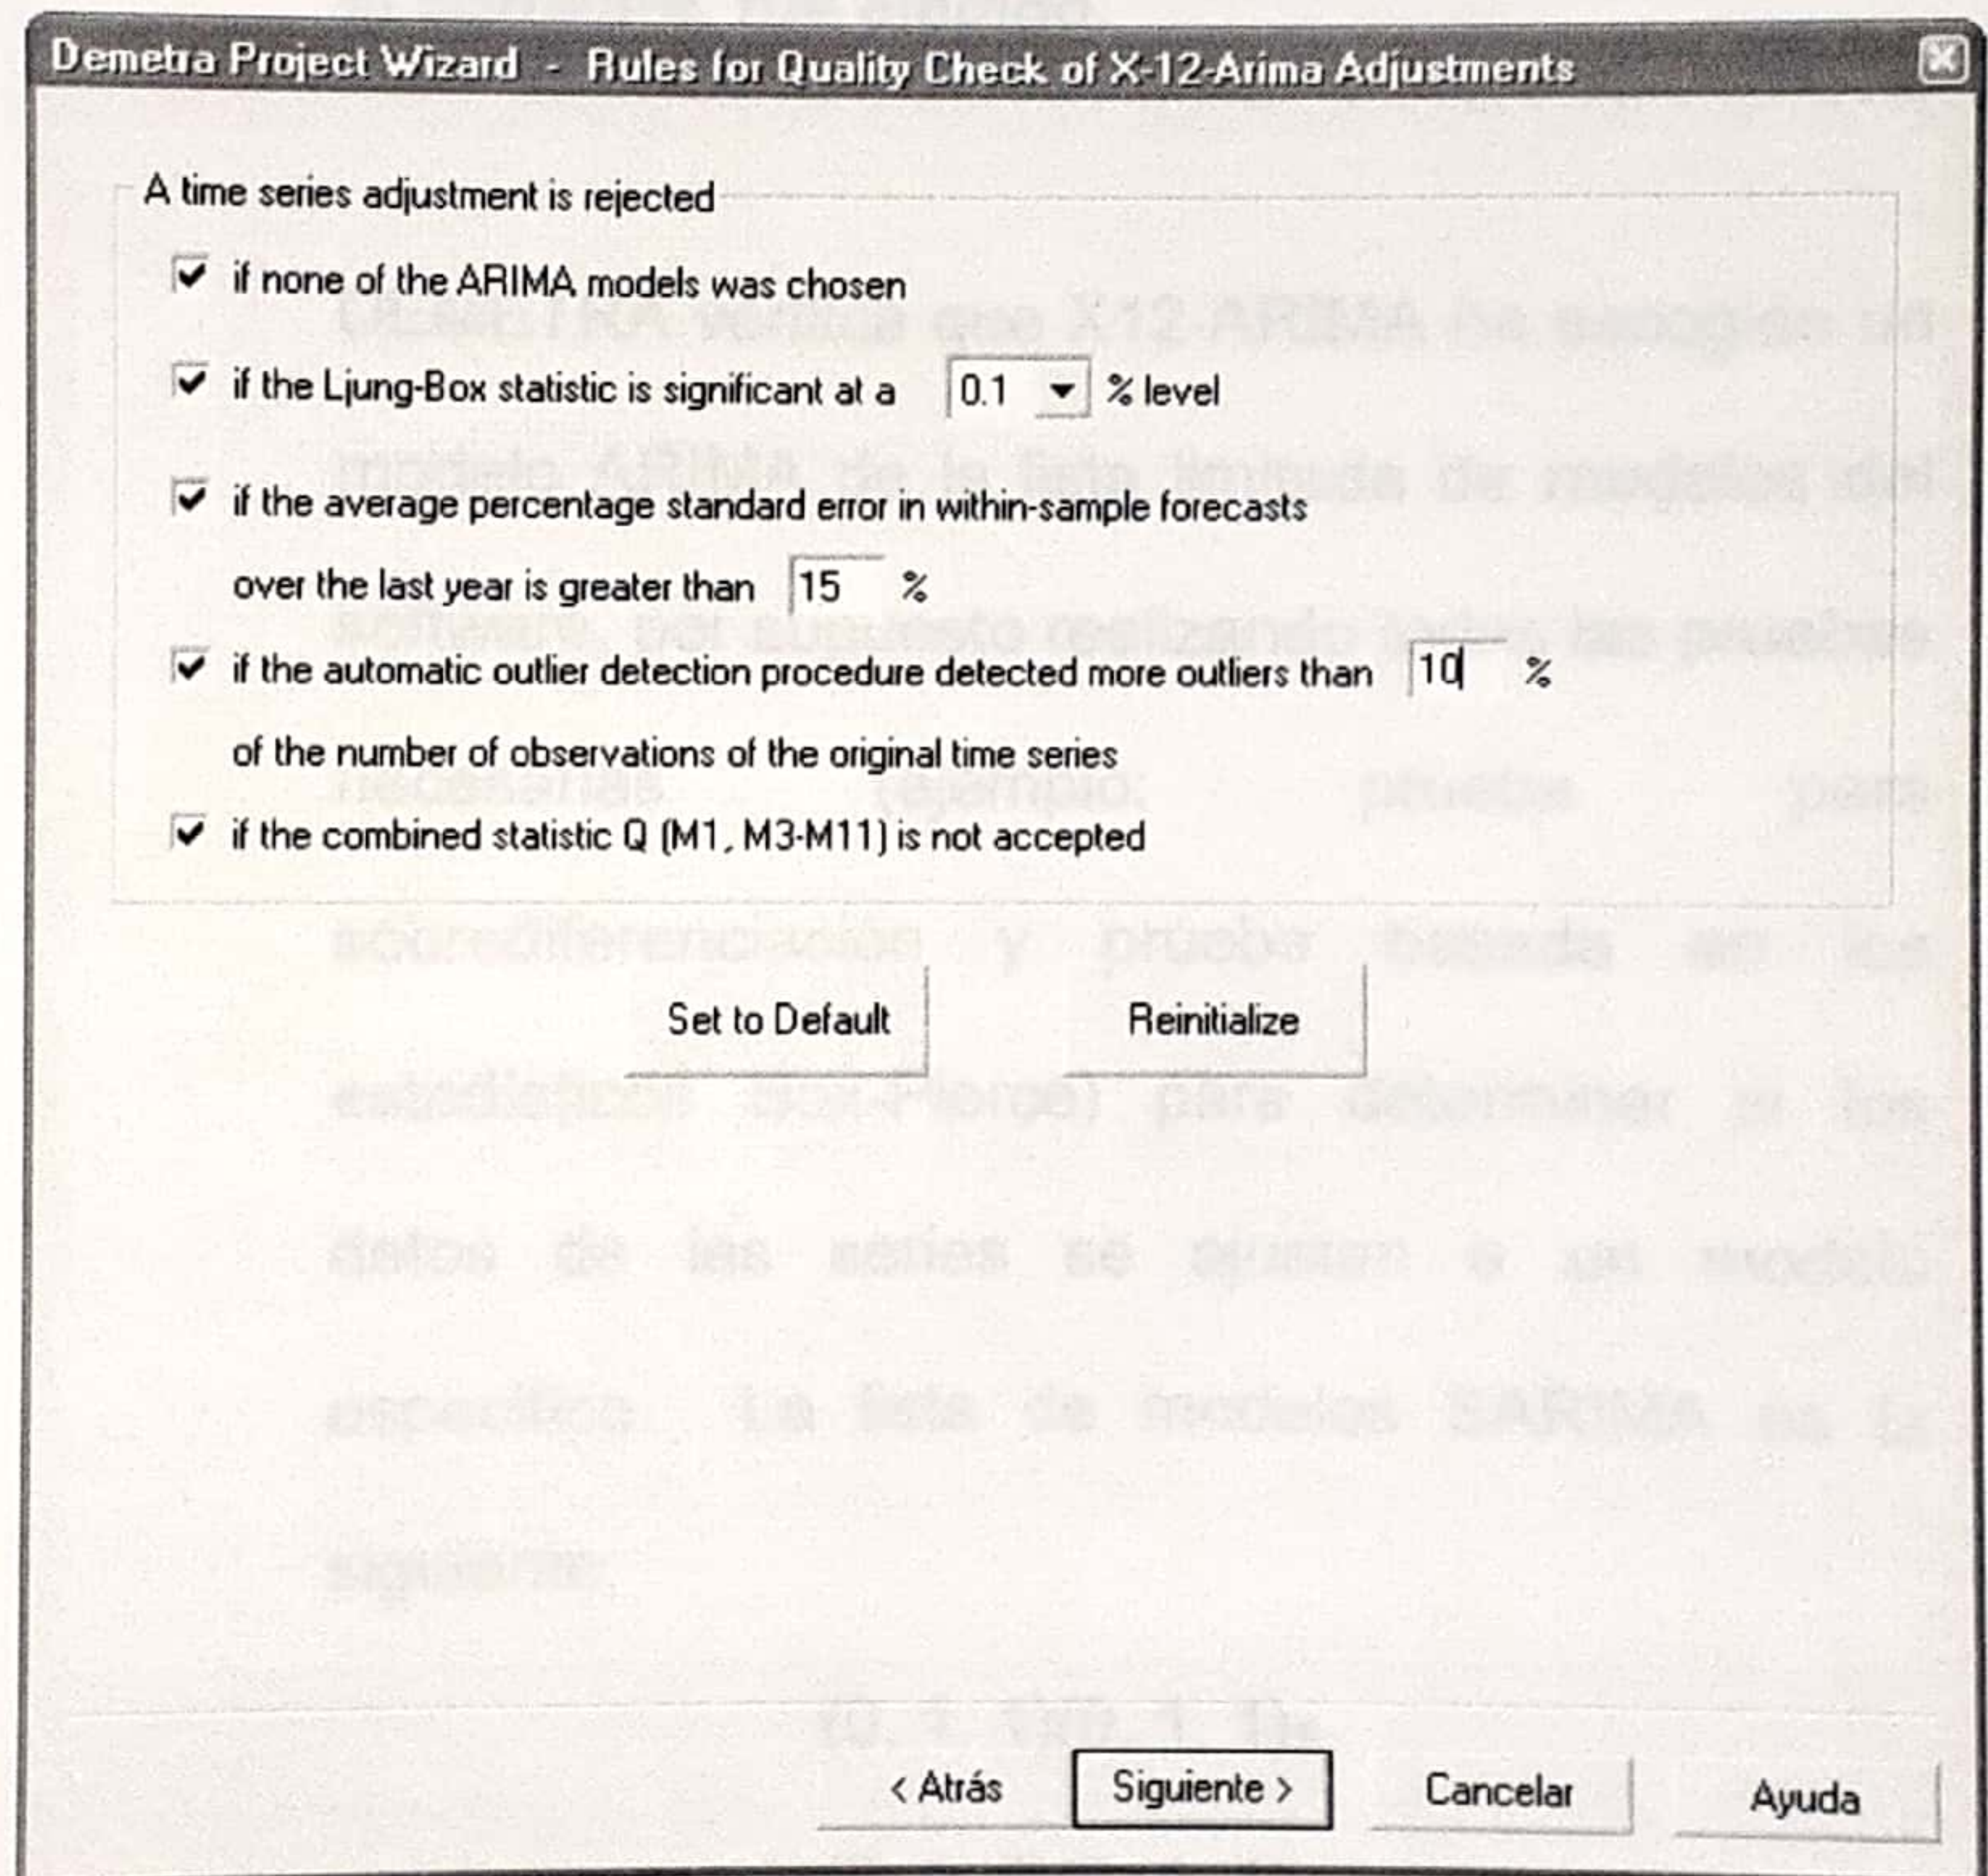
Manual de Usuario Demetra 2.0 Service Pack 1 desarrollado por EUROSTAT y disponible en la página web <http://forum.europa.eu.int/Public/irc/dsis/eurosam/library>



predeterminadas) que posteriormente pueden ser tratados en el Módulo de Análisis Asistido (Manual) para las series que resulten rechazadas.

GRÁFICO 4.1

REGLAS PARA CHEQUEAR LA CALIDAD DEL AJUSTE ESTACIONAL CON X12-ARIMA



DEMETRA proporciona diagnósticos de calidad según el método de ajuste estacional que se elija, en este caso y de acuerdo a lo mostrado en la figura 4.1 (los valores

mostrados son los elegidos para el análisis del ajuste realizado a las Series Económicas del Ecuador), los posibles diagnósticos para que el ajuste de una serie de tiempo con X12-ARIMA sea rechazado son:

a. Ninguno de los modelos ARIMA, predefinidos en el software, fue elegido.

DEMETRA verifica que X12-ARIMA ha escogido un modelo ARIMA de la lista limitada de modelos del software, por supuesto realizando todas las pruebas necesarias (ejemplo: prueba para sobrediferenciación y prueba basada en los estadísticos Box-Pierce) para determinar si los datos de las series se ajustan a un modelo específico. La lista de modelos SARIMA es la siguiente:

$(0, 1, 1)(0, 1, 1)_s$

$(0, 1, 2)(0, 1, 1)_s$

$(2, 1, 0)(0, 1, 1)_s$

$(0, 2, 2)(0, 1, 1)_s$

$(2, 1, 2)(0, 1, 1)_s$

Si los modelos disponibles son insatisfactorios para el conjunto de datos, la predicción de los valores finales de la serie (a fin de extender el número de observaciones) no es calculada y la descomposición se realiza sobre una serie extendida utilizando promedios móviles asimétricos, lo que repercute en la calidad del ajuste.

- b. *El estadístico Ljung - Box, para probar la presencia de autocorrelación en la componente residual, tiene un nivel de significancia del 0.1%.*

DEMETRA prueba si el estadístico Ljung - Box es más pequeño que $\chi_{m,\alpha}^2$, donde m es el número de grados de libertad (dos veces la periodicidad de la serie menos el número de coeficientes ARIMA) y α es el nivel de significancia elegido (por ejemplo son admitidos: 5%, 10%, 2.5%, 2%, 1%, 0.5%, 0.2% o 0.1%)



- c. El porcentaje promedio de error estándar en las predicciones de los últimos años es mayor al 15%.**

En general, la interfaz prueba que el error en las predicciones sea más pequeño que α , que puede tomar valores de 5%, 10%, 15% o 20%. Este diagnóstico también es utilizado para elegir el modelo ARIMA, el escogido debe ser aquel que tenga el más pequeño error en las predicciones de los últimos años de la serie.

- d. El procedimiento automático para detección de outliers (valores atípicos) identificó más del 10% de outliers sobre el número de observaciones de la serie de tiempo original.**

Cabe indicar que el tipo de outliers que se identifican son:

- **Additive Outliers (AO):** los valores aditivos corresponden a un punto aislado, que se

podría deber a una huelga, a cambios climatológicos, etc.. En el modelo de preajuste, este tipo de eventos es integrado dentro del componente irregular.

- *Level Shift (LS)*: los cambios de nivel significan un quiebre en el valor promedio de los valores de la serie. Es un cambio permanente que se puede presentar cuando la definición de la serie es cambiada o su nomenclatura es modificada.

Los cambios de nivel son procesados por DEMETRA como un componente que modifica la Tendencia.

- *Transitory Change (TC)*: los cambios transitorios describen una interrupción (salto es un punto simple) en la trayectoria normal de la serie, con su posterior retorno a la situación inicial.

Los cambios temporales son eventos de tipo irregular.

Además se tiene un tipo especial de outliers, estos son las oscilaciones, muchas veces consideradas como outliers consecutivos en direcciones opuestas. Las oscilaciones se pueden deber a situaciones pospuestas entre periodos y pueden ayudar a revelar el Efecto de la Pascua.

e. El estadístico combinado Q ($M1, M3-M11$) no es aceptado

X12-ARIMA se basa en 11 estadísticos para la valoración de la calidad del ajuste estacional, todos ellos toman valores entre 0 y 3 con un rango de aceptación que va de 0 a 1 inclusive².

El estadístico Q también es probado para esta región de aceptación



6. Luego de definir las reglas para el chequeo de la calidad del ajuste estacional, el usuario debe elegir la herramienta estadística a considerar para el tratamiento de las series económicas. Esta herramienta debe corresponder a las políticas de ajuste estacional y definir los requerimientos mínimos de revisión para las series.

DEMETRA permite elegir cinco tipos de tratamientos, relacionados a los parámetros del modelo, en dos áreas: análisis estacional (identificación y selección del modelo) y desestacionalización (cálculo de los datos ajustados estacionalmente).

Dentro del análisis estacional, correspondiente a la determinación del modelo de pre-ajuste estacional, se tienen las siguientes opciones:

- parámetros predeterminados (incluidos en la aplicación) según los cuales DEMETRA prueba la necesidad de hacer correcciones e incluirlas para mejorar el modelo.

- parámetros personalizados donde el usuario elige las correcciones a implementar en el modelo.
- parámetros escogidos de un archivo modelo para el nuevo procesamiento

Para la fase de desestacionalización (se considera el análisis previo a las series y los parámetros almacenados durante este tratamiento) las opciones mostradas son:

- Aplicación de un modelo al nuevo conjunto de datos, en este caso se consideran los coeficientes del modelo ARIMA estimado previamente.
- Cálculo de los datos ajustados estacionalmente, después de realizar una re-estimación de los coeficientes del modelo.

Para efectos de esta investigación se eligió la opción uno, donde se tiene un grupo predeterminado de parámetros para un nuevo ajuste automático. Estos incluyen:

- Pre-prueba para justificar una transformación logarítmica (descomposición multiplicativa o aditiva)



- Una corrección de la media (si es necesaria).
 - Una nueva identificación, selección y estimación del modelo ARIMA para las series.
 - Pre-pruebas para determinar la presencia de Efectos de la Pascua y de Días Laborables.
 - Una detección y corrección automática de outliers para todas las series y en todas sus extensiones.
 - Una interpolación para observaciones perdidas
 - Predicciones con modelos ARIMA para los valores finales de las series.
 - Una descomposición automática.
7. Como punto final, para posteriormente comenzar la corrida del programa, se tiene la elección del método de ajuste estacional (X12-ARIMA en este caso) y el tipo de tratamiento a efectuar para detectar el Efecto de Días Laborables.



GRÁFICO 4.2

PROCESO DE SA CON X12-ARIMA
EFECTO DÍAS LABORABLES

Demetra Seasonal Adjustment Processing

NEW AUTOMATIC SEASONAL ADJUSTMENT

Seasonal Adjustment Method

Tramo/Seats

X-12-Arima

Modelling Time Interval

... / ... to ... / ...

Otherwise reload from the saved parameters, if available

Type of Trading Day Effect to Test

<input type="radio"/> No trading day adjustment	0 regressors
<input type="radio"/> Working days (Monday to Friday):	1 regressor
<input type="radio"/> Working day (Monday to Friday) & leap-year:	2 regressors
<input type="radio"/> Trading day (Monday, Tuesday, ..., Saturday):	6 regressors
<input checked="" type="radio"/> Trading day (Mon, Tue, ..., Sat) & leap-year:	7 regressors

Allow reducing the number of trading day regressors

< Atrás Siguiente > Cancelar Ayuda

De acuerdo a la figura 4.2, para este estudio, se eligió definir 7 coeficientes de regresión para el tratamiento del Efecto Días Laborables. Esto significa un coeficiente para cada día laboral de la semana (se considera en nuestro país de Lunes a Sábado) y además uno para efectos del año bisiesto.

El elegir los otros tipos de tratamiento para este efecto depende de las diferencias en la actividad económica entre los días laborables y fines de semana, esto según el país de análisis.

	Extrínsecos	Intrínsecos	Asimétricos
Argentina	21	19	19
Brasil	14	14	14
Estados Unidos	14	14	14

Hasta aquí se han descrito los pasos a seguir para el tratamiento de las Series Económicas del Ecuador con DEMETRA y el modelo X12-ARIMA, a continuación se muestran los resultados obtenidos para las diferentes series estudiadas.

4.4. Resultados Obtenidos

4.4.1. Resultados Series Rechazadas en el Punto Principal

La tabla 7 muestra los resultados conseguidos del procesamiento de las Series de las Cuentas Nacionales del Ecuador con DEMETRA y el modelo X12-ARIMA.

TABLA 7
RESULTADOS TRATAMIENTO DE SERIES CON DEMETRA
UTILIZANDO EL AJUSTE ESTACIONAL X12-ARIMA

	<i>Series Exportaciones</i>	<i>Series Importaciones</i>	<i>Series Manufactura</i>
<i>Series Procesadas</i>	21	19	13
<i>Series Aceptadas</i>	14	14	13
<i>Series Rechazadas</i>	7	5	0

Elaborado por: V. Vásquez

En seguida, el análisis de las series objeto de investigación se dividirá en aceptadas y rechazadas, con el fin de establecer diferencias en el procesamiento de las mismas.

4.4.1. Resultados Series Rechazadas en el Ajuste Estacional

A continuación se muestran los análisis a las tablas y gráficos generados por DEMETRA para las series rechazadas, de esta manera se justifica el hecho de no utilizar el modelo ARIMA del preajuste para efectuar la desestacionalización de las series.

Elaborado por: V. Vásquez
 Software: Demetra 2.0

La **primera serie** analizada es la serie de números índices I-x03 de exportaciones, cuyo número de observaciones es 52. En la tabla 8 se muestra un resumen detallado del Pre-ajuste y la descomposición realizadas.

TABLA 8
INFORMACIÓN SOBRE EL MODELO (X12-ARIMA) PARA
LA SERIE DE EXPORTACIONES I-x03

Información sobre el Modelo	Modelo 1 (X12-ARIMA)
Periodo de las series (Nº de observaciones)	Q1. 1990 – Q4. 2002 (52)
Periodo del Modelo (Nº de observaciones)	Q1. 1990 – Q4. 2002 (52)
Método	X12-ARIMA
PRE - AJUSTE	
Transformación	Ninguna
Corrección de Media	Si
Valor Medio-t	0.11 [-2.000, 2.000] 5%
Corrección por Efecto de Días Laborables	Ninguna
Corrección por Efectos de Pascua	Ninguna
Corrección por Outliers (Atípicos)	Automático: AO, LS, TC, 2 outliers fijados
Valor – Crítico t	2.671
AO Q4. 1993 valor-t	3.73 [-2.671, 2.671] val. crít.
AO Q2. 1999 valor-t	4.04 [-2.671, 2.671] val. crít.
Corrección por Observaciones Perdidas	Ninguna
Corrección por otros efectos de Regresión	Ninguna
Especificaciones del Modelo ARIMA	(0,1,0) (0,0,0) (fijado)
Método de Estimación	Máxima Verosimilitud Exacto
DESCOMPOSICIÓN	
Descomposición X-11	Con predicciones ARIMA
Filtro Estacional X-11	MA 3X5
Filtro Tendencia X-11	MA de Henderson de 5 términos
Estacionalidad	No significativa

Elaborado por: V. Vásquez
Software: Demetra 2.0

Como información inicial la Tabla 8 muestra el número de observaciones de la serie (52) y su periodicidad (4, trimestral), posteriormente dentro del proceso de pre-ajuste da a conocer si se realizó algún tipo de transformación a la serie original, una corrección de media, corrección por efecto de días laborables o de Pascua, corrección por outliers, por observaciones perdidas o algún otro efecto de regresión especial.

En este caso no se realizó una transformación, pero en ocasiones tomar esta decisión puede ser apropiada si la amplitud de las fluctuaciones estacionales está correlacionada al nivel de las series. Esto indica una relación multiplicativa entre los componentes, donde es necesario aplicar una transformación logarítmica para obtener una estructura aditiva requerida para la descomposición de la serie (según el método X12-ARIMA). Cabe indicar que DEMETRA realiza una pre-prueba para determinar si es necesaria o no la transformación, en el caso de X12-ARIMA este diagnóstico está basado en los valores de AIC (Criterio de Akaike). Además si la serie contiene valores negativos o ceros la transformación no se realiza.

En cuanto a la corrección de la media, este proceso es adecuado debido a que la componente residual final debe seguir una distribución normal con media cero. Para la serie I-x03 esta corrección fue necesaria y además en los resultados de la tabla se muestra un intervalo de confianza del 95% utilizando el estadístico t que se ubica dentro del intervalo.

Otro aspecto probado durante el proceso de preajuste es la corrección por efecto de días laborables, que para esta serie no fue necesario hacerlo. Sin embargo, en ocasiones es requerido debido a que muchas actividades económicas son influenciadas por efectos del calendario, tales como diferencias entre los días de trabajo y los fines de semana, presencia del año bisiesto, número de semanas durante el mes, fines de semana dentro de un mes, etc. DEMETRA también realiza una pre-prueba para determinar si es necesario o no el ajuste (X12-ARIMA se basa en el Criterio de Akaike) y si resulta positiva la corrección, esta se hace de acuerdo al criterio seleccionado del usuario (para esta investigación se escogió establecer diferencias entre los días laborables y fin de semana, además de la presencia del año

bisiesto; es decir, se tiene la presencia de 7 coeficientes de regresión).


El siguiente análisis es referente a un ajuste por Efecto de Pascua, presente en las series económicas de manera puntual entre los meses de Marzo y Abril (dependiendo de la fecha del año en que caiga). DEMETRA prueba incluirlo, al igual que los otros tipos de efectos mostrados, de acuerdo al Criterio de Akaike en el método X12-ARIMA, el software realiza la pre-prueba y si resulta positiva la corrección por Efecto Pascua, ésta es realizada antes de proceder a la descomposición de la serie. Para la serie I-x03 no fue necesario realizar tal corrección.

Referente a la detección de outliers, X12-ARIMA permite al usuario identificar automáticamente dentro de las series tres tipos de valores atípicos: AO , TC y LS. Aunque se tiene la libertad de limitar la detección, dependiendo del conocimiento de las series, a 2 de 3 tipos de outliers (siempre incluyendo el tipo AO). Cabe indicar que el procedimiento de detección de outliers consta de otros parámetros:



- *Valor Crítico*, referente a una escala de sensibilidad que permite determinar los valores que debe sobrepasar un outlier (de acuerdo al orden que siguen los demás valores de la serie) para ser considerado como tal. Esta escala va de 2.8 (alta sensibilidad) a 4.1 (baja sensibilidad), permitiendo escoger valores más pequeños para incrementar el número de outliers y así mejorar las características residuales del modelo ARIMA, o elegir valores más altos para reducir su presencia (para esta investigación se escogió que si el procedimiento automático detecta más del 10% de outliers, considerados como tales según los valores críticos, sobre el número de número de observaciones de la serie de tiempo original, la serie sea rechazada).

- *Método de estimación de outliers*, X12-ARIMA ofrece dos procedimientos: "agregar uno a uno" donde el outlier con el estadístico t más alto/insignificante es agregado/removido de la serie en su periodo y posteriormente se estima el modelo ARIMA, y "agregar todos los outliers juntos" donde todos los outliers significantes/insignificantes son agregados/removidos




de la serie de una sola vez para luego estimar el modelo ARIMA. En general la detección de outliers depende del tipo de modelo ARIMA definido, ya que según eso se tendrá el patrón que deben seguir los datos.

- *El lapso de tiempo*, es importante definir el periodo de tiempo para el cual se requiere la detección y corrección de outliers, ya que dentro de ese intervalo se validan los demás parámetros.

- *Outliers, días festivos y otras variables de regresión de análisis previos*, DEMETRA brinda al usuario la posibilidad de incluir otros tipos de parámetros (almacenados en una base o archivo) definidos de acuerdo a la experiencia o conocimiento sobre las series.

Para la serie I-x03 se detectaron dos outliers del tipo AO que se encuentran fuera del intervalo definido por el valor crítico, por lo que se los considera significativos.




La parte más importante del proceso de pre-ajuste es la especificación del modelo ARIMA, que para la serie I-x03 es el $(0, 1, 0)(0, 0, 0)$ estimado por el método de Máxima Verosimilitud Exacto. El que la parte estacional del modelo conste de ceros significa que X12-ARIMA ha eliminado la parte estacional del modelo ARIMA debido a que no es lo suficientemente fuerte para la descomposición. Así la descomposición se limita a la estimación de la tendencia y el componente irregular, y la serie ajustada estacionalmente será igual a la serie original de datos. Cabe indicar que los resultados no son normalmente afectados por los cambios que se pudieran hacer durante el proceso.

Referente al Proceso de Descomposición la tabla 8 muestra cuatro aspectos importantes referentes al proceso que efectúa el modelo X11:

- *La descomposición se realiza con predicciones ARIMA, esto es X12-ARIMA podría usar o seleccionar satisfactoriamente el modelo ARIMA, especificado para la serie de tiempo, para extrapolar los valores finales de la serie a fin de extender el número de observaciones (predicción) o estimar valores anteriores*

al primer valor observado (retroproyección). Todo este proceso se realiza cuando las observaciones son pocas y antes de la descomposición, con el propósito de mejorar la calidad del ajuste estacional.

- *El filtro estacional utilizado es uno de 3x5 términos*, esto significa que un simple filtro simétrico de 3 términos es tomado de una secuencia de promedios móviles de 5 términos consecutivos. Este filtro es aplicado para todos los periodos de la serie.
- *El filtro para eliminar la tendencia de la serie de tiempo es el de Henderson de 5 términos*. Los filtros de Henderson largos (referente al número de términos que utiliza) son adecuados cuando los movimientos de la tendencia son estables dentro de la serie, y los de términos cortos cuando hay mucha inestabilidad en el patrón de la tendencia.
- *La estacionalidad no es significativa*, esto quiere decir que X12-ARIMA no detectó un **significante componente estacional** dentro de la series. Este resultado, dado por



el programa, quiere decir que el ajuste estacional es desarrollado pero no recomendado o útil. Además que, dentro del proceso de pre-ajuste, un modelo RegARIMA no estacional debería ser considerado.

Hasta este momento se ha analizado, para la serie I-x03, la información sobre el modelo resultante de los procesos de pre-ajuste y de descomposición de la serie con X12-ARIMA. A continuación se muestra en la Tabla 9 la información referente a los diagnósticos que efectúa DEMETRA para validar la calidad del ajuste estacional.

TABLA 9
INFORMACIÓN DE DIAGNÓSTICO DE LA SERIE DE EXPORTACIONES I-x03 CON X12-ARIMA

Información de Diagnóstico	Modelo 1 (X12-ARIMA)
Índice de Calidad de Ajuste Estacional (hasta 10)	13.615 [0, 10] ad-hoc
Estadísticos sobre los Residuos	
Ljung-Box para residuos	10.71 [0, 32.90] 0.1%
Descripción de los Residuos	
Curtosis	2.29 [0.76, 5.24] 0.1%
Error en Predicciones	
Error en Predicciones sobre los últimos años	64.54% [0%, 15.0%] ad-hoc
Outliers	
Porcentaje de Outliers	3.85% [0%, 10.0%] ad-hoc
Criterio para Descomposición	
Estadístico combinado Q (M1, M3-M11)	1.48 [0, 1] ad-hoc

Software: Demetra 2.0
Elaborado por: V. Vásquez

De acuerdo a esta tabla el usuario puede notar que el estadístico Ljung-Box para residuos se encuentra dentro del intervalo de confianza del 90%, es decir que hay evidencia estadística para afirmar que no existe autocorrelación en los residuos del modelo ARIMA fijado.

El valor de la curtosis de 2.29 dentro del intervalo de confianza del 90%, muestra que no hay evidencia de curtosis en los residuos, es decir se tiene una distribución plana de los valores de la serie alrededor de la media.

El tamaño significativo del error en las predicciones ARIMA (64.54%, cuando el límite es del 15%) muestra mucha variabilidad de las predicciones alrededor de los verdaderos valores de la serie. Por este motivo se dice que el modelo ARIMA no se ajusta muy bien al conjunto de valores de la serie temporal.

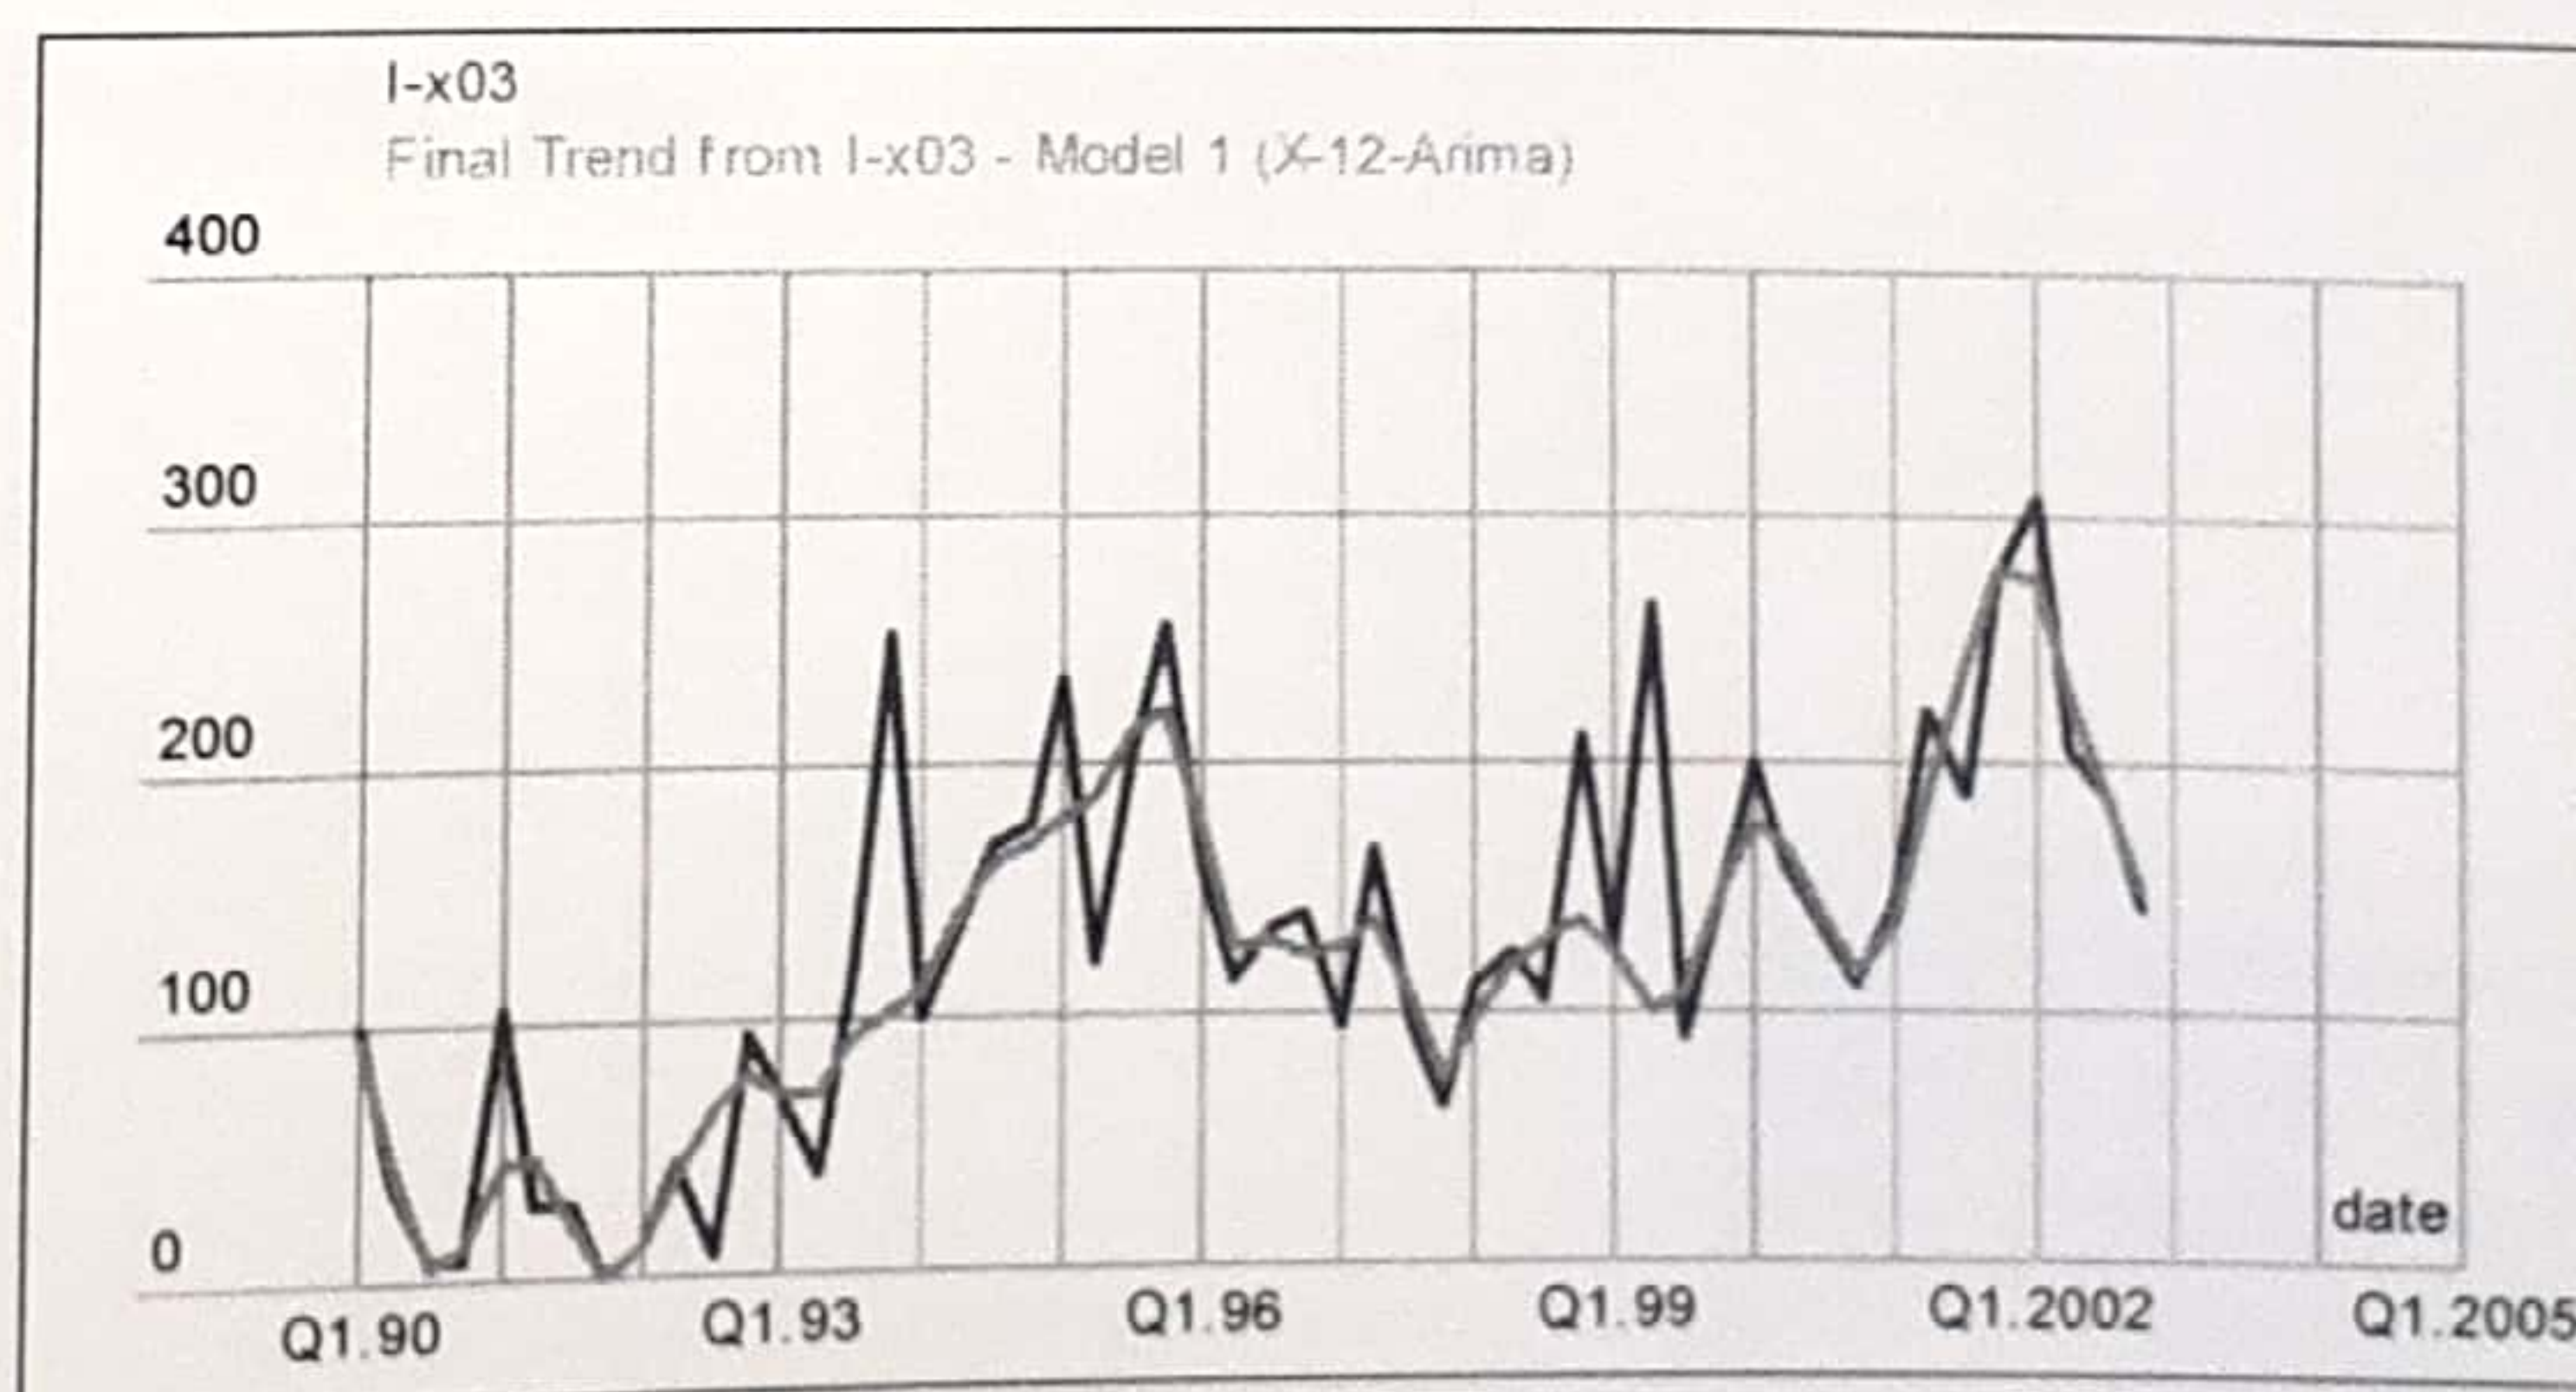
El porcentaje de outliers se mantiene, para esta serie, dentro de los límites establecidos. Alcanza solo un nivel de 3.85% del número original de valores de la serie, frente al máximo permitido del 10%.

La última medida de calidad del ajuste estacional con X12-ARIMA, se refiere al estadístico combinado Q. El valor significativo de 1.48 fuera del intervalo permitido evidencia que algún valor de los estadísticos M concernientes a la calidad de la descomposición se encuentran fuera de la región de aceptación. Con lo que se concluye que el modelo falla algunas pruebas de diagnóstico de la calidad del ajuste estacional y por ello es rechazada.

Para concluir el análisis a la serie de exportaciones I-x03 se muestran los gráficos relativos a la serie original, la tendencia final, la ajustada estacionalmente final y las tres series juntas.


GRÁFICO 4.3

SERIE ORIGINAL Y DE TENDENCIA FINAL PARA I-x03 ⁽¹⁾



⁽¹⁾ I-x03: Serie de Índices de Precios cuyo año base es 1993 = 100

GRÁFICO 4.4

SERIE ORIGINAL Y AJUSTADA ESTACIONALMENTE
FINAL PARA I-x03 ⁽¹⁾

⁽¹⁾ I-x03: Serie de Índice de Precios cuyo año base es 1993 = 100

El usuario puede notar el similar patrón de la serie original y la ajustada estacionalmente, debido a que el componente estacional no fue lo suficientemente fuerte para ser incluido dentro del proceso.





GRÁFICO 4.5

SERIE ORIGINAL, DE TENDENCIA FINAL Y AJUSTADA ESTACIONALMENTE FINAL PARA I-x03 ⁽¹⁾

⁽¹⁾ I-x03: Serie de Índice de Precios cuyo año base es 1993 = 100

Esta serie I-x03 es bastante irregular, la varianza no es constante y se pueden observar outliers del tipo AO, en diferentes periodos, siendo los más significantes los del periodo Q4-1993 y Q2-1999. Similar serie original y ajustada estacionalmente, serie de tendencia ligeramente plana pero irregular.

Siguiendo con el análisis a las series rechazadas a continuación se muestran tablas de información del modelo y del diagnóstico, además de los gráficos, de ciertas series escogidas del total de series procesadas. El análisis se puede extender a las series no presentadas y por ello su omisión en esta investigación.

TABLA 10
INFORMACIÓN SOBRE EL MODELO (X12-ARIMA) PARA LA
SERIE DE IMPORTACIONES I-m09

Información sobre el Modelo	Modelo 1 (X12-ARIMA)
Periodo de las series (Nº de observaciones)	Q1. 1987 – Q4. 2002 (64)
Periodo del Modelo (Nº de observaciones)	Q1. 1987 – Q4. 2002 (64)
Método	X12-ARIMA
PRE - AJUSTE	
Transformación	Logaritmica
Corrección de Media	Si
Valor Medio-t	-0.05 [-1.990, 1.990] 5%
Corrección por Efecto de Días Laborables	Ninguna
Corrección por Efectos de Pascua	Si (6 días)
Valor t para Efecto de Pascua	-0.16 [-1.990, 1.990] 5%
Corrección por Outliers (Atípicos)	Automático: AO, LS, TC; 10 outliers fijados
Valor – Crítico t	3.713
LS Q1.1990 valor -t	6.44 [-3.713, 3.713] val. crít.
TC Q4.1997 valor -t	7.19 [-3.713, 3.713] val. crít.
LS Q1.1998 valor -t	10.72 [-3.713, 3.713] val. crít.
LS Q3.1998 valor -t	-11.46 [-3.713, 3.713] val. crít.
TC Q4.1998 valor -t	4.45 [-3.713, 3.713] val. crít.
LS Q2.1999 valor -t	-16.30 [-3.713, 3.713] val. crít.
TC Q4.1999 valor -t	6.60 [-3.713, 3.713] val. crít.
TC Q2.2001 valor -t	4.25 [-3.713, 3.713] val. crít.
AO Q1.2002 valor -t	18.54 [-3.713, 3.713] val. crít.
TC Q3.2002 valor -t	6.78 [-3.713, 3.713] val. crít.
Corrección por Observaciones Perdidas	Ninguna
Corrección por otros efectos de Regresión	Ninguna
Especificaciones del Modelo ARIMA	(0,1,0) (0,1,1) (fijado)
Valor MA(lag 4) estacional	-0.0929
Valor -t para MA (lag 4) estacional	0.74 [-1.990, 1.990] 5%
Método de Estimación	Máxima Verosimilitud Exacto
DESCOMPOSICIÓN	
Descomposición X-11	Con predicciones ARIMA
Filtro Estacional X-11	MA 3X1
Filtro Tendencia X-11	MA de Henderson de 5 términos
Estacionalidad	No significativa

Elaborado por: V. Vásquez
Software: Demetra 2.0

En esta serie se ha realizado inicialmente una transformación logarítmica (basada en el criterio de Akaike de X12-ARIMA en la pre-prueba) y corrección de la media. El estadístico t cae dentro del intervalo de confianza del 95% por lo que se dice que existe evidencia estadística para afirmar que la media de la serie es cero.

No se realiza ajuste por efecto de Días Laborables, pero sí por efectos de Pascua. 6 días antes de la Pascua son considerados para la variable de regresión definida para este efecto. También, se muestra que el valor t para este caso cae dentro del intervalo de confianza del 95%.

Es importante el número de outliers detectados en el módulo automático, 10 en total y de diferentes tipos: AO, TC y LS. Aparentemente esta serie es bastante irregular, algún agente económico extraordinario afectó a esta serie. Cada uno de los valores detectados son significativos, no siguen el modelo ARIMA escogido.

En cuanto a las especificaciones del modelo y el método de estimación, la serie I-m09 se ajusta al modelo RegARIMA (0,

1, 0)(0, 1, 1) estimado mediante el método de Máxima Verosimilitud. Se presenta, además, el valor del coeficiente estacional (retardo cuatro) de la parte MA(1) y el estadístico t que en este caso está dentro del intervalo, lo que indica que el coeficiente estimado no es estadísticamente significativo.

En el proceso de descomposición se detalla lo siguiente: se realiza la descomposición con predicciones ARIMA, es decir, se utiliza el modelo para añadir observaciones en la parte final de la serie y no se usan filtros simétricos que disminuyen la calidad del ajuste estacional. El filtro estacional usado es uno de 3x1 términos y el de tendencia es el de Henderson de 5 términos.

Para esta serie la estacionalidad no es significativa, es decir el ajuste estacional no es recomendado con el modelo especificado sino con un RegARIMA sin parte estacional. La serie original y la ajustada estacionalmente serán las mismas al final del proceso.

El grafico 4.6 muestra la aseveración anterior y todos los resultados en torno al procesamiento de la serie.





GRÁFICO 4.6

SERIE ORIGINAL Y AJUSTADA ESTACIONALMENTE FINAL PARA I-m09 ⁽¹⁾




⁽¹⁾ I-m09: Serie de Índice de Precios cuyo año base es 1993 = 100

Nótese el significativo outlier AO del periodo Q1.2002 y los LS de Q1.1998, Q3.1998 y Q2.1999. La transformación logarítmica efectuada también es notoria en el gráfico de la serie.

La siguiente tabla mostrada es la referente a los Diagnósticos del SA efectuado.

TABLA 11
INFORMACIÓN DE DIAGNÓSTICO DEL AJUSTE ESTACIONAL DE LA SERIE DE IMPORTACIONES I-m09 CON X12-ARIMA

Información de Diagnóstico	Modelo 1 (X12-ARIMA)
Indice de Calidad de Ajuste Estacional (hasta 10)	7.838 [0, 10] ad-hoc



Curtosis	4.13 [0.98, 5.02] 0.1%
Error en Predicciones	
Error en Predicciones sobre los últimos años	7.88% [0%, 15.0%] ad-hoc
Outliers	
Porcentaje de Outliers	15.63% [0%, 10.0%] ad-hoc
Criterio para Descomposición	
Estadístico combinado Q (M1, M3-M11)	0.88 [0, 1] ad-hoc

Software: Demetra 2.0

Elaborado por: V. Vásquez

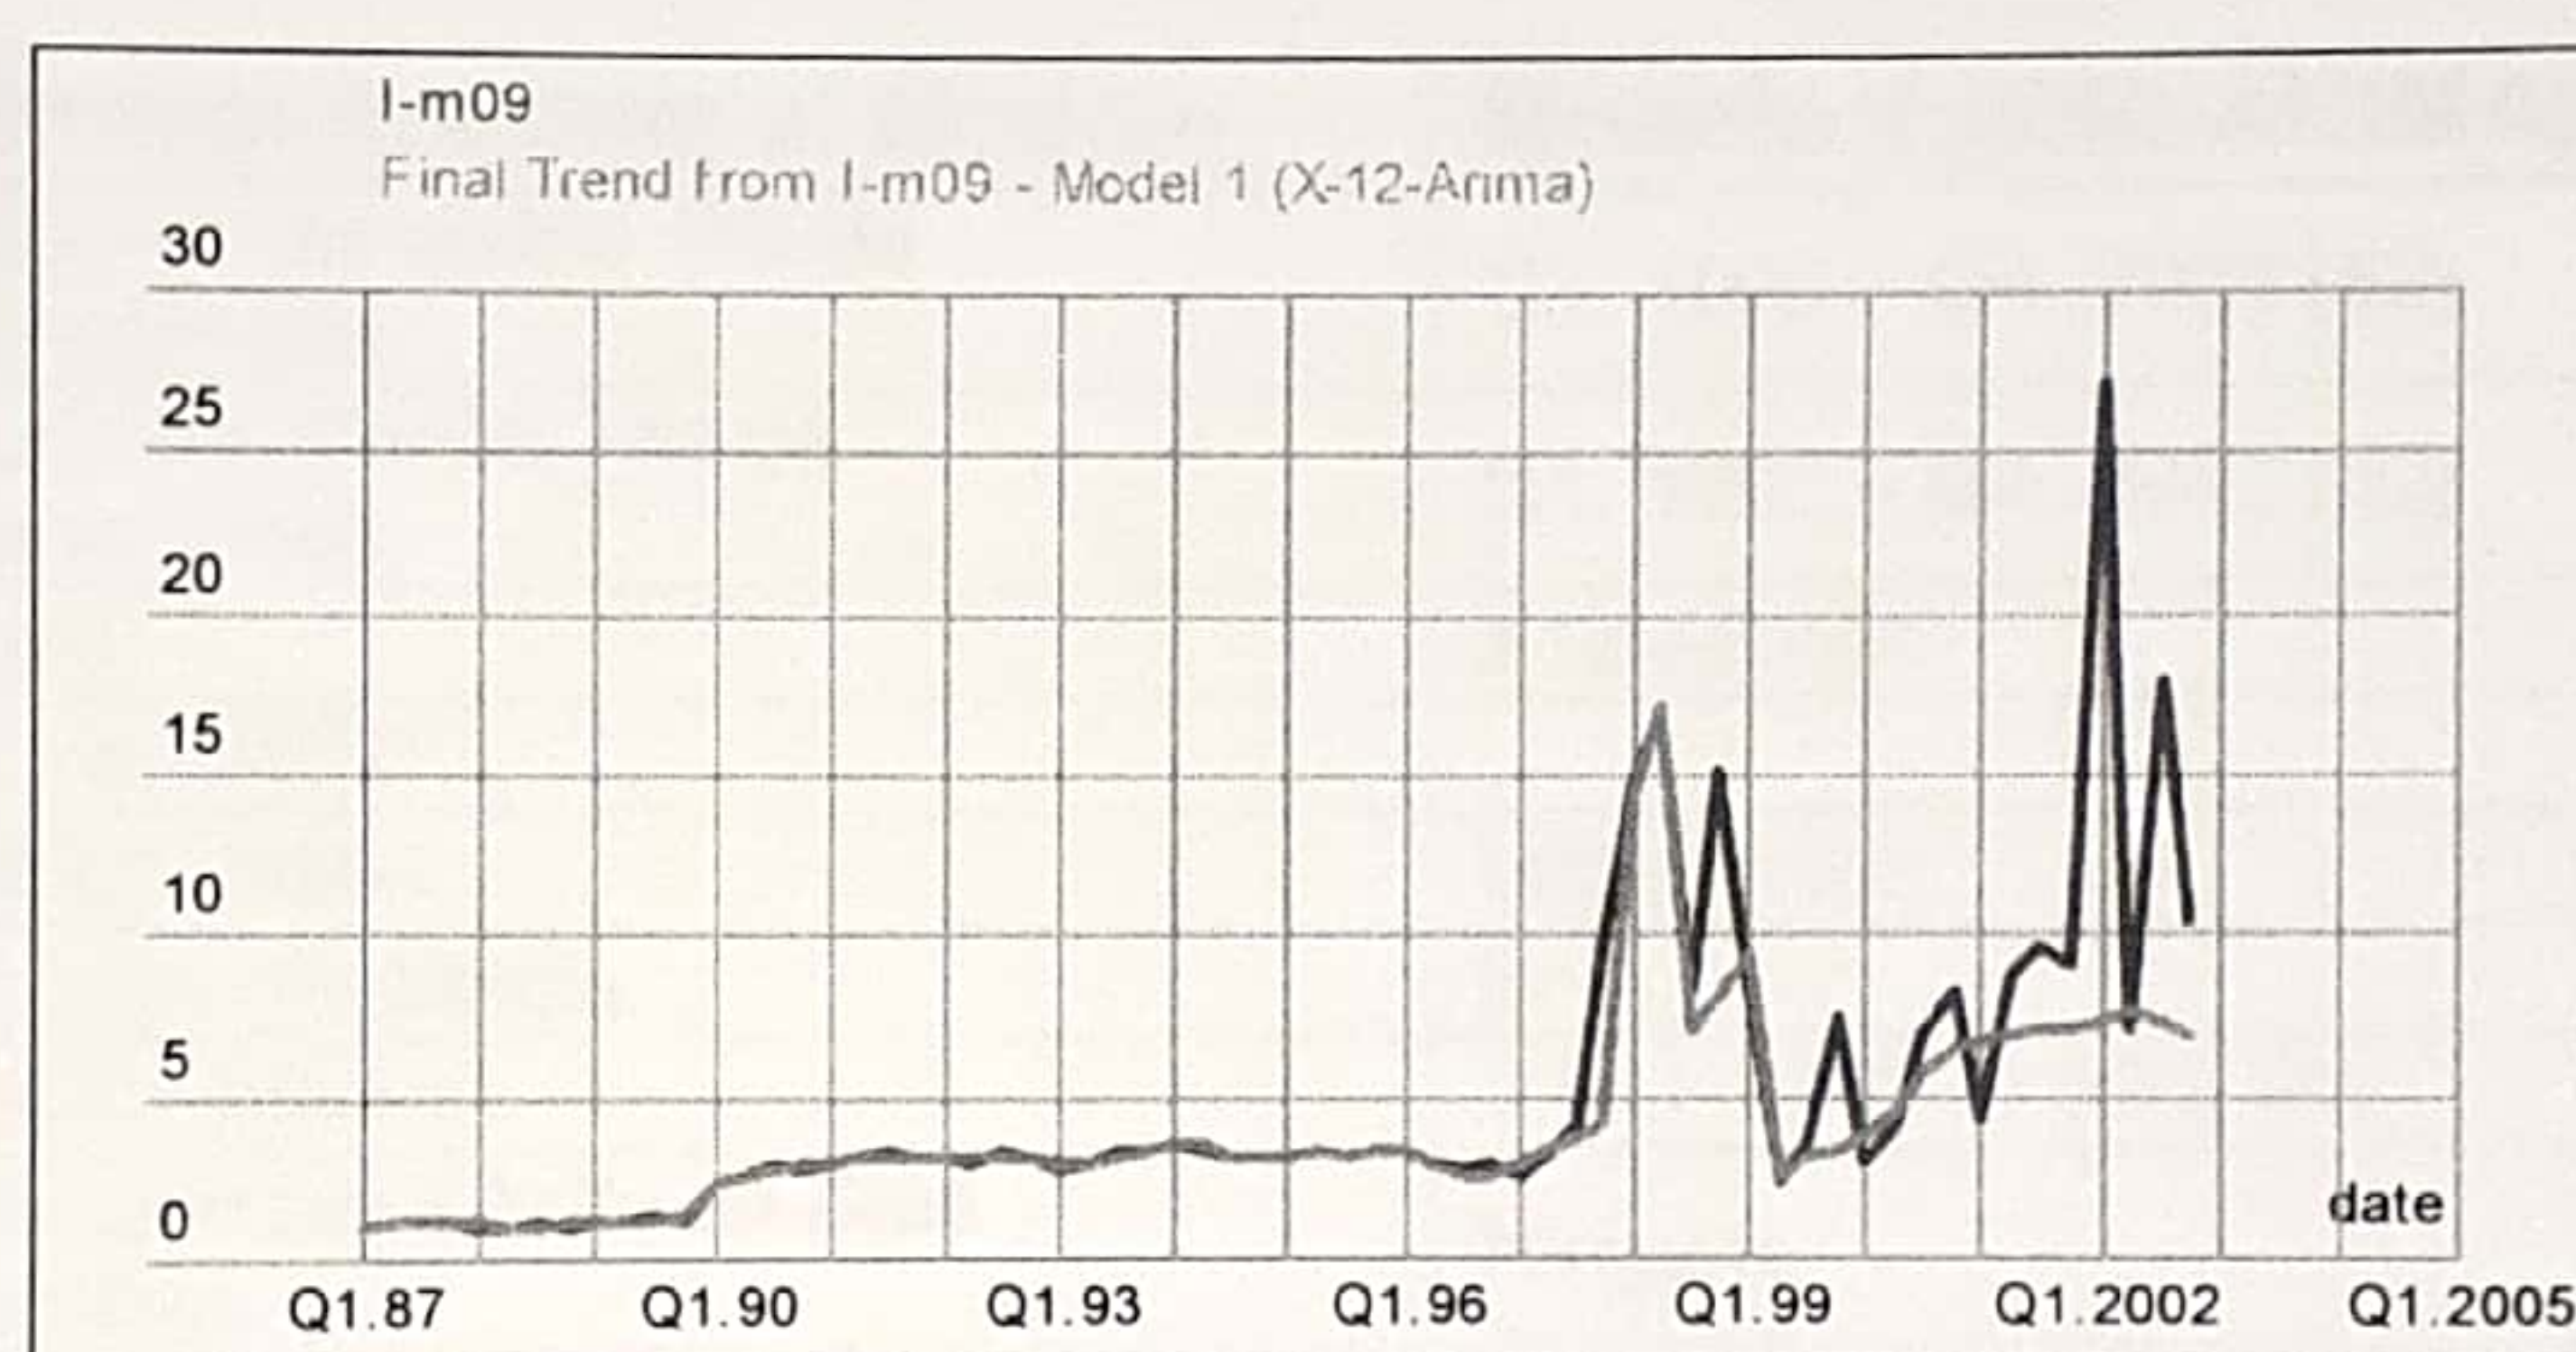
Para la serie I-m09 todos los estadísticos que muestran la calidad del ajuste estacional se encuentran dentro de sus respectivos intervalos de confianza. Sin embargo, existe un gran problema debido al número de outliers encontrados. Esto puede significar que hay problemas en cuanto a la estabilidad del proceso (los métodos de tipo ARIMA son muy sensibles a las perturbaciones que pudieran presentar los datos, esto influye en la identificación del modelo y la estimación de los parámetros) o a la fiabilidad de los datos.

Por esta razón el modelo fijado pudiera no ajustarse de manera efectiva a los datos, y en conclusión se rechaza para el ajuste estacional.

Finalmente se muestra la gráfica 4.7 de la Serie Original y la Tendencia Final, y la gráfica 4.8 con las tres series juntas (original, tendencia y ajustada estacionalmente).

GRÁFICO 4.7


SERIE ORIGINAL Y DE TENDENCIA FINAL PARA I-m09 ⁽¹⁾



⁽¹⁾ I-m09: Serie de Índice de Precios cuyo año base es 1993 = 100

GRÁFICO 4.8

SERIE ORIGINAL, DE TENDENCIA FINAL Y AJUSTADA ESTACIONALMENTE FINAL PARA I-m09 ⁽¹⁾



⁽¹⁾ I-m09: Serie de Índice de Precios cuyo año base es 1993 = 100

La siguiente serie a ser analizada es la de exportaciones I-x06, la Tabla 12 revela información relativa al modelo de dicha serie.

TABLA 12
INFORMACIÓN SOBRE EL MODELO (X12-ARIMA) PARA LA
SERIE DE EXPORTACIONES I-x06

Información sobre el Modelo	Modelo 1 (X12-ARIMA)
Periodo de las series (Nº de observaciones)	Q1. 1990 – Q4. 2002 (52)
Periodo del Modelo (Nº de observaciones)	Q1. 1990 – Q4. 2002 (52)
Método	X12-ARIMA
PRE - AJUSTE	
Transformación	Logaritmica
Corrección de Media	Si
Valor Medio-t	2.43 [-1.990, 1.990] 5%
Corrección por Efecto de Días Laborables	Ninguna
Corrección por Efectos de Pascua	Ninguna
Corrección por Outliers (Atípicos)	Automático: AO, LS, TC
Valor – Crítico t	3.671
Corrección por Observaciones Perdidas	Ninguna
Corrección por otros efectos de Regresión	Ninguna
Especificaciones del Modelo ARIMA	(1,1,2) (0,0,0) (fijado)
Valor AR(lag 1) no estacional	0.8903
Valor -t para AR (lag 1) no estacional	-10.81 [-2.000, 2.000] 5%
Valor MA(lag 1) no estacional	0.3219
Valor -t para MA (lag 1) no estacional	-2.85 [-2.000, 2.000] 5%
Valor MA(lag 2) no estacional	-0.6718
Valor -t para MA (lag 2) no estacional	6.14 [-2.000, 2.000] 5%
Método de Estimación	Máxima Verosimilitud Exacto
DESCOMPOSICIÓN	
Descomposición X-11	Con predicciones ARIMA
Filtro Estacional X-11	MA 3X1
Filtro Tendencia X-11	MA de Henderson de 7 términos
Estacionalidad	No significativa

Software: Demetra 2.0
Elaborado por: V. Vásquez

Para la serie de exportaciones I-x06 se realiza una transformación logarítmica a la serie de datos original con el fin de conseguir que esta sea estacionaria. Adicionalmente, hay una corrección de la media aunque el estadístico t cae fuera del intervalo de confianza del 95%. Con esto se concluye que no existe evidencia estadística para afirmar que la media de la serie transformada es igual a cero.

No hay corrección por Efecto de Días Laborables, Efecto Pascua, Outliers, Observaciones Perdidas u otros Efectos de Regresión.

Se realiza la especificación del modelo al que se ajusta la serie I-x06 $(1,1,2)(0,0,0)$. Se muestran cada uno de los coeficientes (retardos) y sus respectivos intervalos de confianza para determinar su significancia, concluyendo que los coeficientes de AR(1) y MA(2) son significantes por encontrarse fuera del intervalo de confianza.

Los parámetros seguidos para el proceso de descomposición son claramente especificados en la tabla 12, y siguen el mismo patrón de análisis descrito para las series anteriores.

La tabla 13 presenta Información relacionada a los Diagnósticos del Ajuste Estacional realizado a I-x06.

TABLA 13


INFORMACIÓN DE DIAGNÓSTICO DEL AJUSTE ESTACIONAL DE LA SERIE DE EXPORTACIONES I-x06 CON X12-ARIMA

Información de Diagnóstico	Modelo 1 (X12-ARIMA)
Indice de Calidad de Ajuste Estacional (hasta 10)	5.396 [0, 10] ad-hoc
Estadísticos sobre los Residuos	
Ljung-Box para residuos	7.42 [0, 32.90] 0.1%
Descripción de los Residuos	
Curtosis	2.20 [0.76, 5.24] 0.1%
Error en Predicciones	
Error en Predicciones sobre los últimos años	9.66% [0%, 15.0%] ad-hoc
Outliers	
Porcentaje de Outliers	0.00% [0%, 10.0%] ad-hoc
Criterio para Descomposición	
Estadístico combinado Q (M1, M3-M11)	1.47 [0, 1] ad-hoc

Software: Demetra 2.0

Elaborado por: V. Vásquez


En esta ocasión el modelo falla en algunas pruebas de diagnóstico. El estadístico combinado Q está fuera del intervalo permitido. Dependiendo del conocimiento que el usuario tenga acerca de la serie, esta medida se puede corregir con el uso del método de análisis detallado. Este aspecto queda a criterio del usuario finalmente.



Ahora los gráficos respectivos de la serie original, de tendencia final y Ajustada Estacionalmente Final.

GRÁFICO 4.9

SERIE ORIGINAL Y DE TENDENCIA FINAL PARA I-x06 ⁽¹⁾




⁽¹⁾ I-x06: Serie de Índice de Precios cuyo año base es 1993 = 100

En la gráfica 4.9 se puede apreciar la presencia de los abundantes movimientos irregulares de la serie original y la alisada componente tendencia-ciclo que solo en ocasiones permite observar las fechas de los picos y valles de la serie

La serie original y la ajustada estacionalmente tienen similar patrón debido a que X12-ARIMA no logró identificar estacionalidad significativa en la serie. El gráfico 4.10 muestra esta afirmación.

GRÁFICO 4.10
SERIE ORIGINAL Y AJUSTADA ESTACIONALMENTE
FINAL PARA I-x06 ⁽¹⁾




⁽¹⁾ I-x06: Serie de Índice de Precios cuyo año base es 1993 = 100

En el gráfico 4.11 se pueden apreciar las tres series juntas: la serie original, la serie ajustada estacionalmente (libre del componente irregular) y la serie tendencia-ciclo.

GRÁFICO 4.11

**SERIE ORIGINAL, DE TENDENCIA FINAL Y
AJUSTADA ESTACIONALMENTE FINAL PARA I-x06 ⁽¹⁾**



⁽¹⁾ I-x06: Serie de Índice de Precios cuyo año base es 1993 = 100

Para concluir el análisis de series rechazadas durante esta investigación, se muestran tablas y gráficos generados por DEMETRA para la serie de importaciones I-m07.

TABLA 14

**INFORMACIÓN SOBRE EL MODELO (X12-ARIMA) PARA LA
SERIE DE IMPORTACIONES I-m07**

Información sobre el Modelo	Modelo 1 (X12-ARIMA)
Periodo de las series (Nº de observaciones)	Q1. 1987 – Q4. 2002 (64)
Periodo del Modelo (Nº de observaciones)	Q1. 1987 – Q4. 2002 (64)
Método	X12-ARIMA
PRE - AJUSTE	
Transformación	Logarítmica
Corrección de Media	Si
Valor Medio-t	4.44 [-1.990, 1.990] 5%
Corrección por Efecto de Días Laborables	Ninguna
Corrección por Efectos de Pascua	Ninguna
Corrección por Outliers (Atípicos)	Automático: AO, LS, TC; 1 outliers fijado
Valor – Crítico t	3.713
LS Q3.1997 valor -t	5.01 [-3.713, 3.713] val. crít.
Corrección por Observaciones Perdidas	Ninguna
Corrección por otros efectos de Regresión	Ninguna
Especificaciones del Modelo ARIMA	(3,0,0) (1,0,1) (fijado)
Valor AR(lag 1) no estacional	-0.8121
Valor -t para AR (lag 1) no estacional	6.66 [-1.990, 1.990] 5%
Valor AR(lag 2) no estacional	0.0498
Valor -t para AR (lag 2) no estacional	-0.31 [-1.990, 1.990] 5%
Valor AR(lag 3) no estacional	-0.0959
Valor -t para AR (lag 3) no estacional	0.71 [-1.990, 1.990] 5%
Valor AR(lag 4) estacional	-0.8819
Valor -t para AR (lag 4) estacional	7.99 [-1.990, 1.990] 5%
Valor MA(lag 4) estacional	-0.6882
Valor -t para MA (lag 4) estacional	5.16 [-1.990, 1.990] 5%
Método de Estimación	Máxima Verosimilitud Exacto
DESCOMPOSICIÓN	
Descomposición X-11	Con predicciones ARIMA
Filtro Estacional X-11	MA 3X1
Filtro Tendencia X-11	MA de Henderson de 5 términos
Estacionalidad	Significante

Software: Demetra 2.0

Elaborado por: V. Vásquez

Para la serie I-m07 se realiza una transformación logarítmica y además una corrección de la media, aunque debido a que el estadístico t cae fuera del intervalo de aceptación se dice que no existe evidencia estadística para afirmar que la media de la serie transformada es cero.

Se da una corrección por motivo de outliers de tipo LS (Level Shift), que de acuerdo al valor mostrado en la tabla es significativo, y se debe excluir del total de observaciones de la serie.

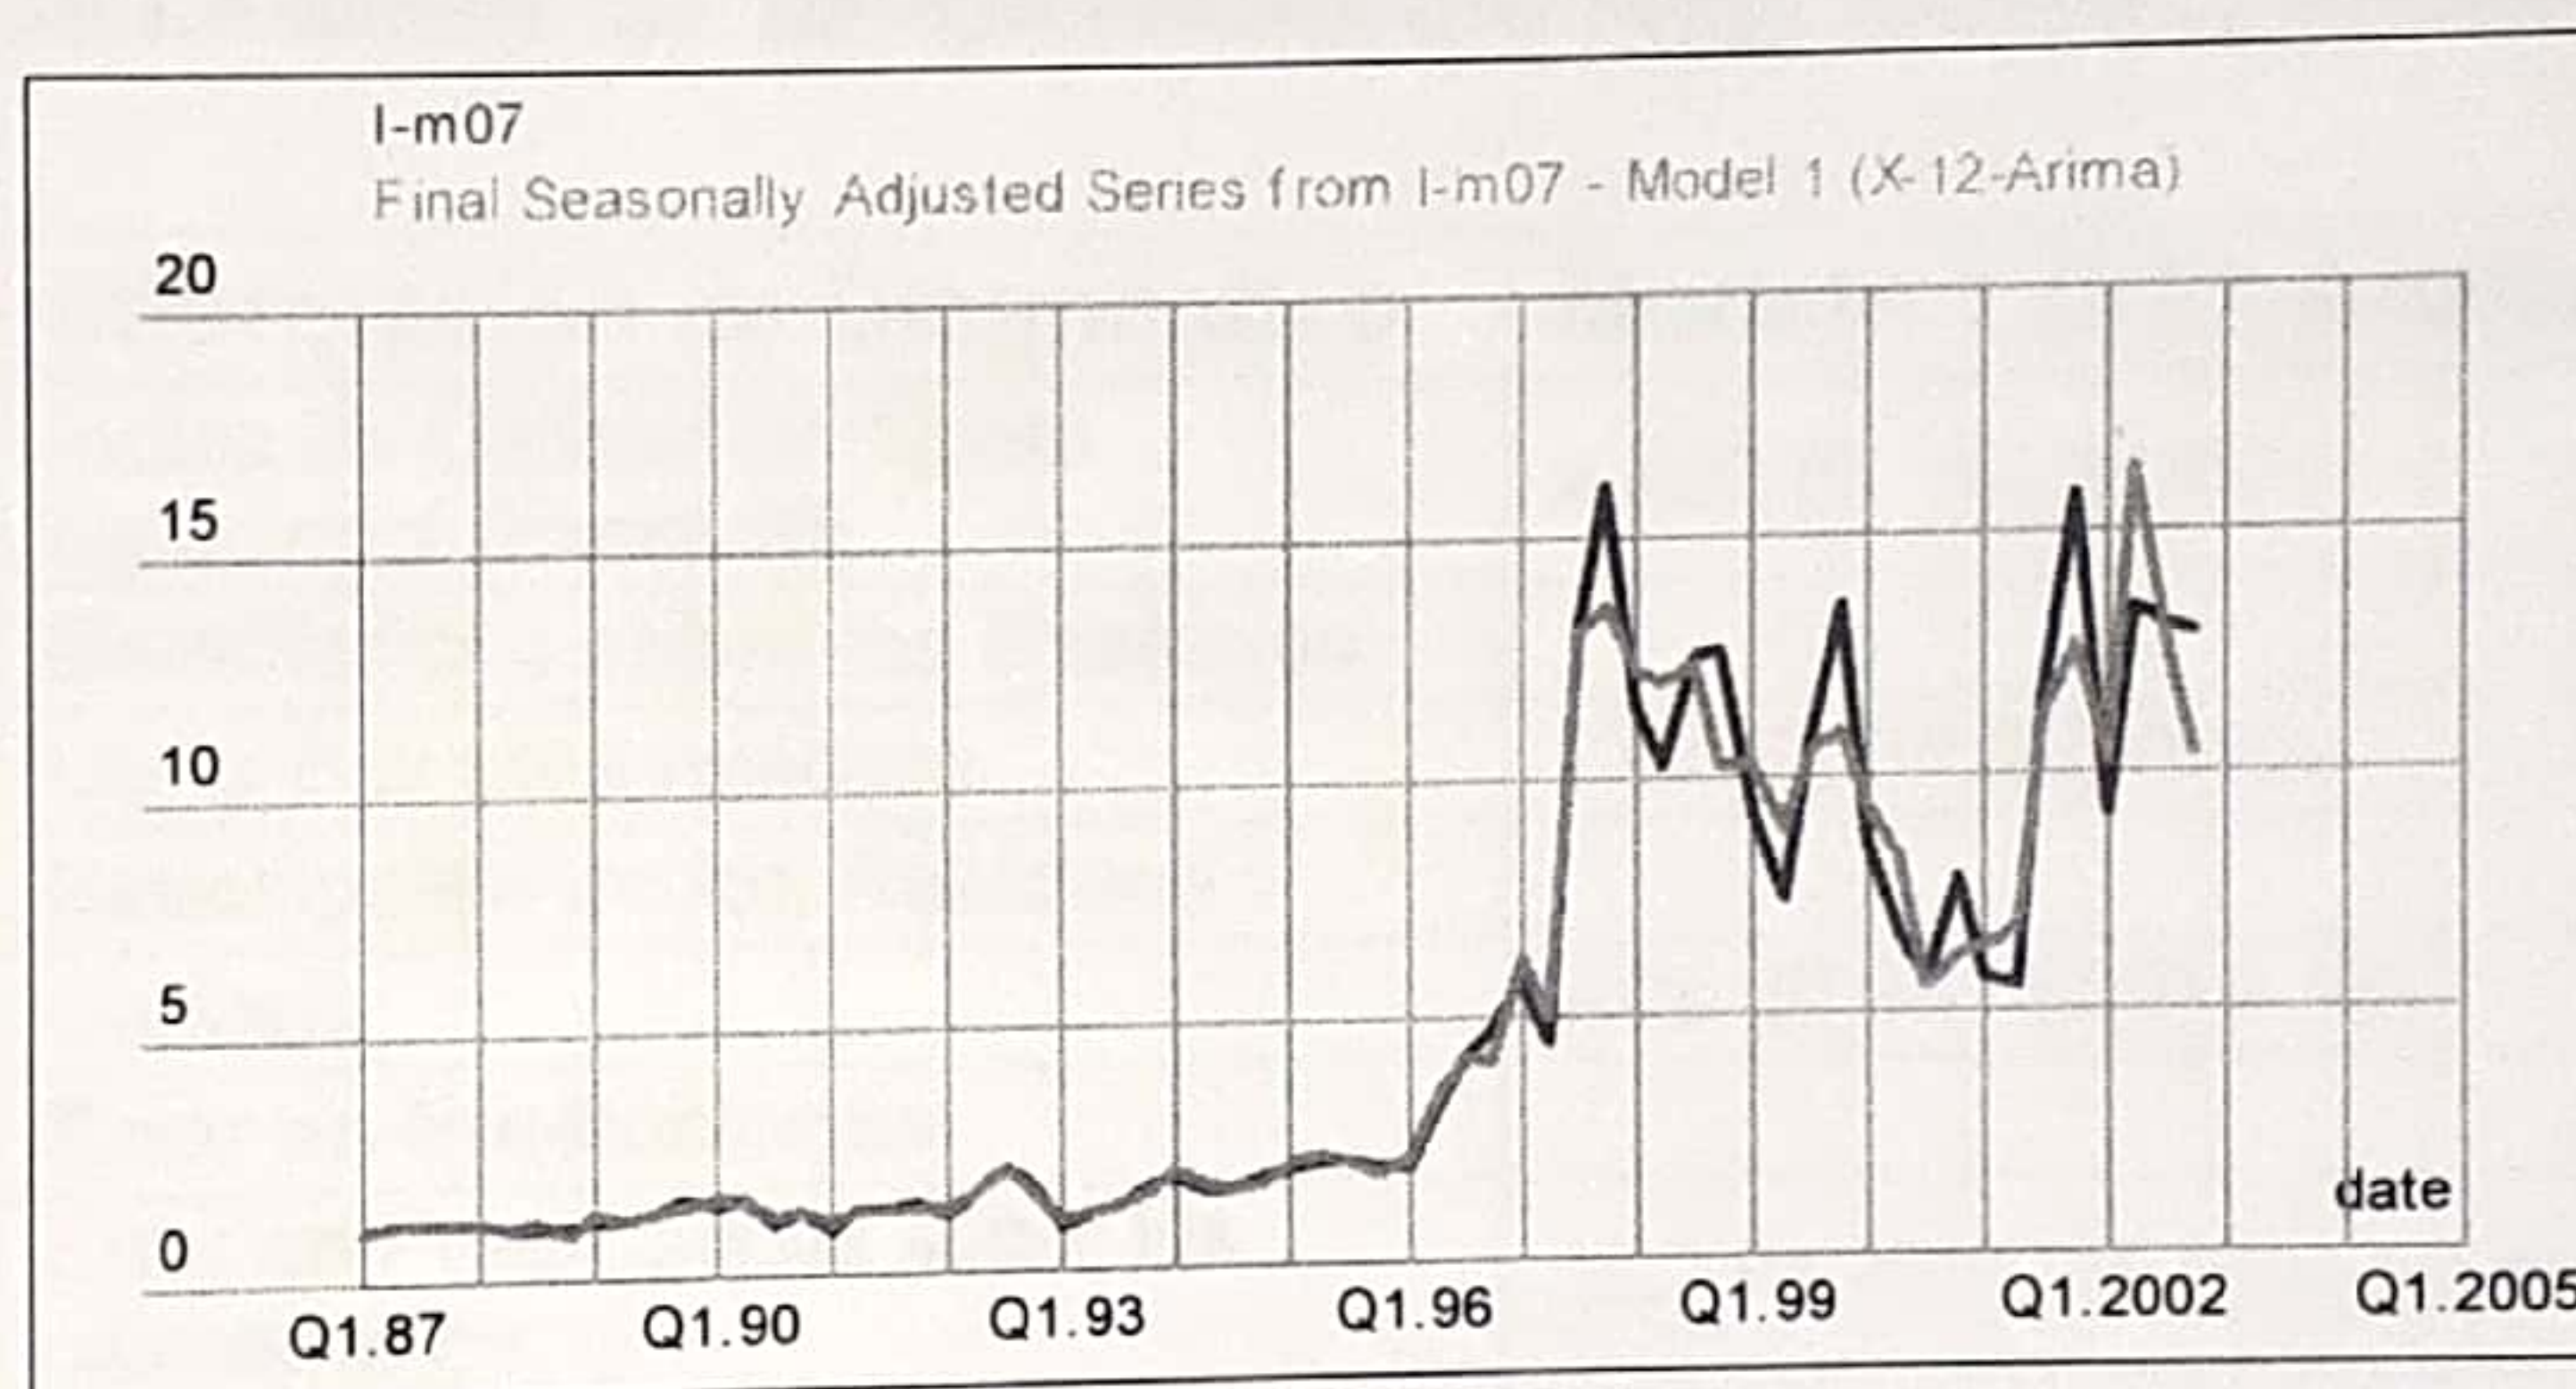
El modelo al que se ajustan los datos es del tipo RegARIMA $(3,0,0)(1,0,1)$ donde todos los coeficientes correspondientes a la parte AR y MA (no estacional y estacional) son significativos excepto el segundo y tercer retardo de la parte AR no estacional. Es decir estos coeficientes no siguen una distribución normal estándar.

Detalles sobre el proceso de descomposición son mostrados en la tabla 14, en cuanto a tipo de descomposición, filtro estacional y de tendencia usados, y además acerca de la significancia de la estacionalidad. En este caso, el lector

puede percatarse que X12-ARIMA ha considerado como significativo el nivel de estacionalidad de la serie. Por lo que es ajuste es más que recomendado.

GRÁFICO 4.12


SERIE ORIGINAL Y AJUSTADA ESTACIONALMENTE FINAL PARA I-m07 ⁽¹⁾



⁽¹⁾ I-m07: Serie de Índice de Precios cuyo año base es 1993 = 100

En el gráfico 4.12 se puede apreciar la serie original y la ajustada estacionalmente final. Esta última está libre del componente irregular que le afecta y además de significantes outliers.

Sin embargo, la tabla 15 muestra porque la serie fue rechazada. Básicamente porque el porcentaje de error en las



permitido, sólo el conocimiento del usuario acerca de la serie permitiría corregirla a través del módulo manual y definirla como aceptada.

TABLA 15


INFORMACIÓN DE DIAGNÓSTICO DEL AJUSTE ESTACIONAL DE LA SERIE DE IMPORTACIONES I-m07 CON X12-ARIMA

Información de Diagnóstico	Modelo 1 (X12-ARIMA)
Índice de Calidad de Ajuste Estacional (hasta 10)	4.497 [0, 10] ad-hoc
Estadísticos sobre los Residuos	
Ljung-Box para residuos	1.67 [0, 32.90] 0.1%
Descripción de los Residuos	
Curtosis	3.06 [0.98, 5.02] 0.1%
Error en Predicciones	
Error en Predicciones sobre los últimos años	16.71% [0%, 15.0%] ad-hoc
Outliers	
Porcentaje de Outliers	1.56% [0%, 10.0%] ad-hoc
Criterio para Descomposición	
Estadístico combinado Q (M1, M3-M11)	0.90 [0, 1] ad-hoc

Software: Demetra 2.0

Elaborado por: V. Vásquez

GRÁFICO 4.13

SERIE ORIGINAL, DE TENDENCIA FINAL Y
AJUSTADA ESTACIONALMENTE FINAL PARA I-m07 ⁽¹⁾

⁽¹⁾ I-m07: Serie de Índice de Precios cuyo año base es 1993 = 100

En este gráfico se nota que el componente irregular fue suavizado, aproximándose la serie filtrada por la estacionalidad a la forma de la tendencia-ciclo, y permitiendo fijar los puntos de giro sin lugar a dudas.

4.4.2. Resultados Series Aceptadas en el Ajuste Estacional

Luego de analizar brevemente algunas representativas series rechazadas durante el Ajuste Estacional, a continuación se muestran determinadas series aceptadas, tanto de exportaciones como de importaciones y manufactura. Al igual que el análisis anterior, este se puede hacer extensivo a las series no mostradas.

La primera serie analizada es la de exportaciones I-x01, para la que se presenta la Tabla 16 de Información sobre el Modelo.

Para esta serie I-x01 que consta de 52 observaciones, no se realiza ningún tipo de transformación (esto de acuerdo al Criterio de Akaike en la pre-prueba) pero si un ajuste de Media. Por lo que, debido al valor del estadístico t que cae dentro del intervalo de confianza del 95%, se concluye que existe evidencia estadística para asegurar que la media de la serie es cero.

TABLA 16

**INFORMACIÓN SOBRE EL MODELO (X12-ARIMA) PARA LA
SERIE DE EXPORTACIONES I-x01**


Información sobre el Modelo	Modelo 1 (X12-ARIMA)
Periodo de las series (Nº de observaciones)	Q1. 1990 – Q4. 2002 (52)
Periodo del Modelo (Nº de observaciones)	Q1. 1990 – Q4. 2002 (52)
Método	X12-ARIMA
PRE - AJUSTE	
Transformación	Ninguna
Corrección de Media	Si
Valor Medio-t	-0.49 [-2.000, 2.000] 5%
Corrección por Efecto de Días Laborables	2 Variable(s) de Regresión
Valor - t Trad1	-0.04 [-2.000, 2.000] 5%
Valor - t Trad2	0.04 (derivado) [-2.000, 2.000] 5%
Valor - t Año Bisiesto	0.23 [-2.000, 2.000] 5%
Corrección por Efectos de Pascua	Ninguna
Corrección por Outliers (Atípicos)	Automático: AO, LS, TC; 1 outliers fijado
Valor – Crítico t	3.671
LS Q3.1997 valor -t	4.25 [-3.671, 3.671] val. crit.
Corrección por Observaciones Perdidas	Ninguna
Corrección por otros efectos de Regresión	Ninguna
Especificaciones del Modelo ARIMA	(0,1,1) (0,1,1) (fijado)
Valor MA (lag 1) no estacional	-0.4129
Valor -t para MA (lag 1) no estacional	3.40 [-2.000, 2.000] 5%
Valor MA(lag 4) estacional	-0.9817
Valor -t para MA (lag 4) estacional	11.04 [-2.000, 2.000] 5%
Método de Estimación	Máxima Verosimilitud Exacto
DESCOMPOSICIÓN	
Descomposición X-11	Con predicciones ARIMA
Filtro Estacional X-11	MA 3X5
Filtro Tendencia X-11	MA de Henderson de 5 términos
Estacionalidad	Significante

Software: Demetra 2.0
Elaborado por: V. Vásquez

Para I-x01, en particular, se realiza un ajuste por Efecto de Días Laborables. El valor detectado es 2 variables de regresión, lo que indica que se ha efectuado una corrección por diferencias en la actividad económica de los días laborables y por longitud de periodo. Esto es, no hay diferencias en la actividad económica entre los días laborables (Lunes a Viernes) pero si entre estos y los días no laborables (Sábado y Domingo), además se ha considerado el total de número de días por periodo y la presencia del año bisiesto. Se presenta el estadístico t para cada una de las variables de regresión, que cae dentro del intervalo de confianza respectivo.

No hay corrección por Efectos de Pascua pero si se ha detectado un outlier tipo LS (Cambio de Nivel "Level Shift"), que de acuerdo al intervalo presentado se concluye que es significativo.

El modelo ARIMA identificado y seleccionado al que se ajustan los datos es el $(0,1,1)(0,1,1)$, donde el coeficiente correspondiente a MA(1) es igual a -0.4129 y para $MA_s(4)$ es -0.9817, para el orden q y sq respectivamente de



(0,1,1)(0,1,1). Para cada uno de los estimadores del modelo se presenta un valor t , que por caer fuera del intervalo, indica su significancia.

Hasta aquí se ha explicado la parte correspondiente al Proceso de Pre-Ajuste, DEMETRA adicionalmente muestra información referente al Proceso de Descomposición. Este detalle sólo se muestra cuando el Ajuste Estacional se realiza con X12-ARIMA.

Así se indica que a la serie se le agregan valores en su parte final con la ayuda de "predicciones ARIMA", es decir se utiliza el modelo seleccionado para predecir valores y de esta forma mejorar la calidad de la descomposición.

También se indican los tipos de filtros utilizados para estimar la tendencia y la estacionalidad, para esta serie el Filtro de Tendencia de Henderson utilizado es uno de 5 términos y el Filtro de estacionalidad es uno simple de 3x5 términos. Es de recordar, que los filtros largos (mayor número de términos) son recomendables cuando se tienen movimientos estacionales estables y los cortos cuando el patrón de

estacionalidad es muy inestable, además el filtro seleccionado es utilizado para todos los periodos de la serie.

La parte final de la Tabla 16, indica la significancia de la estacionalidad detectada por X12-ARIMA, por lo que se recomienda el ajuste.


La siguiente Tabla número 17, muestra los resultados obtenidos por las Pruebas de Calidad del Ajuste Estacional, estas son las que en realidad indican si el modelo de SA es aceptado o no por DEMETRA, por supuesto de acuerdo a los parámetros indicados por el usuario.

TABLA 17

INFORMACIÓN DE DIAGNÓSTICO DEL AJUSTE ESTACIONAL DE LA SERIE DE EXPORTACIONES I-x01 CON X12-ARIMA

Información de Diagnóstico	Modelo 1 (X12-ARIMA)
Indice de Calidad de Ajuste Estacional (hasta 10)	4.778 [0, 10] ad-hoc
Estadísticos sobre los Residuos	
Ljung-Box para residuos	12.72 [0, 32.90] 0.1%
Error en Predicciones	
Error en Predicciones sobre los últimos años	12.47% [0%, 15.0%] ad-hoc
Outliers	
Porcentaje de Outliers	1.92% [0%, 10.0%] ad-hoc
Criterio para Descomposición	
Estadístico combinado Q (M1, M3-M11)	0.50 [0, 1] ad-hoc

Elaborado por: V. Vásquez
Software: Demetra 2.0



Al contrario de las tablas mostradas para las series rechazadas, esta tabla indica porque la serie de exportaciones I-x01 fue aceptada. Pasa todos los parámetros de calidad definidos.

El estadístico Ljung-Box para residuos se encuentra dentro del intervalo de confianza del 90%, es decir que hay evidencia estadística para afirmar que no existe autocorrelación en los residuos del modelo ARIMA fijado. El porcentaje de error en las predicciones sobre los últimos periodos de la serie está dentro del intervalo fijado, por lo que se dice que las predicciones no distan mucho de los verdaderos valores y que el modelo ARIMA seleccionado se ajustan muy bien a la serie.

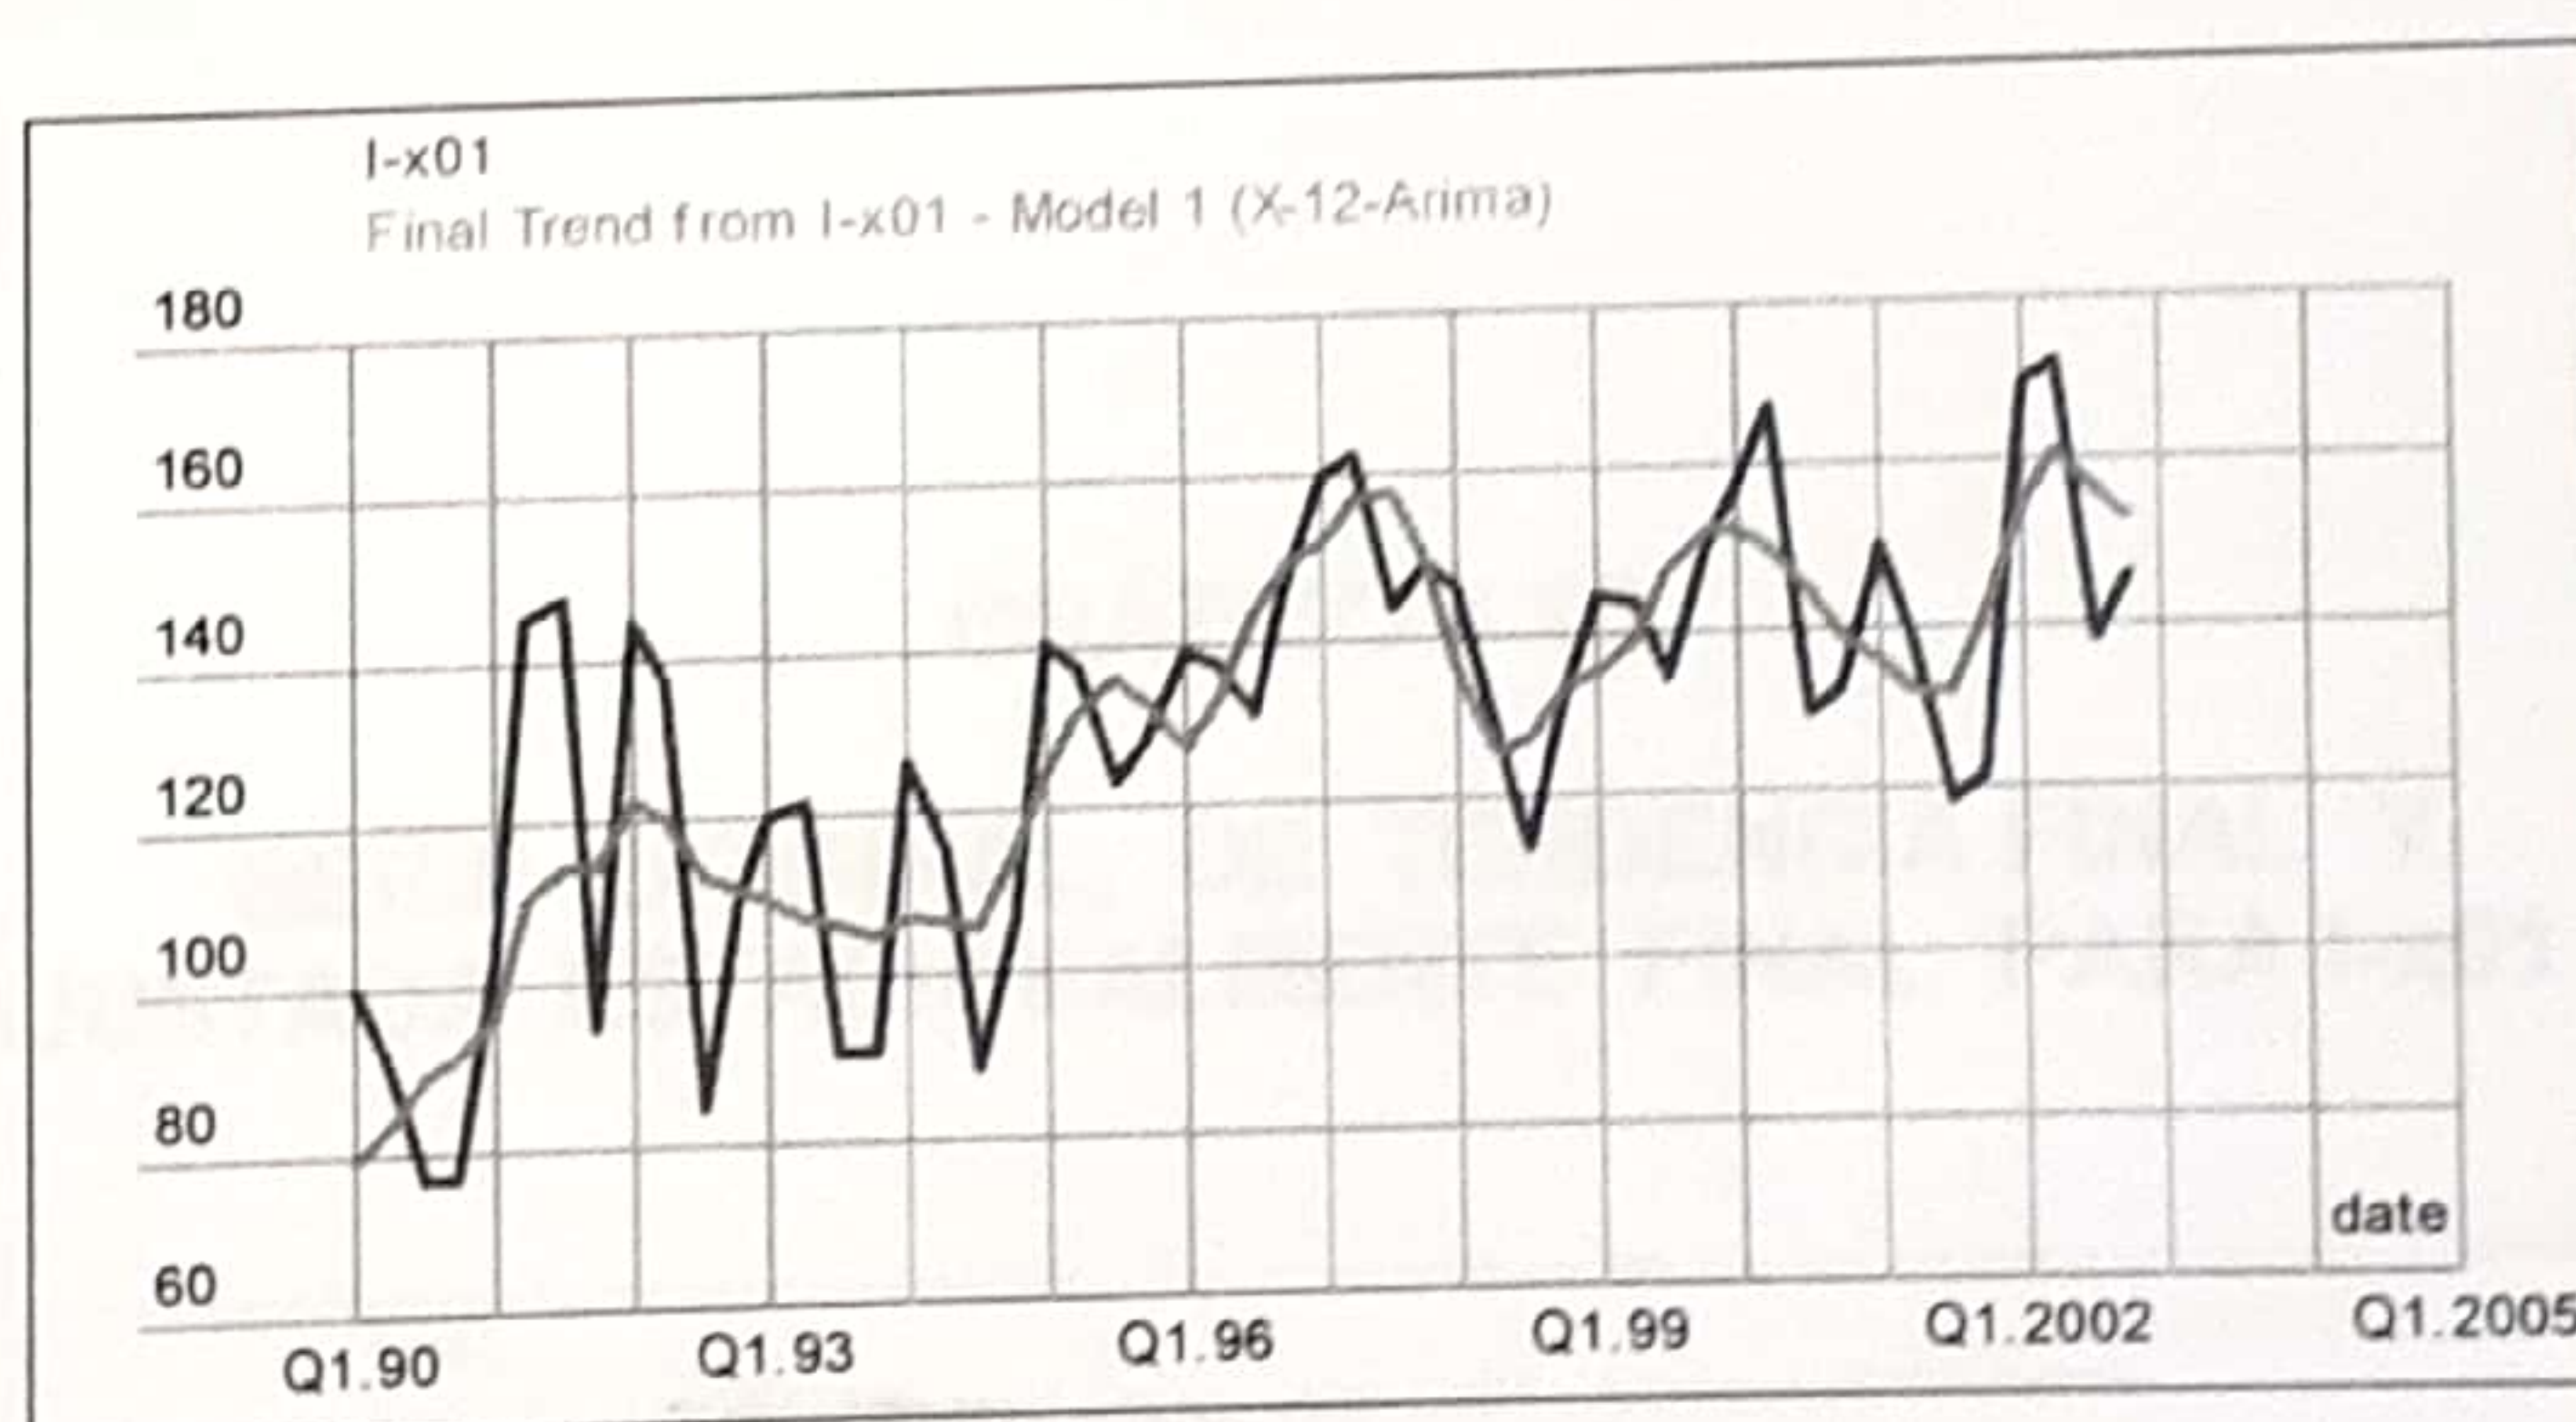
El porcentaje de outliers es reducido frente al número total de observaciones, lo que indica que el proceso es estable y que los datos son confiables.

Y lo más importante el estadístico Q combinado cae dentro del intervalo definido, por lo que se concluye que los estadísticos de Calidad concernientes a la Descomposición están dentro de la región de aceptación.

En el gráfico 4.14 se muestra la serie original y la serie tendencia-ciclo obtenida luego de la descomposición. Es claro que la tendencia de la serie I-x01 es creciente y que ha sido suavizada, aunque si permite observar los ciclos altos y bajos que ha sufrido la serie durante el periodo de análisis.

GRÁFICO 4.14


SERIE ORIGINAL Y DE TENDENCIA FINAL PARA I-x01 ⁽¹⁾



⁽¹⁾ I-x01: Serie de Índice de Precios cuyo año base es 1993 = 100


La serie original y la ajustada estacionalmente final se muestran en el gráfico 4.15, la serie desestacionalizada se muestra suavizada y con puntos de inflexión que en un análisis económico futuro serán motivo de estudio específico.

GRÁFICO 4.15

SERIE ORIGINAL Y AJUSTADA ESTACIONALMENTE
FINAL PARA I-x01 ⁽¹⁾

⁽¹⁾ I-x01: Serie de Índice de Precios cuyo año base es 1993 = 100

GRÁFICO 4.16

SERIE ORIGINAL, DE TENDENCIA FINAL Y
AJUSTADA ESTACIONALMENTE FINAL PARA I-x01 ⁽¹⁾

⁽¹⁾ I-x01: Serie de Índice de Precios cuyo año base es 1993 = 100



En este gráfico se condensan las tres series: original, tendencia-ciclo y ajustada estacionalmente final. Fácilmente se observa que la tendencia tiene un movimiento bastante más suave, esto se logra al eliminar los movimientos irregulares y estacionales con lo que se reduce la varianza.

Siguiendo con el análisis a las series aceptadas, toca el turno a la serie de manufactura I-pr20. Esta es una serie muy singular debido a que muestra un ajuste por diferentes efectos.

TABLA 18

INFORMACIÓN SOBRE EL MODELO (X12-ARIMA) PARA LA SERIE DE MANUFACTURA I-pr20

Automatador AO, LB, TC, 5 outliers	
Valor - Único	3740
LS Q3 1964	
LB Q3 1967	
AO Q2 1969	
TC Q2 1969	
LS Q3 1964	
Correlación por Componentes	
Correlación por los efectos de Reg. Est.	
Especificaciones del Modelo ARIMA	
Valor AR (lag 1) no estacional	0.9209
Valor -1 para AR (lag 1) no estacional	0.0791
Valor AR (lag 2) no estacional	0.0427
Valor -1 para AR (lag 2) no estacional	0.9573
Valor MA (lag 1) no estacional	-0.0427
Valor -1 para MA (lag 1) no estacional	0.9573
Valor MA (lag 2) no estacional	0.7695
Valor -1 para MA (lag 2) no estacional	0.2305
Valor MA (lag 4) estacional	-0.0427
Valor -1 para MA (lag 4) estacional	0.9573
Método de Estimación	Máxima Verosimilitud Exacta
DESCRIPCIÓN	
Descomposición X-11	Con especificaciones ARIMA
Princ. Estacional X-11	MA (4)
Princ. Tendencia X-11	Método de Henderson con 5 términos
Estacionalidad	Procedimiento presente
Elaborado por: V. Sánchez	
Software: DECOMA 2.0	

Información sobre el Modelo	Modelo 1 (X12-ARIMA)
Periodo de las series (Nº de observaciones)	Q1. 1984 – Q4. 2002 (76)
Periodo del Modelo (Nº de observaciones)	Q1. 1984 – Q4. 2002 (76)
Método	X12-ARIMA
PRE - AJUSTE	
Transformación	Logarítmica
Corrección de Media	Si
Valor Medio-t	0.75 [-1.990, 1.990] 5%
Corrección por Efecto de Días Laborables	6 Variable(s) de Regresión
Valor - t Trad1	-1.41 [-1.990, 1.990] 5%
Valor - t Trad2	2.12 [-1.990, 1.990] 5%
Valor - t Trad3	-2.01 [-1.990, 1.990] 5%
Valor - t Trad4	-2.04 [-1.990, 1.990] 5%
Valor - t Trad5	0.49 [-1.990, 1.990] 5%
Valor - t Trad6	0.72 [-1.990, 1.990] 5%
Valor - t Trad7	2.14 (derivado) [-1.990, 1.990] 5%
Corrección por Efectos de Pascua	Ninguna
Corrección por Outliers (Atípicos)	Automático: AO, LS, TC; 5 outliers fijado
Valor – Crítico t	3.749
LS Q3.1984 valor -t	5.79 [-3.749, 3.749] val. crít.
LS Q3.1987 valor -t	6.52 [-3.749, 3.749] val. crít.
AO Q2.1998 valor -t	6.97 [-3.749, 3.749] val. crít.
AO Q3.1999 valor -t	10.62 [-3.749, 3.749] val. crít.
LS Q1.2001 valor -t	20.10 [-3.749, 3.749] val. crít.
Corrección por Observaciones Perdidas	Ninguna
Corrección por otros efectos de Regresión	Ninguna
Especificaciones del Modelo ARIMA	(2,1,2) (0,1,1) (fijado)
Valor AR (lag 1) no estacional	-1.6269
Valor -t para AR (lag 1) no estacional	34.35 [-1.990, 1.990] 5%
Valor AR (lag 2) no estacional	0.9471
Valor -t para AR (lag 2) no estacional	-19.83 [-1.990, 1.990] 5%
Valor MA (lag 1) no estacional	-0.9947
Valor -t para MA (lag 1) no estacional	11.54 [-1.990, 1.990] 5%
Valor MA (lag 2) no estacional	0.7666
Valor -t para MA (lag 2) no estacional	-9.26 [-1.990, 1.990] 5%
Valor MA (lag 4) estacional	-0.0427
Valor -t para MA (lag 4) estacional	0.32 [-1.990, 1.990] 5%
Método de Estimación	Máxima Verosimilitud Exacto
DESCOMPOSICIÓN	
Descomposición X-11	Con predicciones ARIMA
Filtro Estacional X-11	MA 3X3
Filtro Tendencia X-11	MA de Henderson de 5 términos
Estacionalidad	Probablemente presente

Elaborado por: V. Vásquez
Software: Demetra 2.0

Para la serie I-pr20 la tabla 18 que muestra DEMETRA, indica que para las 76 observaciones de la serie se realizó una transformación logarítmica y un ajuste de media, donde el estadístico t que cae dentro del intervalo de confianza indica que existe evidencia estadística para afirmar que la media es cero (siempre referente al componente irregular final que debe tener una distribución normal con media cero).

Hay ajuste por efecto de días laborables con 6 variables de regresión, lo que revela una variación en la actividad económica de todos los días laborables (Lunes a Viernes) y entre estos y los fines de semana (Sábado y Domingo). Adicionalmente, en este ajuste también se involucra el número de días por periodo (longitud del periodo).

Hay detección y corrección de outliers en diferentes periodos de la serie, y ningún ajuste por efecto de Pascua y otros factores de regresión.


El modelo al que se ajustan los datos es el RegARIMA $(2,1,2)(0,1,1)$ para el que se muestran los valores de los coeficientes de AR (2), MA (2) y $MA_S(4)$. Cada uno de ellos

es significativo excepto el correspondiente a la parte estacional.

Los detalles del Proceso de Descomposición mostrados en la tabla 18 son muy entendibles, sólo resta aclarar la parte de la estacionalidad que en esta ocasión muestra un resultado de "Probablemente Presente". Esto indica que X12-ARIMA identificó una estacionalidad incierta en la serie y que un ajuste podría ser recomendado.

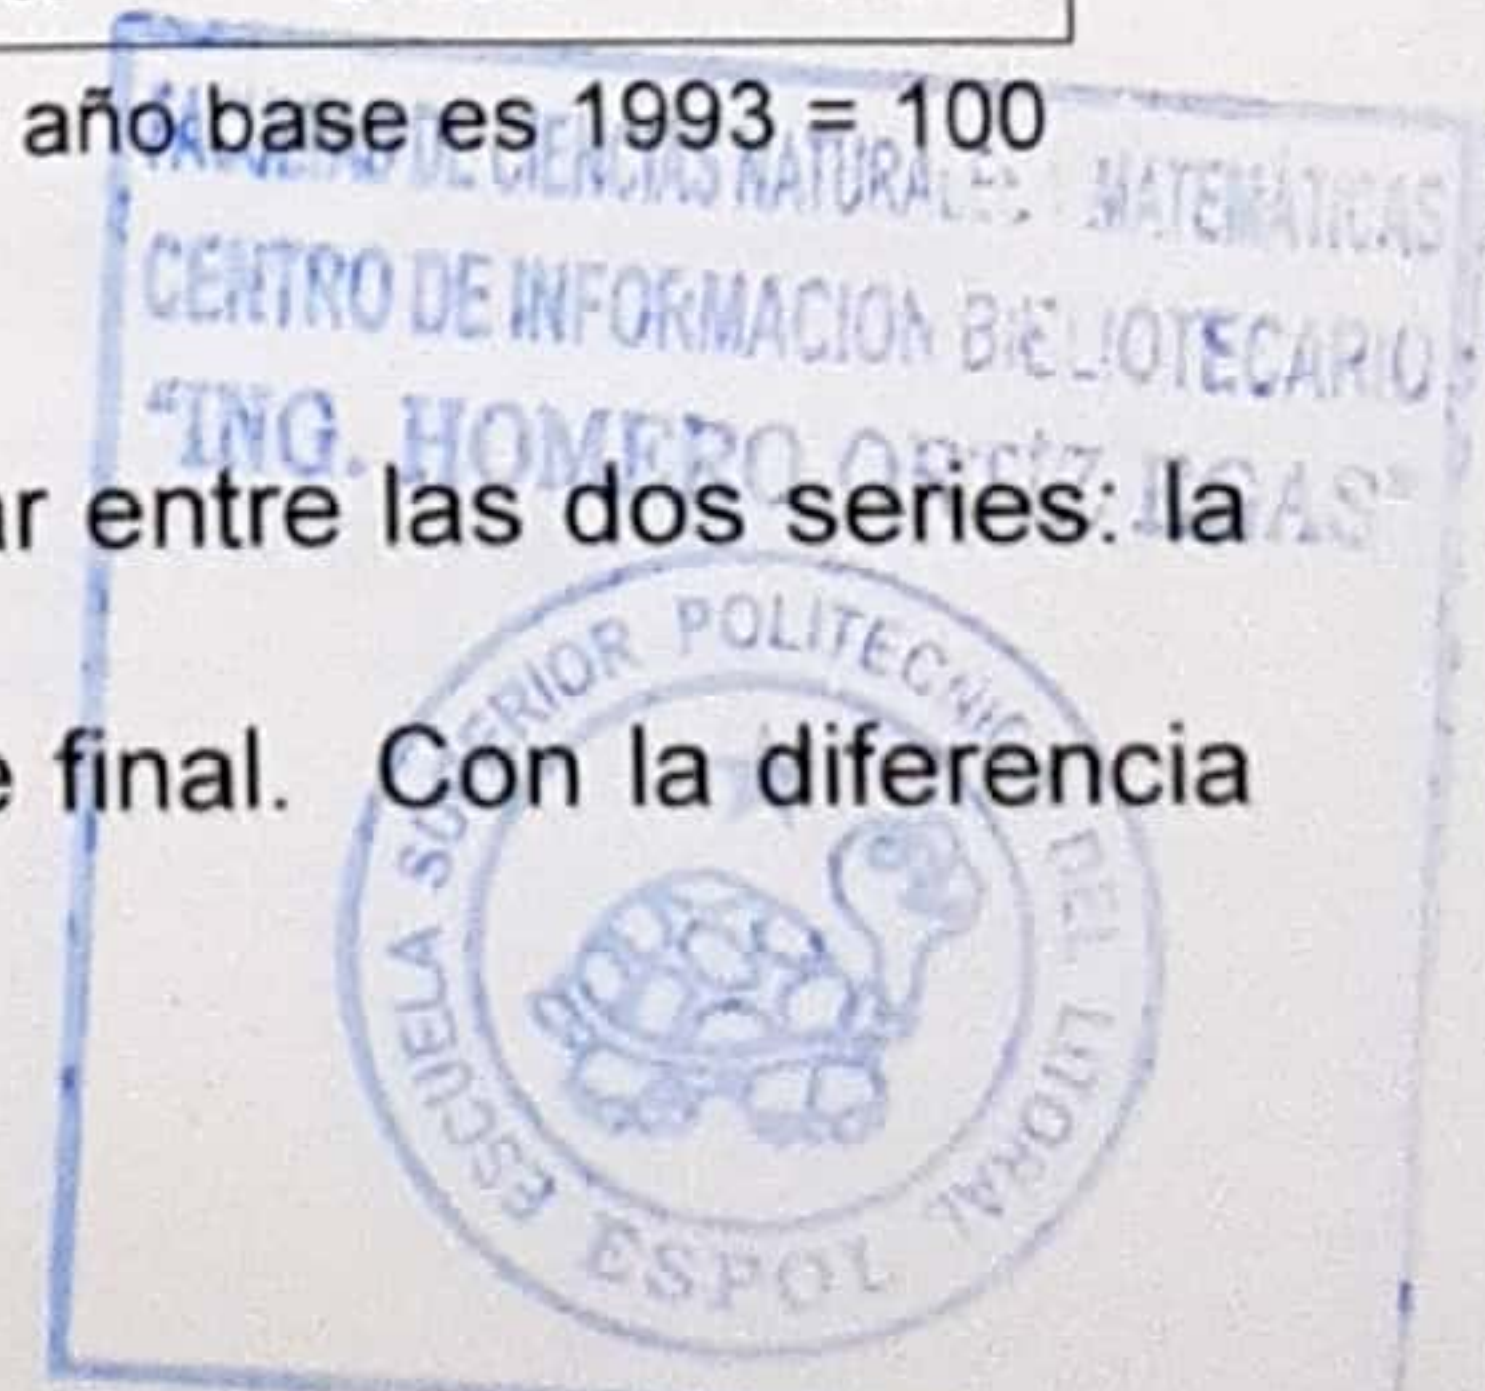
GRÁFICO 4.17

SERIE ORIGINAL Y AJUSTADA ESTACIONALMENTE FINAL PARA I-pr20 ⁽¹⁾



⁽¹⁾ I-pr20: Serie de Índice de Precios cuyo año base es 1993 = 100

El gráfico 4.17 revela un patrón similar entre las dos series: la original y la ajustada estacionalmente final. Con la diferencia



que la serie ajustada estacionalmente esta suavizada, libre de muchos factores externos que influyen en su comportamiento original. Son claros los ciclos económicos presentes, los cambios de nivel en los años de crisis económica del Ecuador.

La tabla 19 de Información de Diagnósticos de Calidad y los gráficos de las series tendencia-ciclo y ajustada estacionalmente final para I-pr20, son presentados para concluir el análisis a las series Ajustadas con X12-ARIMA a través del software DEMETRA.

TABLA 19

INFORMACIÓN DE DIAGNÓSTICO DEL AJUSTE ESTACIONAL DE LA SERIE DE MANUFACTURA I-pr20 CON X12-ARIMA

Información de Diagnóstico	Modelo 1 (X12-ARIMA)
Indice de Calidad de Ajuste Estacional (hasta 10)	5.704 [0, 10] ad-hoc
Estadísticos sobre los Residuos	
Ljung-Box para residuos	10.78 [0, 32.90] 0.1%
Descripción de los Residuos	
Curtosis	3.44 [1.15,4.85] 0.1%
Error en Predicciones	
Error en Predicciones sobre los últimos años	12.04% [0%, 15.0%] ad-hoc
Outliers	
Porcentaje de Outliers	6.58% [0%, 10.0%] ad-hoc
Criterio para Descomposición	
Estadístico combinado Q (M1, M3-M11)	0.82 [0, 1] ad-hoc

Elaborado por: V. Vásquez
Software: Demetra 2.0


Esta tabla da la siguiente información:

- No hay correlación en los residuos (estadístico Ljung-Box para residuos cae en intervalo definido)
- Los valores predcidos en los últimos años, no varían de los valores reales (error en predicciones dentro del intervalo).
- Adecuado porcentaje de outliers (dentro del límite establecido).
- Estadístico combinado Q dentro del intervalo.
- Adicionalmente se muestra el coeficiente de curtosis, que indica una concentración de los valores alrededor de la media

Así la serie se clasifica como aceptada, ha pasado todos las pruebas de calidad.


El siguiente gráfico 4.18 se refiere a la Serie Original y de Tendencia Final

GRÁFICO 4.18

SERIE ORIGINAL Y DE TENDENCIA FINAL PARA I-pr20 ⁽¹⁾

⁽¹⁾ I-pr20: Serie de Índice de Precios cuyo año base es 1993 = 100

GRÁFICO 4.19

SERIE ORIGINAL, DE TENDENCIA FINAL Y AJUSTADA ESTACIONALMENTE FINAL PARA I-pr20 ⁽¹⁾

⁽¹⁾ I-pr20: Serie de Índice de Precios cuyo año base es 1993 = 100

Las tres series juntas: original, tendencia-ciclo y desestacionalizada. El componente irregular ha sido separado de la serie original, por ello la serie filtrada por la estacionalidad sigue la forma de la curva de la tendencia-ciclo.

5. CONCLUSIONES Y RECOMENDACIONES

Esta es la parte final del capítulo referente a la Aplicación del Método X12-ARIMA al Tratamiento de las Series Económicas

de las Cuentas Nacionales del Ecuador, se ha buscado

mostrar al lector las series más representativas, con análisis

diferentes a las demás. En realidad lo demás es repetitivo y

por la decisión de obviar el resto de series.

Solo restan dar las conclusiones y recomendaciones de la investigación hecha a las series económicas del Ecuador, esto se muestra en la siguiente sección.

2. De las 53 series de las Cuentas Nacionales del Ecuador analizadas 41 series fueron aceptadas, por lo que se tiene un porcentaje del 22% de series rechazadas. Estas cifras dan cuenta de la eficacia


CAPITULO 5

5. CONCLUSIONES Y RECOMENDACIONES

5.1. Conclusiones

1. El procesamiento automático de series económicas se puede realizar con un software profesional bastante eficiente como es el caso de DEMETRA, que en su módulo automático permite el análisis masivo de series económicas. Sin embargo, en muchas ocasiones es necesario el criterio y conocimiento del investigador acerca de las series para darlas como aceptadas o rechazadas totalmente.
2. De las 53 series de las Cuentas Nacionales del Ecuador analizadas 41 series fueron aceptadas, por lo que se tiene un porcentaje del 22% de series rechazadas. Estas cifras dan cuenta de la eficacia

- del método de ajuste estacional (X12-ARIMA) y el software utilizado.
- De las 41 series aceptadas 11 necesitaron la intervención del usuario, debido a que se categorizaban como rechazadas debido a pequeños valores fuera de los intervalos permitidos. Por ejemplo la serie I-m09 inicialmente fue rechazada por tener un estadístico combinado Q con valor 1.12 cuando el intervalo de aceptación es $[0, 1]$, de acuerdo al conocimiento del analista esta serie debería ser aceptada.
 - En ciertas series como la I-x03 el método de ajuste estacional X12-ARIMA detecta una estacionalidad no significativa, por lo que en pocas palabras el ajuste estacional es desarrollado pero no recomendado o útil. Finalmente la serie original y la ajustada estacionalmente presentan patrones similares de comportamiento.
 - De las series aceptadas un porcentaje del 80% pasa la prueba de hipótesis que establece que el componente irregular debe presentar todas las características de un Ruido Blanco. Esto permite reconocer la validación del modelo aplicado.



6. Dado que las series analizadas sirven de base para la elaboración de indicadores económicos que posteriormente servirán para efectuar recomendaciones y decidir sobre la política económica del país, las series que fueron aceptadas por DEMETRA con el método X12-ARIMA van a permitir al investigador efectuar análisis económicos más precisos que con las series originales.
7. Debido a que en las series aceptadas el componente estacional ha sido detectado y eliminado, el analista podrá utilizar las series desestacionalizadas para realizar comparaciones de las series entre distintos períodos de tiempo (mes a mes o con el mismo mes del año anterior). Además, las inferencias que se realicen son válidas para los análisis económicos de coyuntura.
8. En todas las series aceptadas se pueden notar los cambios entre la serie original y la ajustada estacionalmente. Las fluctuaciones intra-anales sistemáticas han sido eliminadas y revelan los movimientos subyacentes de la tendencia-ciclo. Se tienen series más suaves que permiten establecer los puntos de giro.
9. Todas las series procesadas utilizan los modelos regARIMA, establecidos en la etapa de Pre-ajuste, para extender la serie en su

parte final (forecasts) o inicial (backcasts). Esto es importante porque añade calidad al ajuste estacional y reduce el error de revisión en las series desestacionalizadas por efecto de la agregación de datos.

2. En algunas series presentadas se tuvieron dificultades debido a lo

10. El utilizar los modelos regARIMA para extender las series a ambos lados antes de efectuar el ajuste estacional, añade estabilidad a los coeficientes estacionales calculados en los extremos de las series. Esto es importante dado que indica que las series aceptadas son confiables para realizar un análisis de coyuntura.

métodos de control de calidad, ya que son sensibles a errores de los

11. En todas las series analizadas se puede notar la fuerte influencia que tuvo la crisis económica por la que atravesó el país durante el periodo 1998 – 2001. En este intervalo de tiempo son más notorios

3. No los cambios de nivel y otros tipos de outliers que detecta X12-ARIMA.

los principales, X11-ARIMA, X12-ARIMA, TRAMO-SEATS, Métodos Basados en Modelos Estructurales, etc.), por lo que es de

esperar que los resultados conseguidos por otros métodos y

5.2. Recomendaciones comparables. Sin embargo, es preferible adoptar

de manera interna en el país a región de interés un solo método con el


1. Además del procesamiento automático, se recomienda que los investigadores que vayan a usar este tipo de técnicas realicen un

procesamiento manual para ciertas series que sean importantes o para las cuales el procedimiento automático determina resultados dudosos.

2. En algunas series procesadas se tuvieron dificultades debido a la variabilidad que estas presentaban en su estructura estocástica, esto a pesar de que el método X12-ARIMA es una herramienta muy eficaz para la detección de outliers, efectos calendario y otros componentes externos que afectan el comportamiento a corto y largo plazo de las series. Por ello se recomienda depurar las series con determinados métodos de control de calidad, ya que son sensibles a errores de los datos. Es preferible aplicar otros métodos para detectar anomalías dentro de las series antes de proceder a la descomposición.
3. No hay método de desestacionalización único (en este trabajo se han presentado los principales: X11-ARIMA, X12-ARIMA, TRAMO-SEATS, Métodos Basados en Modelos Estructurales, etc.), por lo que es de esperar que los resultados conseguidos por otros métodos y organismos no sean comparables. Sin embargo, es preferible adoptar de manera interna en el país o región de interés un solo método con el que se identifique el ajuste estacional. Inicialmente se recomienda probar diferentes métodos en cuanto a su flexibilidad, precisión de

estimación, errores de revisión, etc., para finalmente decidirse por la mejor opción.

4. El análisis realizado en esta tesis a las series de las Cuentas Nacionales del Ecuador constituye una base para la elaboración de futuros indicadores, pero no disminuye la necesidad de más y mejores datos económicos. Por lo que se recomienda su uso para estudios de corto plazo y por lo demás se espera la intervención del analista económico y la posibilidad de contar en un futuro con mayor acceso a información económica de interés nacional.
5. La técnica de ajuste estacional revisada y aplicada en el presente trabajo constituye un tipo de técnica no estudiada en ninguna materia del flujo académico de Ingeniería en Estadística Informática. La principal razón de su exclusión es debido a su reciente desarrollo pero se recomienda su investigación tanto para estudiantes como profesionales que gustan de aprender nuevas herramientas que contribuyen al mejoramiento de su trabajo.
6. A las instituciones del sector público y privado del país se recomienda la utilización de este tipo de técnicas para el tratamiento de series de datos. Es importante que el analista económico que tenga bajo su



responsabilidad el procesamiento de las series considere como ventaja competitiva el ajuste estacional, ya que podrá entender mejor la situación presente y le permitirá ajustar los pronósticos.

ANEXO 1

LAS MEDIDAS DE CONTROL Y DE CALIDAD DEL AJUSTE ESTACIONAL CON X12-ARIMA

1. LOS ONCE M's

El X12-ARIMA propone 11 medidas de control de calidad del ajuste estacional que se agrupan en tres categorías: tres medidas de diagnóstico, dos de diagnóstico y control, y seis de diagnóstico y control.

- 1. **M1**: El coeficiente de correlación entre la serie original y su versión estacionalmente ajustada. Si el valor es menor que -0.5, se dice que hay una primera falla. Cuando el M1 es menor que -2, se dice que hay una primera falla. Cuando el M1 es menor que -3, pero mayor que -2, hay una segunda falla. Si toma el valor máximo de -3, se está ante una falla completa.

ANEXO 1

LAS MEDIDAS DE CONTROL Y DE CALIDAD DEL AJUSTE ESTACIONAL CON X12-ARIMA

1. LOS ONCE M's

El X12-ARIMA presenta 11 medidas de control de calidad del ajuste estacional designadas con valores de M1 hasta M11 y dos medidas resumen denominadas Q1 y Q2.

Cada uno de los M evalúa una característica específica del ajuste estacional. Toman valores entre 0 y 3, con un rango de aceptación que va de 0 a 1, inclusive. Si su valor es mayor que 1 pero menor que 2, se dice que hay una primera falla. Cuando el M es mayor que 2 pero menor que 3, hay una segunda falla. Si toma el valor máximo de 3, se está ante una falla completa.

M1: Contribución relativa del componente irregular en un intervalo de 3 meses. Si esta medida falla significa que el componente irregular tiene mucha variabilidad y puede no ser fácilmente separado del estacional.


M2: La contribución relativa del componente irregular a la parte estacionaria de la varianza de la serie. Este valor mide el tamaño relativo de la varianza del componente irregular comparado con los otros componentes.

Los componentes estacional e irregular no pueden ser estimados fácilmente cuando la variación del componente irregular es demasiado grande con respecto a la variación del factor estacional. Ambas medidas, M1 y M2, señalan esta situación ajustando (extrayendo) la tendencia-ciclo de dos maneras diferentes.

M3: Magnitud del cambio mensual absoluto en el componente irregular comparado con el cambio mensual absoluto en la tendencia-ciclo. M3 es una función de la razón $\frac{\bar{i}}{c}$, muy útil para el análisis de los ciclos económicos. Cuando el M3 falla indica que el componente irregular es muy variable comparado con el

componente tendencia-ciclo y, por lo tanto, es difícil separar ambos componentes de la serie ajustada por estacionalidad.

- M4:** Grado de autocorrelación en el componente irregular conforme a la duración media de las rachas (ADR). Esta medida prueba la presencia de autocorrelación residual (proceso autorregresivo de primer orden) en el componente irregular de la serie. Dado que no se supone que el componente irregular sea ruido blanco, esta medida de control no es importante.
- M5:** Meses de Dominancia Cíclica. Números de meses que le toma al cambio en la tendencia-ciclo superar el cambio en el irregular. Es una medida importante para el análisis de ciclos económicos. Indica el orden del promedio móvil necesario para que el movimiento cíclico domine. Es otra manera de medir la facilidad de la separación entre tendencia-ciclo e irregular (ver medida M3).
- M6:** Medida de la magnitud del cambio anual en el componente irregular comparado con la magnitud del cambio anual en el componente estacional. Esta medida usa la razón $\frac{M}{S}$ para probar si un promedio móvil estacional 3x5 es adecuado para



estimar los factores estacionales. Sólo es relevante cuando el filtro estacional usado para ajustar la serie es precisamente 3x5. Si M6 falla, se puede probar otro filtro estacional.

M7: Cantidad de estacionalidad móvil presente, relativa a la estacionalidad estable. Esta medida es computada usando los valores F para la estacionalidad estable y móvil. Indica si la estacionalidad puede ser identificada por el método del X-11, por este motivo este es el más importante de los M.

M8 a M11: Movimiento inter-anual en el componente estacional. Estas cuatro medidas estadísticas son usadas para analizar los movimientos inter-anales en los factores estacionales. Cuando ellas fallan, revelan que la estimación de los factores estacionales es inestable. Los movimientos capturados por estos estadísticos son:

- Fluctuaciones aleatorias.
- Movimiento lineal.

Las medidas individuales son:

M8: Magnitud de la fluctuación aleatoria en el componente estacional a través de toda la serie. Un valor alto probablemente indica una alta distorsión en los factores estacionales.

M9: Magnitud del movimiento lineal en el componente estacional a través de toda la serie. Un valor alto puede significar pobres estimaciones de los factores estacionales.

M10: El tamaño de la fluctuación aleatoria inter-anual en el componente estacional en los años recientes.

M11: El promedio del movimiento lineal inter-anual en el componente estacional en los años recientes.

Ambas medidas, M10 y M11, brindan información sobre la calidad de los factores estacionales al final de la serie. Son muy importantes si se desean usar los factores extrapolados con anticipación de un año. La alternativa es re-estimar el ajuste estacional cada vez que se modifican los últimos datos.

2. LOS DOS Q's

La medida Q es un promedio ponderado de los diferentes M, donde el valor de M7 es el que más se pondera debido a su importancia. El valor de Q es una indicación global del ajuste estacional, que se rige de acuerdo a los valores mostrados en la siguiente tabla:

**TABLA
VALORES DE LAS MEDIDAS Q'S**

VALOR DE Q	AJUSTE ESTACIONAL
$0 \leq Q < 0.8$	Aceptado
$0.8 \leq Q < 1.0$	Condicionamente Aceptado
$1.0 \leq Q < 1.2$	Condicionamente Rechazado
$1.2 \leq Q \leq 3.0$	Rechazado

Para calcular el valor de Q1 se incluyen todos los valores de los once M's, pero para el cálculo de Q2 todos son considerados con excepción de M2.

BIBLIOGRAFIA

1. Ana Cecilia Kikut Valverde, Evelyn Muñoz Salas, Juan Carlos Quirós Solano, *Aspectos Conceptuales sobre Series de Tiempo (Nociones Básicas)*, Documento de Trabajo, Banco Central de Costa Rica, Junio 2002
2. Banco Central del Ecuador, *Cuentas Nacional 1993 – 2001 dólares corrientes y dólares de 2000*, Dirección General de Estudios, Octubre 2002
3. Banco Central del Ecuador, *Información Estadística Mensual N° 1823*, Dirección General de Estudios, Enero 31 de 2004
4. Banco Central del Ecuador, *Información Estadística Mensual N° 1831*, Dirección General de Estudios, Septiembre 30 de 2004
5. Banco Central del Ecuador, *Series de Indices del Comercio Exterior del Ecuador*, Enero 1990 a Octubre 2002.
6. BCE (2004); *Banco Central del Ecuador*, <http://www.bce.fin.ec> (Última visita: Mayo 13 de 2004)
7. David F. Findley, Brian C. Monsell, William R. Bell, Mark C. Otto, Bor-Chung Chen, *New Capabilities and Methods of the X12-ARIMA*

- Seasonal Adjustment Program*, U.S. Bureau of the Census, Washington D.C., 1998
8. Elvia Campos Villalobos, Ana Cecilia Kikut Valverde, Marta Muñoz Barrantes, Alexander Porras Jara, Lizette M. Rocha Bonilla, Margarita Rodríguez Mora, *Determinación de Modelos para la Extracción de Señales y el Pronóstico de las Series Trimestrales de la Oferta y Demanda Globales*, Documento de Investigación, Banco Central de Costa Rica, Junio 2001
 9. EUROSTAT (2002); *Advanced Seasonal Adjustment Interface. Demetra 2.0 Service Pack 1 – Release (Mayo 2002)*, <http://forum.europa.eu.int/irc/dsis/eurosam/info/data/demetra.htm> (Última visita Abril 25 de 2004)
 10. EUROSTAT, *Seasonal Adjustment Interface for Tramo/Seats and X12-ARIMA. Demetra 2.0. User Manual*, Mayo 2002
 11. EUROSTAT, *Seasonal Adjustment with Demetra. Demetra 2.0. Pedagogical Manual*, Mayo 2002
 12. Fernando Sandoya Sánchez, *Ajuste Estacional: conceptos, métodos y prácticas. Metodología Tramo-Seats*, Sociedad Estadística Ecuatoriana Quito, Ecuador, Abril 2003
 13. Ramón Mahía, *Conceptos Básicos de Matemática Económica para el Manejo de Series*, Madrid, España, Abril 2001



14. Uriel Ezequiel Jiménez, 1985, *Análisis de Series Temporales*, S/N Edición, Editorial Paraninfo S.A., Valencia, España, páginas 11 - 178
15. U.S. Census Bureau (2004); *The X12-ARIMA Seasonal Adjustment Program*, <http://www.census.gov/srd/www/x12a/> (Última visita: Abril 25 de 2004)