

**UNIVERSIDAD NACIONAL DE INGENIERIA**

**FACULTAD DE INGENIERÍA ECONOMICA Y  
CIENCIAS SOCIALES**



**EVALUACIÓN DEL MÉTODO DE EXTRACCIÓN DE SEÑALES  
AMB APLICADO A SERIES MACROECONÓMICAS  
TRIMESTRALES DEL PERÚ**

**PARA OPTAR EL TITULO PROFESIONAL DE :  
INGENIERO ECONOMISTA  
POR LA MODALIDAD DE TESIS**

**ELABORADO POR :**

**Waldy Goy Bejarano Baldeón**

**LIMA – PERU**

**2002**

*A mis padres ,mis hermanas y mis  
tíos Pedro y Nancy*

## **Agradecimientos**

Agradezco a Víctor Gómez, de la Dirección General de Planificación del Ministerio de Economía y Hacienda de España, por sus comentarios; a Agustín Maravall, del Departamento de Investigación del Banco de España, por haberme facilitado muchas de sus publicaciones y el programa TRAMO-SEATS WINDOWS. Mi gratitud a mis padres y mis hermanas por su infinito amor y su asistencia financiera, a mis tíos Pedro Albornoz y Nancy Albornoz, y a mis grandes amigos James Gayozzo y Diana Gayozzo, quienes ayudaron a financiar este estudio.

## Resumen

Este estudio evalúa los resultados de aplicar el método de extracción de señales AMB, implementado en TRAMO-SEATS, a veintiún series macro trimestrales del Perú. Este procedimiento fue adoptado oficialmente por Eurostat, y también recomienda su uso. El Banco Central Europeo utiliza también esta metodología conjuntamente con el X12-ARIMA. El método de extracción de señales AMB es una metodología internamente consistente y provee una herramienta unificada tanto para el análisis de corto como de largo plazos. El diagnóstico propio del método AMB indica que sólo en dos series analizadas (PBI pesca y manufactura) hay evidencia de que la descomposición no fue adecuada.

Para la evaluación de los resultados de la descomposición de las series se utilizaron dos tests. El primer test se utilizó para verificar si la serie desestacionalizada está efectivamente limpia de estacionalidad. Éste se basa en una ecuación autorregresiva de segundo orden para la serie desestacionalizada en primera diferencia. Esta ecuación fue estimada por OLS y las pruebas  $t$  usuales se utilizaron para determinar la significancia de los coeficientes. Adicionalmente, se usó el estadístico de Box-Pierce de dos rezagos estacionales. El segundo test tuvo por objeto conocer si el ajuste estacional no alteró la tendencia de la serie original. Para ello se corrió una (posible) ecuación cointegradora entre la serie original y la desestacionalizada. Luego, se aplicó las pruebas Phillips-Perron y Dickey Fuller Aumentado a los residuos. Si las innovaciones son estacionarias, ello sugiere que el ajuste preservó la tendencia de la serie original.

Los resultados de la evaluación del ajuste estacional fueron: i) de las veintiún series analizadas, en una (PBI manufactura) la serie desestacionalizada muestra autocorrelación estacional, por lo que el ajuste no removió completamente la estacionalidad y ii) en todos los casos, la serie original y la desestacionalizada cointegran si se aplica la prueba Phillips-Perron, sugiriendo que el ajuste preservó la tendencia de la serie original. En conclusión, TRAMO-SEATS arrojó resultados confiables en el 90,5% de los series sometidas al proceso de descomposición.



## CONTENIDO

1.	INTRODUCCIÓN.....	1
1.1.	DESCOMPOSICIÓN DE SERIES DE TIEMPO: APLICACIONES Y MÉTODOS .....	1
1.2.	OBJETIVO Y JUSTIFICACIÓN DE LA INVESTIGACIÓN.....	6
1.3.	HIPÓTESIS DE LA INVESTIGACIÓN .....	6
1.4.	PLAN DEL INFORME.....	7
2.	MARCO TEÓRICO Y PROCEDIMIENTO METODOLÓGICO .....	9
2.1.	MODELACIÓN DE SERIES DE TIEMPO UNIVARIANTES.....	9
2.1.1.	Método Clásico de Identificación de Modelos .....	9
2.1.2.	Métodos de Identificación Automáticos de Modelos ARIMA .....	11
2.1.2.1	Métodos Basados en Funciones de Penalidad .....	11
2.1.2.2	Herramientas para la Identificación Automática de Modelos .....	12
2.1.2.2a.	Procedimiento de Gómez para la Estimación de Raíces Unitarias .....	12
2.1.2.2b.	Método de Hannan y Rissanen (HR).....	16
2.1.2.3	Métodos de Modelación Automática en Presencia de Outliers.....	23
2.1.2.3a.	Definición de outlier.....	23
2.1.2.3b.	Algoritmos para la Detección y Corrección Automática de Outliers .....	26
2.1.2.3c.	Un Algoritmo para la Identificación Automática del Modelo en Presencia de Outliers .....	32
2.1.2.4	Un Procedimiento Automático para el Modelo General Regresión-ARIMA en Presencia de Outliers, Efectos Especiales y Observaciones Perdidas .....	33
2.1.2.4a.	Observaciones Perdidas .....	34
2.1.2.4b.	Efectos Día de la Semana y Semana Santa.....	34
2.1.2.4c.	Efectos de Intervención y de Regresión .....	37
2.2.	COMPONENTES NO OBSERVADOS EN SERIES DE TIEMPO ECONÓMICAS .....	38
2.2.1.	Conceptos y Definiciones Previas .....	38
2.2.2.	Método de Extracción de Señales Basado en Modelos ARIMA .....	50
2.2.3.	Especificación de los Componentes No Observados.....	52
2.2.4.	Identificación de los Componentes No Observados .....	54
2.2.5.	Estimación de los Componentes No Observados .....	59

2.2.5.1.	Estimadores MMSE (Error Cuadrático Medio Mínimo).....	59
2.2.5.2.	Filtro Wiener-Kolmogorov.....	60
2.2.5.3.	Estructura y Subestimación Estructural del Estimador Optimo .....	62
2.2.5.4.	Covarianza entre los Estimadores .....	64
2.2.6.	Estimador Preliminar y Pronóstico .....	65
2.2.7.	Estimador Final.....	67
2.2.8.	Revisiones en el Estimador.....	67
2.2.9.	Inferencia .....	69
2.2.9.1.	Error de Estimación.....	69
2.2.9.2.	La Mejora de Un Ajuste Concurrente.....	70
2.3.	PROCEDIMIENTO METODOLÓGICO .....	72
3.	RESULTADOS DEL AJUSTE ESTACIONAL TRAMO-SEATS.....	76
3.1.	VARIABLES DEL SECTOR REAL.....	76
3.2.	VARIABLES DEL SECTOR MONETARIO .....	90
3.3.	VARIABLES DEL SECTOR FISCAL .....	95
3.4.	VARIABLES DEL SECTOR EXTERNO.....	103
4.	EVALUACIÓN DEL AJUSTE ESTACIONAL TRAMO-SEATS.....	110
4.1.	VARIABLES DEL SECTOR REAL.....	110
4.2.	VARIABLES DEL SECTOR MONETARIO .....	114
4.3.	VARIABLES DEL SECTOR FISCAL .....	117
4.4.	VARIABLES DEL SECTOR EXTERNO.....	120
5.	CONCLUSIONES Y RECOMENDACIONES.....	123
	REFERENCIAS BIBLIOGRÁFICAS .....	127
	DIRECCIONES URL DE INTERÉS .....	132
	ANEXO 1: COMPONENTES NO OBSERVADOS DE LAS SERIES ESTIMADOS POR TRAMO-SEATS	
	ANEXO 2: GRÁFICOS DE LOS COMPONENTES NO OBSERVADOS ESTIMADOS POR TRAMO-SEATS	
	ANEXO 3: GLOSARIO DE TÉRMINOS	

## INDICE DE CUADROS

CUADRO N° 3.1.1: PARÁMETROS DE TRAMO-SEATS, SECTOR REAL .....	80
CUADRO N° 3.1.2: PARÁMETROS DE TRAMO-SEATS, SECTOR REAL .....	80
CUADRO N° 3.1.3: OUTLIERS Y EFECTOS CALENDARIO, SECTOR REAL .....	82
CUADRO N° 3.1.4: RESUMEN ESTADÍSTICO TRAMO, SECTOR REAL .....	83
CUADRO N° 3.1.5: ACF DEL COMPONENTE IRREGULAR, SECTOR REAL .....	84
CUADRO N° 3.1.6: CCF ENTRE LOS ESTIMADORES (TRANSFORMADOS EN ESTACIONARIO), SECTOR REAL .....	85
CUADRO N° 3.1.7: RESUMEN ESTADÍSTICO: SEATS, SECTOR REAL .....	86
CUADRO N° 3.2.1: PARÁMETROS DE TRAMO-SEATS, SECTOR MONETARIO.....	91
CUADRO N° 3.2.2: MODELOS IDENTIFICADOS, SECTOR MONETARIO .....	92
CUADRO N° 3.2.3: OUTLIERS, SECTOR MONETARIO .....	92
CUADRO N° 3.2.4: RESUMEN ESTADÍSTICO TRAMO, SECTOR MONETARIO.....	93
CUADRO N° 3.2.5: ACF DEL COMPONENTE IRREGULAR, SECTOR MONETARIO .....	93
CUADRO N° 3.2.6: CCF ENTRE LOS ESTIMADORES (TRANSFORMADOS EN ESTACIONARIO), SECTOR MONETARIO .....	94
CUADRO N° 3.2.7: RESUMEN ESTADÍSTICO: SEATS, SECTOR MONETARIO.....	94
CUADRO N° 3.3.1: PARÁMETROS DE TRAMO-SEATS, SECTOR FISCAL .....	99
CUADRO N° 3.3.2: MODELOS IDENTIFICADOS, SECTOR FISCAL .....	99
CUADRO N° 3.3.3: OUTLIERS, SECTOR FISCAL .....	100
CUADRO N° 3.3.4: RESUMEN ESTADÍSTICO TRAMO, SECTOR FISCAL .....	100
CUADRO N° 3.3.5: ACF DEL COMPONENTE IRREGULAR, SECTOR FISCAL.....	101
CUADRO N° 3.3.6: CCF ENTRE LOS ESTIMADORES (TRANSFORMADOS EN ESTACIONARIO), SECTOR FISCAL.....	101
CUADRO N° 3.3.7: RESUMEN ESTADÍSTICO: SEATS, SECTOR FISCAL.....	102
CUADRO N° 3.4.1: PARÁMETROS DE TRAMO-SEATS, SECTO EXTERNO .....	105
CUADRO N° 3.4.2: MODELOS IDENTIFICADOS, SECTOR EXTERNO.....	105
CUADRO N° 3.4.3: OUTLIERS, SECTOR EXTERNO.....	106
CUADRO N° 3.4.4: RESUMEN ESTADÍSTICO TRAMO, SECTOR EXTERNO.....	106
CUADRO N° 3.4.5: ACF DEL COMPONENTE IRREGULAR, SECTOR EXTERNO.....	107
CUADRO N° 3.4.6: CCF ENTRE LOS ESTIMADORES (TRANSFORMADOS EN ESTACIONARIO), SECTOR EXTERNO.....	107
CUADRO N° 3.4.7: RESUMEN ESTADÍSTICO: SEATS, SECTOR EXTERNO.....	108

CUADRO Nº 4.1.1: PRUEBA DE AUTOCORRELACIÓN ESTACIONAL EN LA SERIE DESESTACIONALIZADA, SECTOR REAL .....	111
CUADRO Nº 4.1.2: PRUEBA DE COINTEGRACIÓN ENTRE LA SERIE ORIGINAL Y LA DESESTACIONALIZADA-PP, SECTOR REAL .....	113
CUADRO Nº 4.1.3: PRUEBA DE COINTEGRACIÓN ENTRE LA SERIE ORIGINAL Y LA DESESTACIONALIZADA-ADF, SECTOR REAL .....	114
CUADRO Nº 4.2.1: PRUEBA DE AUTOCORRELACIÓN ESTACIONAL EN LA SERIE DESESTACIONALIZADA, SECTOR MONETARIO .....	115
CUADRO Nº 4.2.2: PRUEBA DE COINTEGRACIÓN ENTRE LA SERIE ORIGINAL Y LA DESESTACIONALIZADA-PP, SECTOR MONETARIO .....	116
CUADRO Nº 4.2.3: PRUEBA DE COINTEGRACIÓN ENTRE LA SERIE ORIGINAL Y LA DESESTACIONALIZADA-ADF, SECTOR MONETARIO.....	117
CUADRO Nº 4.3.1: PRUEBA DE AUTOCORRELACIÓN ESTACIONAL EN LA SERIE DESESTACIONALIZADA, SECTOR FISCAL .....	118
CUADRO Nº 4.3.2: PRUEBA DE COINTEGRACIÓN ENTRE LA SERIE ORIGINAL Y LA DESESTACIONALIZADA-PP, SECTOR FISCAL.....	118
CUADRO Nº 4.3.3: PRUEBA DE COINTEGRACIÓN ENTRE LA SERIE ORIGINAL Y LA DESESTACIONALIZADA-ADF, SECTOR FISCAL .....	119
CUADRO Nº 4.4.1: PRUEBA DE AUTOCORRELACIÓN ESTACIONAL EN LA SERIE DESESTACIONALIZADA, SECTOR EXTERNO .....	120
CUADRO Nº 4.4.2: PRUEBA DE COINTEGRACIÓN ENTRE LA SERIE ORIGINAL Y LA DESESTACIONALIZADA-PP, SECTOR EXTERNO .....	121
CUADRO Nº 4.4.3: PRUEBA DE COINTEGRACIÓN ENTRE LA SERIE ORIGINAL Y LA DESESTACIONALIZADA-ADF, SECTOR EXTERNO.....	122

# **Capítulo 1**

## **Introducción**

## **1. Introducción**

### **1.1. Descomposición de Series de Tiempo: Aplicaciones y Métodos**

El uso de la descomposición de series de tiempo en sus componentes no observados (tendencia, ciclo, estacional e irregular) se da en dos contextos: en investigaciones económicas y econométricas aplicadas; y, en el diseño de la política económica y el monitoreo de la economía en el corto plazo.

En el primer contexto, sus aplicaciones se realizan en una variedad de problemas, entre los que se puede mencionar: la modelación del progreso técnico, la modelación de la credibilidad de la autoridad monetaria, en la medición de la persistencia de los shocks económicos y en la literatura de los ciclos económicos. Para más detalles los lectores interesados pueden consultar Maravall (1995, p. 12-15). En el segundo contexto, en el diseño de la política económica y el monitoreo de la economía en el corto plazo. Típicamente, la política económica está basada en series ajustadas por estacionalidad. Un ejemplo puede encontrarse en la política monetaria de corto plazo, en donde la oferta monetaria se acomoda a las fluctuaciones estacionales de la demanda de dinero a fin de evitar fluctuaciones estacionales de las tasas de interés. La presente investigación se sitúa en el segundo de los contextos, no obstante, sus resultados

pueden ser aplicados en el primer contexto<sup>1</sup>.

Ahora bien, para la estimación de los componentes no observados se puede hacer uso de procedimientos que no están relacionados. Por ejemplo, para la estimación de la series desestacionalizadas puede emplearse el procedimiento X11-ARIMA ó su nueva versión el X12-ARIMA y la tendencia puede ser estimada usando el filtro de Hodrick-Prescott. El método de extracción de señales basado en modelos ARIMA (AMB) es una metodología unificada e internamente consistente que se implementó en los programas TRAMO-SEATS. El desarrollo teórico de esta metodología tuvo lugar principalmente en los 80s y su uso se difundió en los 90s. El procedimiento TRAMO-SEATS fue oficialmente adoptado por Eurostat en 1998 aunque lo ha venido utilizando desde 1994, institución que además recomienda su uso, luego de una evaluación teórica y empírica de los diversos métodos de ajuste estacional llevado a cabo para establecer la política de la Unión Europea en este tema. La evaluación comprendió a los programas DAINTRIES, SABL, BV4, X-11-ARIMA/88, X-11 UK, X-12-ARIMA y TRAMO-SEATS, concentrándose luego en estos dos últimos, y finalmente adoptando de manera oficial el procedimiento TRAMO-SEATS. En la siguiente dirección URL se encuentra abundante información sobre este trabajo de evaluación <http://europa.eu.int/comm/eurostat/research/index.htm?http://europa.eu.int/en/comm/eurostat/research/noris4/&1>. El Banco Central Europeo también utiliza el procedimiento TRAMO-SEATS conjuntamente con el X12-ARIMA.

---

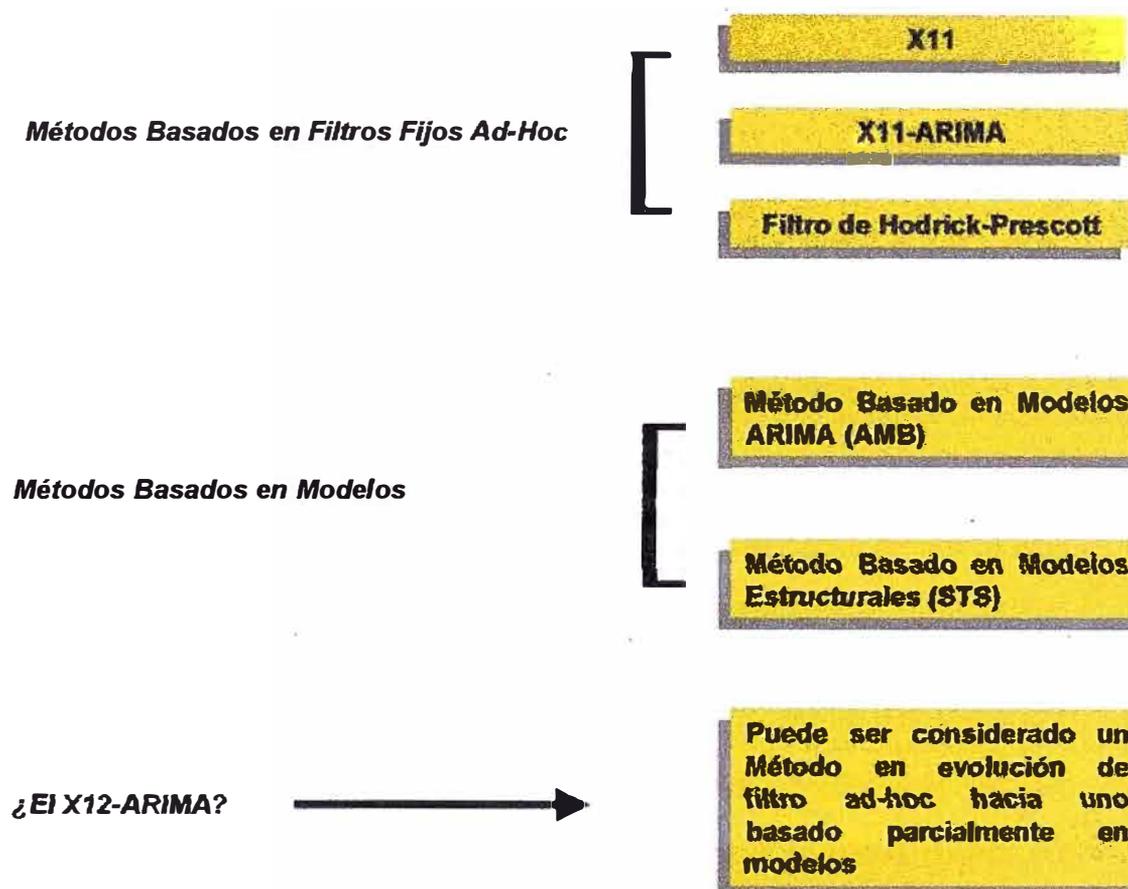
<sup>1</sup> Una aplicación econométrica al Perú se ubica en Bejarano (2001), quien encuentra que la política monetaria del Perú se ha hecho más eficiente en los 90s y que el anuncio de rangos objetivo de inflación ha contribuido a reducir las expectativas inflacionarias. El procedimiento utilizado para el ajuste estacional y la estimación de la brecha del producto fue el método de extracción de señales AMB.

En el siguiente esquema se muestra una clasificación de algunos métodos principales de descomposición de series de tiempo. El método AMB se encuentra dentro de los métodos basados en modelos, conjuntamente con el método STS, denominados también el de extracción de señales basado en modelos. El método AMB fue implementado en los programas TRAMO-SEATS y el STS en el programa STAMP. Los métodos basados en modelos, en opinión de algunos autores, eventualmente, reemplazarán al paradigma X11.<sup>2</sup> Existen varios otros métodos de ajuste estacional que recaen en otras clasificaciones, entre ellos DAINTRIES y BV4 que siguen un procedimiento de regresión sobre intervalos móviles y SABL que utiliza filtros no lineales robustos. Una comparación sobre estos tres últimos métodos, TRAMO-SEATS y el X11-ARIMA se encuentra en el trabajo de Fischer (1995) desarrollado para Eurostat. En el estado actual de las artes los métodos de ajuste estacional se encuentran concentrados en el análisis univariante y la línea de investigación en el futuro probablemente se concentrará al análisis multivariante. En este último contexto se encuentra el programa STAMP.

---

<sup>2</sup> Vea Gómez y Maravall (2000b) p. 9

## Algunos Métodos para la Estimación de Componentes No Observados de Series de Tiempo



### Estudios previos en el Perú

Existen muy pocos estudios empíricos de descomposición de series macroeconómicas en el Perú. Todos ellos utilizan el método X11-ARIMA (la penúltima versión de la familia X11). Castillo (1997) analiza 14 agregados monetarios (nominales y reales) en frecuencia mensual (1991-1996), encontrando que la liquidez en moneda nacional, nominal y real, no presenta estacionalidad y el saldo de la emisión primaria muestra una estacionalidad aceptada y condicionalmente aceptada en el caso nominal y real, respectivamente. Díaz (1997) analiza 8 variables del sector real (PBI por actividades económicas y el PBI global) en frecuencia

mensual y trimestral (1991-1996), concluyendo que las series en frecuencia trimestral presentan una estacionalidad estable. INEI (1997) desarrolla un estudio de ajuste estacional a 115 series mensuales (ene.1983–feb.1996) de producción y 64 series trimestrales (1Trim1986-4Trim1995) de precios. A diferencia de los dos primeros, este último también aplica, aunque de manera muy incipiente, el método AMB al PBI global. Es preciso indicar que en todos estos estudios la serie del PBI real corresponde al año base 1979 debido a que en ese momento todavía no estuvieron disponibles las series en el año base 1994.

Entre las desventajas del programa X11-ARIMA está el hecho de que el filtro X11 subestima el componente estacional en series que tengan una alta estacionalidad; y, lo sobreestima en series que tienen una estacionalidad muy estable. Esto, precisamente, se debe al carácter fijo del filtro X11. Teniendo en cuenta esta observación y considerando que estos estudios obviaron realizar una evaluación de los resultados del ajuste estacional X11-ARIMA para considerar i) si la serie desestacionalizada está efectivamente libre de estacionalidad y ii) si el proceso de ajuste no alteró la tendencia de la serie original, sus conclusiones eventualmente podrían ser frágiles. Soto (2000) aplica el X11-ARIMA, entre otros métodos, a 15 variables macroeconómicas chilenas en frecuencia trimestral (1983-1999), concluyendo que en 9 de ellas la serie desestacionalizada muestra evidencia de estacionalidad, lo cual indica que el ajuste fue inadecuado. También encontró que en 7 series, la original y la desestacionalizada no cointegran, lo cual significa que el método de desestacionalización distorsionó la tendencia de la serie original. Teniendo en cuenta estas consideraciones, la presente investigación es inédita en cuanto a la utilización y evaluación del método de descomposición de series de tiempo basado en extracción de señales para el Perú.

A la luz de los antecedentes para el caso peruano y los métodos contemporáneos de descomposición de series de tiempo, el presente estudio intenta responder a la pregunta ¿cuál es la validez del ajuste estacional basado en el método de extracción de señales AMB, implementado en los programas TRAMO-SEATS, para las variables macroeconómicas del Perú?

## **1.2. Objetivo y Justificación de la Investigación**

El estudio tiene por objetivo mostrar, a la comunidad académica y agencias productoras de estadísticas del Perú, los resultados de la evaluación de la descomposición (en particular, la descomposición serie desestacionalizada + componente estacional) de las principales series trimestrales de los sectores real, monetario, fiscal y externo del Perú, aplicando el método de extracción de señales AMB, implementado en TRAMO-SEATS, en un modo automático. Todo ello, con la finalidad de considerar su aplicación masiva y rutinaria.

La justificación estriba en que es necesario realizar un análisis de la calidad de ajuste estacional de las variables macroeconómicas del Perú, basado en un método integrado para el análisis económico tanto de corto como de largo plazos, a saber, el método AMB.

## **1.3. Hipótesis de la Investigación**

El método de extracción de señales AMB implementado en TRAMO-SEATS, en general, proveerá resultados confiables en la identificación, estimación de los modelos ARIMA y la descomposición de las series, en el modo automático. Para casos específicos, la evaluación indicará la identificación y estimación de modelos ARIMA alternativos para las series observadas cuya descomposición apruebe la etapa de evaluación.

#### **1.4. Plan del Informe**

El resto del informe se organiza como sigue: El Capítulo 2 contiene el marco teórico (secciones 2.1 y 2.2) y el procedimiento metodológico seguido por el presente estudio para evaluar los resultados de la aplicación del método de extracción de señales AMB (sección 2.3.). La intención de la sección 2.2. es proporcionar un resumen sobre la descomposición de las series de tiempo basado en modelos ARIMA y el análisis espectral, previamente, se expone en la sección 2.1. la teoría para la modelación automática de series de tiempo univariantes, considerando la detección y corrección por outliers y otros efectos a la serie observada.

Los siguientes capítulos son propiamente el aporte del estudio. En el Capítulo 3 se expone los resultados de la descomposición de la series consideradas, el énfasis es puesto en la descomposición serie desestacionalizada más el componente estacional. La extensión de las series va desde el primer trimestre de 1990 al primer trimestre del 2001, esto es, 45 observaciones; sólo en el caso de las series del sector monetario abarcó una observación adicional, comprendiendo hasta el segundo trimestre del 2001, esto es, 46 observaciones. La

no disponibilidad al público de series trimestrales largas del sector monetario, hizo que sólo se analizara a la liquidez del sistema bancario en moneda nacional y el saldo de la emisión primaria. La fuente de las series estadísticas fue el Banco Central de Reserva del Perú, recopilados de su dirección URL. En el Capítulo 4 se lleva a cabo la evaluación de los resultados de la descomposición serie desestacionalizada más componente estacional, siguiendo el procedimiento metodológico descrito en la sección 2.3. Esta evaluación puede ser aplicado a cualquier método de ajuste estacional. Por último, el Capítulo 5 resume las conclusiones de la investigación, aportando recomendaciones a la luz de los resultados obtenidos. En la redacción de este último capítulo se tuvo en cuenta no hacerla excesivamente técnica, con la finalidad de que un lector no muy familiarizado con el tema también pueda comprenderla.

## **Capítulo 2**

# **Marco Teórico y Procedimiento Metodológico**

## **2. Marco Teórico y Procedimiento Metodológico**

En las secciones 2.1. y 2.2. se expone el marco teórico utilizado por la presente investigación. La primera de ellas, cubre el tópico de modelación automática de series de tiempo univariantes, también se describe muy brevemente el método clásico con fines de comparación, mostrándose sus principales desventajas y su carácter subjetivo. La sección 2.2. expone el método de extracción de señales basados en modelos ARIMA (AMB). En la sección 2.3. se detalla el procedimiento metodológico seguido para la evaluación del ajuste estacional, el mismo que es aplicable a cualquier método de desestacionalización.

### **2.1. Modelación de Series de Tiempo Univariantes**

En esta sección se expone la teoría relacionada a la modelación automática de series de tiempo univariantes, el mismo que fue implementado en el programa TRAMO (Time Series Regression with ARIMA Noise, Missing Observations and Outliers). Para propósito de comparación, previamente se comenta sucintamente el método “clásico” de Box-Jenkins.

#### **2.1.1. Método Clásico de Identificación de Modelos**

La modelación de series de tiempo (el cual consta de las etapas de identificación, especificación, estimación y validación) bajo el enfoque clásico de Box-Jenkins es subjetiva,

en el sentido de que depende en un alto grado de la experiencia y conocimiento del analista. Por ejemplo, con relativa frecuencia en mi desempeño como analista identificaba un modelo distinto que el identificado por un homólogo en otra institución para una misma serie económica y un mismo intervalo de tiempo. Es conocido que la metodología Box-Jenkins se desempeña bien para la identificación de modelos autorregresivos puros o de medias móviles puro, pero no tan bien cuando se trata de modelos ARMA.

El modelo ARIMA estacional multiplicativo especialmente útil para el análisis en economía es  $\phi(B)\Phi(B^s)\nabla^d\nabla^D z_t = C + \theta(B)\Theta(B^s)a_t$ , cuya notación es  $ARIMA(p, d, q)(P, D, Q)_s$ .

Las herramientas utilizadas para la identificación, la función de autocorrelación simple y la función de autocorrelación parcial, pueden identificar con facilidad procesos ya sean sólo AR o sólo MA. Pero, cuando son procesos mixtos estas funciones son difíciles de interpretar. La dificultad para identificar modelos ARMA se incrementa cuando la estacionalidad está también presente en la serie. A diferencia del método clásico de identificación de un modelo ARIMA, TRAMO utiliza herramientas que pueden considerarse como objetivos. Primero, para obtener los órdenes de diferenciación regular  $d$  y estacional  $D$  se utiliza, opcionalmente, pruebas de raíces unitarias. Luego, para identificar el modelo ARMA para la serie estacionaria, previamente diferenciada de ser el caso usual, se utiliza un método basado en una función de penalidad; Gómez y Maravall (2000a).

## 2.1.2. Métodos de Identificación Automáticos de Modelos ARIMA

Habiendo comentado el método de Box-Kenkins en la sub-sección 2.1.1., en esta sub-sección se expone la teoría de la modelación automática de los modelos ARIMA, la misma que está contenida en Gómez y Maravall (2000a) e implementada en el programa TRAMO. Referencias para el manejo de TRAMO son Caporello y Maravall (2000a) y (2000b)

### 2.1.2.1 Métodos Basados en Funciones de Penalidad

Para determinar los órdenes  $k$  e  $i$  de un modelo ARMA( $k,i$ ) se usa una función de la forma

$$P(k, i) = Ln\hat{\sigma}_{k,i}^2 + (k + i) \frac{C(n)}{n}, \quad k \leq K, i \leq I, \text{ donde } \hat{\sigma}_{k,i}^2 \text{ es la estimación máxima}$$

verosimilitud (ML) de la varianza del ruido blanco,  $C(n)$  es función del número de observaciones  $n$  de la serie,  $K$  e  $I$  son los límites superiores para los órdenes, impuestos a priori. Debido a que  $\hat{\sigma}_{k,i}^2$  decrece cuando el orden crece, no puede ser un buen criterio

seleccionar el orden mediante su minimización. Esta es la razón por la cual el término

$$(k + i) \frac{C(n)}{n} \text{ se incluye. Cuando } C(n) = 2 \text{ se obtiene el Criterio de Información de Akaike o}$$

simplemente AIC (Akaike's information criterion); si  $C(n) = Ln(n)$  corresponde al Criterio de

Información Bayesiano o BIC (Bayesian information criterion) y si  $C(n) = 2Ln(Ln(n))$

corresponde al criterio HQ (Hannan and Quinn).

El BIC estima los órdenes de un a modelo ARMA de manera consistente, mientras que el AIC no. No obstante, esto no es una razón para preferir el estadístico BIC en lugar de AIC debido a que la consistencia se basa en el supuesto que hay un “verdadero” modelo ARMA para la serie, lo cual es una proposición dudosa. Los modelos son construcciones artificiales y hay cierto consenso de que no existe tal modelo verdadero.

En la experiencia práctica de algunos autores el BIC tiene mejor desempeño que el AIC, en términos de seleccionar más a menudo el modelo original cuando se está trabajando con data simulada y la selección de modelos tiene un mejor ajuste cuando se trata de series reales. Para un mayor detalle vea Gómez y Maravall (2000a, p. 7).

### **2.1.2.2 Herramientas para la Identificación Automática de Modelos**

#### **2.1.2.2a. Procedimiento de Gómez para la Estimación de Raíces Unitarias**

La estimación de raíces unitarias es hecho primero mediante la estimación de modelos autorregresivos de la forma  $(1 + \phi_1 B + \phi_2 B^2)(1 + \Phi B^s)(z_t - \mu) = a_t$ , donde  $\{z_t\}$  es la serie observada y  $s$  es el número de observaciones por año,  $\mu$  es la media del proceso y  $\{a_t\}$  es una secuencia i.i.d.  $N(0, \sigma^2)$  de variables aleatorias. Luego, la serie es diferenciada usando los órdenes de diferenciación dado por las raíces unitarias obtenidas después de la estimación del modelo arriba descrito y un modelo  $ARMA(1,1) (1,1)_s$  con media de la forma  $(1 + \phi B)(1 + \Phi B^s)(x_t - \mu) = (1 + \theta B)(1 + \Theta B^s)a_t$  se ajusta a la serie diferenciada. Si cualquier

nueva raíz unitaria aparece después de la estimación de este último modelo, los órdenes de diferenciación son apropiadamente incrementados y nuevamente se estima el modelo. El proceso continúa hasta que no sea posible estimar más raíces unitarias. Luego, los residuos del último modelo estimado son utilizados para decidir si es especificado con una media o no.

Suponga que la serie  $\{z_t\}$  sigue el modelo  $ARIMA(p, d, q)$ :  $\phi(B)(\delta(B)z_t - \mu) = \theta(B)a_t$ ,

donde:  $\delta(B) = \nabla^d \Delta_s^D$

$$\phi(B) = \phi_r(B)\phi_s(B^s)$$

$$\theta(B) = \theta_r(B)\theta_s(B^s)$$

en el cual para simplificar asúmase que  $\mu = 0$ , Entonces, los estimadores OLS obtenidos de una regresión  $AR(k)$ ,  $k \geq d$ , asintóticamente verifica  $\Phi_k(B) \stackrel{!}{\approx} \hat{\delta}(B)\hat{\phi}_m(B)$ ,  $\stackrel{!}{\approx}$  denota la equivalencia asintótica en probabilidad,  $m = k - d$  y  $\hat{\Phi}_k(B)$ ,  $\hat{\delta}(B)$  y  $\hat{\phi}_m(B)$ , (los subíndices  $k$  y  $m$  denotan los grados) son los polinomios estimados por OLS en las regresiones

$$\Phi_k(B)z_t = a_t$$

$$\delta(B)z_t = a_t$$

$$\phi_m(B)\omega_t = a_t$$

donde  $\omega_t = \delta(B)z_t$  es un proceso estacionario que sigue el modelo  $ARMA(p, q)$

$$\phi(B)\omega_t = \theta(B)a_t .$$

La aplicación práctica de este resultado es que si se desarrolla una autorregresión de orden mayor o igual al grado (desconocido) del polinomio  $\delta(B)$ , se obtiene un estimado consistente de  $\delta(B)$  como un componente de  $\Phi_k(B)$ . Si se especifica un modelo  $AR(2)(1)_s$  para  $\Phi_k(B)$ ,

se cubre los casos  $\delta(B) = 1$ ,  $\delta(B) = \nabla$ ,  $\delta(B) = \nabla_s$ ,  $\delta(B) = \nabla\nabla_s$ , y  $\delta(B) = \nabla^2\nabla_s$ , los cuales son los casos de mayor interés.

En caso de que la serie no presente estacionalidad, donde  $\delta(B) = \nabla^d$  y  $0 \leq d \leq 2$ , si se especifica un modelo  $AR(2)$  todos los casos importantes son cubiertos.

Sobre estas consideraciones previas, el algoritmo para identificar el polinomio diferencia,  $\delta(B)$ , es el siguiente:

1. Especifique un modelo  $AR(2)(1)_s$  con media, dado por la ecuación  $(1 + \phi_1 B + \phi_2 B^2)(1 + \Phi B^s)(z_t - \mu) = a_t$ , si el proceso es estacional multiplicativo o un modelo  $AR(2)$  con media, también dado por esta última ecuación pero sin el segundo factor, si el proceso es regular. Este proceso autorregresivo es estimado usando el método de Hannan y Rissanen (HR), a menos que el usuario decida usar mínimos cuadrados incondicionales (unconditional least squares). Se considera que una raíz es unitaria si su módulo es más grande que un valor especificado, el cual por omisión es 0,97.
2. Además del grado de diferenciación identificado en 1, como resultado de las raíces unitarias estimadas, un modelo  $ARMA(1,1)(1,1)_s$  con media para una serie que muestra estacionalidad, o un modelo  $ARMA(1,1)$  con media para una serie sin estacionalidad es especificado. Sea  $x_t$  la serie que resulta de diferenciar  $z_t$  con el polinomio diferencia obtenido después de la estimación de la autorregresión inicial. Las ecuaciones para estos modelos son  $(1 + \phi B)(1 + \Phi B^s)(x_t - \mu) = (1 + \theta B)(1 + \Theta B^s)a_t$ , en el caso estacional y el

mismo, sin los factores que contengan  $B^s$  en el caso regular. El modelo es estimado usando el método HR o máxima verosimilitud exacta (exact maximum likelihood), dependiendo de la opción seleccionada por el usuario, y si cualquiera de los parámetros autorregresivos estimados está cerca de 1, el grado de diferenciación se incrementa adecuadamente. Un parámetro es considerado cerca de 1 si su módulo es más grande que un valor especificado, el cual por omisión es 0,88. Para evitar la cancelación de factores en el modelo, el valor absoluto de la diferencia entre cada parámetro autorregresivo y su correspondiente parámetro media móvil debe ser mayor a 0,15. Para modelos estacionales multiplicativos, no es posible pasar de diferencia 0 a  $\nabla^2 \nabla_s$  directamente. Si esto pasa, las raíces del polinomio autorregresivo obtenido en 1 son consideradas otra vez, el de módulo más grande es seleccionado, y la serie es adecuadamente diferenciada. Si la serie ha sido diferenciada en este paso, repita el paso 2, en otro caso, vaya al paso 3.

3. Usando los residuos del último modelo estimado, se decide si especificar con media o no dependiendo de si es o no significativo la media de los residuos (estimada). Pare.

El modelo  $ARMA(1,1)(1,1)_s$  usado en el paso 2 es muy flexible y constituye una generalización del modelo de Líneas Aéreas de Box y Jenkins. Para una serie estacionaria, da una buena aproximación para muchos de los modelos ARMA encontrados en la práctica. Cuando es usado con series no estacionarias, puede detectar raíces unitarias autorregresivas no encontrados por el modelo autorregresivo utilizado en el paso 1; Gómez y Maravall (2000a, p.13).

Por ejemplo, un modelo  $(1 - B)(z_t - \mu) = (1 - 0,8B)a_t$ , donde la parte autorregresiva y la parte media móvil casi se cancelan, en este caso un modelo ARMA(1,1) probablemente estimaría la raíz unitaria mejor que un modelo AR(2).

### 2.1.2.2b. Método de Hannan y Rissanen (HR)

Luego de haber obtenido la transformación estacionaria, el siguiente paso en el proceso de modelación es la identificación de un modelo ARMA(p,q) para la serie diferenciada, posiblemente corregida por outliers y otros efectos de regresión. Con la finalidad de explicar el método HR se asume que la serie ya está corregida. En las secciones 2.1.2b.3 y 2.1.2b.4 se explica el tratamiento para corregir la serie por outliers y otros efectos de regresión.

En esta sección se explica el método HR y el procedimiento seguido por Gómez (implementado en TRAMO) para identificar el modelo ARMA(p,q).

El método HR es un método de función de penalidad basado en el criterio BIC, donde las estimaciones de los parámetros del modelo ARMA son calculados por medio de regresiones lineales. Se demuestra que estos estimadores tienen propiedades similares a los obtenidos por máxima verosimilitud (ML).

Sea  $z = [z_1, \dots, z_T]'$  la serie observada, el cual sigue el modelo  $\phi(B)(\delta(B)z_t - \mu) = \theta(B)a_t$ , donde por simplicidad asúmase  $\mu = 0$ . Luego de que  $\delta(B)$  ha

sido identificado, se puede calcular la serie diferenciada  $\omega_t = \delta(B)z_t$ ,  $t = d+1, \dots, T$ , ( $\omega = [\omega_1, \dots, \omega_{T-d}]'$ ) el cual sigue un modelo ARMA(p,q)  $\phi(B)\omega_t = \theta(B)\alpha_t$ . Si el modelo es estacional multiplicativo tiene la descomposición  $\phi(B) = \phi_r(B)\phi_s(B^s)$  y  $\theta(B) = \theta_r(B)\theta_s(B^s)$ .

Si los órdenes del modelo ajustado  $\phi(B)\omega_t = \theta(B)\alpha_t$  son (p,q) el estadístico BIC es  $BIC(p, q) = \text{Ln}(\hat{\sigma}_{p,q}^2) + (p + q) \frac{\text{Ln}(T - d)}{(T - d)}$ , donde  $\hat{\sigma}_{p,q}^2$  es el estimador ML de  $\sigma^2$ . El criterio

estima los órdenes (p,q) seleccionando  $(\hat{p}, \hat{q})$  de modo tal que  $BIC(p, q)$  sea mínimo. Este método requiere mucho cálculo en computadora debido a que tiene que desarrollar un optimización no lineal para cada (p,q) para obtener  $\hat{\sigma}_{p,q}^2$ .

Hannan y Rissanen desarrollaron un procedimiento usando técnicas de regresión lineal en tres pasos. Sólo se considerará los dos primeros pasos debido a que el tercer paso es utilizado para estimar los parámetros ARMA del modelo seleccionado usando el BIC, los mismos que tienen propiedades similares a los estimadores ML.

Paso 1. En el primer paso del método HR, el cual sólo se desarrolla cuando existe una parte MA ( $q > 0$ ), estima las innovaciones,  $\hat{\alpha}_t$ , los cuales se obtienen utilizando un modelo AR largo para la serie. Dado un entero positivo N,  $\hat{\alpha}_t$  se calcula usando

$$\hat{\alpha}_t = \sum_{j=0}^N \hat{\phi}_N(j) \omega_{t-j}, \quad \hat{\phi}_N(0) = 1, \quad t \geq 1,$$

$\omega_t = 0$  si  $t \leq 0$  y  $\hat{\phi}_N(j)$  es calculado usando el algoritmo de Durbin-Levinson.

Algoritmo Durbin-Levinson

a) Se calcula las autocovarianzas muestrales de  $\omega_t$ ,

$$c_t = \frac{1}{T-d} \sum_{s=1}^{T-d-t} \omega_s \omega_{s+t}$$

b) Se calcula recursivamente  $\hat{\phi}_N(j)$  usando las ecuaciones

$$\hat{\phi}_N(N) = -\sum_{j=0}^{N-1} \hat{\phi}_{N-1}(j) c_{N-j} / \hat{\sigma}_{N-1}^2,$$

$$\hat{\phi}_N(j) = \hat{\phi}_{N-1}(j) + \hat{\phi}_N(N) \hat{\phi}_{N-1}(N-j),$$

$$\hat{\sigma}_N^2 = \{1 - \hat{\phi}_N^2(N)\} \hat{\sigma}_{N-1}^2,$$

$$\hat{\phi}_1(1) = c_1 / c_0,$$

$$\hat{\sigma}_0^2 = c_0$$

El valor de N se selecciona de modo que  $N = \max\{[Ln^2(T-d)]; 2\max\{p, q\}\}$ , donde (p,q) son los órdenes del modelo ARMA para el cual el estadístico BIC se calcula y  $[Ln^2(T-d)]$  es la parte entera de  $Ln^2(T-d)$ .

Paso 2. En el segundo paso el método HR, dado los órdenes (p,q), primero se estiman los

parámetros del modelo  $\phi(B)\omega_t = \theta(B)\alpha_t$  minimizando  $S(p, q) = \sum_{t=m}^{T-d} \left\{ \sum_{j=0}^p \phi_j \omega_{t-j} - \sum_{j=1}^q \theta_j \hat{\alpha}_{t-j} \right\}^2$

(suma de cuadrados de los residuos), donde  $m = \max\{p+1, q+1\}$  y  $\phi_0 = 1$ . Luego, el

estimador  $\hat{\sigma}_{p,q}^2$  es calculado por  $\hat{\sigma}_{p,q}^2 = S(p,q)/(T-d)$  y el estadístico  $BIC(p,q)$  es

$$\text{calculado por } BIC(p,q) = \text{Ln}(\hat{\sigma}_{p,q}^2) + (p+q) \frac{\text{Ln}(T-d)}{(T-d)}.$$

En el procedimiento de Gómez, las siguientes modificaciones son hechas al método HR: si no hay una parte MA, es decir  $q = 0$ , los parámetros estimados coinciden con los obtenidos por OLS.

Si hay una parte MA, es decir  $q > 0$ , los estimadores  $\tilde{\phi}_j$  y  $\tilde{\theta}_j$  del modelo ARMA(p,q) obtenidos minimizando  $S(p,q)$ , son consistentes, pero tienen un sesgo, por lo cual ellos no son asintóticamente eficientes. A fin de obtener estimadores corregidos por sesgo, consistentes y asintóticamente eficientes se siguen los siguientes pasos:

Primero, calcule  $\tilde{\alpha}_t = -\sum_{j=1}^q \tilde{\theta}_j \tilde{\alpha}_{t-j} + \sum_{j=0}^p \tilde{\phi}_j \omega_{t-j}$ ,  $t \geq 1$ , donde  $\tilde{\alpha}_t = 0$  y  $\omega_t = 0$  si  $t \leq 0$ .

Luego, calcule  $\eta_t = -\sum_{j=1}^p \tilde{\phi}_j \eta_{t-j} + \tilde{\alpha}_t$ ,  $\xi_t = -\sum_{j=1}^q \tilde{\phi}_j \xi_{t-j} + \tilde{\alpha}_t$ ,  $t \geq 1$ , donde  $\eta_t = 0$  y  $\xi_t = 0$  si  $t \leq 0$ .

Finalmente, regrese  $\tilde{\alpha}_t$  con  $-\eta_{t-j}$ ,  $j = 1, \dots, p$  y  $\xi_{t-j}$ ,  $j = 1, \dots, q$ . Los coeficientes de regresión obtenidos así son añadidos a los estimadores  $\tilde{\phi}_j$  y  $\tilde{\theta}_j$  para obtener los estimadores deseados  $\hat{\phi}_j$  y  $\hat{\theta}_j$ .

Cuando hay una parte MA y una parte AR, Gómez propone obtener mejores estimaciones de la parte MA repitiendo el procedimiento previo con la serie filtrada con el filtro autorregresivo. Esto es, la serie es primero filtrada con el filtro autorregresivo  $\hat{\phi}(B)$  calculadas en las dos etapas previas para estimar  $x_t = \hat{\phi}(B)\omega_t$ . Luego, la serie  $x_t$ , el cual asintóticamente sigue el modelo  $x_t = \theta(B)a_t$ , y por lo cual no tiene una parte autorregresiva, está sujeta a los dos pasos previos.

Una vez que los parámetros del modelo  $\phi(B)\omega_t = \theta(B)a_t$  han sido obtenidos para algún orden  $(p, q)$ , el estimador  $\hat{\sigma}_{p,q}^2$  es necesitado para calcular el estadístico  $BIC(p, q)$ . En el procedimiento de Gómez, los residuos  $r_t$ ,  $t = 1, \dots, T = \max(p, q)$  de la serie  $\omega_t$  son primero calculados usando el filtro de Kalman (basado en el algoritmo de Morf-Sidhu-Kailath). Luego, el resto de residuos  $r_t$  son obtenidos recursivamente usando la ecuación en diferencias dado por el modelo  $\phi(B)\omega_t = \theta(B)a_t$ . Finalmente, se calcula  $\hat{\sigma}_{p,q}^2 = \frac{1}{T-d} \sum_{t=1}^{T-d} r_t^2$ , el cual es utilizado para obtener el estadístico  $BIC(p, q)$ .

### **Optimización del Estadístico $BIC(p, q)$**

En el método HR el modelo  $ARMA(\tilde{p}, \tilde{q})$  que se selecciona es aquel cuyo  $BIC(\tilde{p}, \tilde{q})$  es el mínimo entre todos los modelos  $ARMA(p, q)$  que satisfacen  $p \leq P$  y  $q \leq Q$ , donde  $P$  y  $Q$  son los límites superiores, fijados exógenamente.

Para describir el procedimiento de Gómez se trabajará con el modelo general estacional multiplicativo. En la práctica se asume que los órdenes del modelo  $ARMA(p_r, q_r)(p_s, q_s)_s$  de la serie bajo análisis satisface  $0 \leq p_r, q_r \leq 3$  y  $0 \leq p_s, q_s \leq 2$  y el estadístico BIC debería de calcularse para todas las combinaciones. Debido a que el número de combinaciones es alto, la búsqueda se realiza secuencialmente. El algoritmo para ello es:

Paso 1.- Especifique un modelo  $ARMA(0,3)$  para la parte regular. Luego, calcule el estadístico BIC para los modelos cuya parte estacional satisfaga  $0 \leq p_s, q_s \leq m_s$  y se selecciona aquel que tenga el menor BIC. El número  $m_s$  es seleccionado por el usuario, el valor por omisión es 1.

Paso 2.- Determinado los órdenes de la parte estacional en el Paso 1, el estadístico BIC se calcula para todos los modelos cuya parte regular satisfaga  $0 \leq p_r, q_r \leq m_r$ . Se selecciona el modelo cuyo BIC sea el mínimo. El número  $m_r$  es seleccionado por el usuario, el valor por omisión es 3.

Paso 3.- Fijado los órdenes de la parte regular en el Paso 2, se calcula el estadístico BIC para todos los modelos cuya parte estacional satisfaga  $0 \leq p_s, q_s \leq m_s$ . Se selecciona el modelo cuyo BIC es el mínimo. El número  $m_s$  es el mismo utilizado en el Paso 1.

En el Paso 1 se asume un modelo cuya parte regular es  $ARMA(0,3)$ . Esto es usualmente una buena aproximación a muchos modelos regulares encontrados en el trabajo práctico, de allí su

uso. Los órdenes de la parte estacional que se obtiene en el Paso 1 probablemente serán una buena aproximación, igualmente, sucede en el Paso 2. En el Paso 3, se vuelve a obtener los órdenes más aproximados. Este procedimiento es iterativo y puede repetirse los dos últimos pasos, pero usualmente los tres pasos son suficientes para encontrar un modelo satisfactorio.

Finalizado el algoritmo previo, y a fin de evitar la tendencia del estadístico BIC a una sobreparametrización, especialmente en la parte estacional, los 5 valores BIC más pequeños se ordenan en forma ascendente. Luego, el primero se compara con los otros 4 y si la diferencia en valor absoluto es menor que un cierto número y mayor a los dos BIC correspondientes a una parte estacional más parsimoniosa, este último es elegido. Entre la totalidad de los valores BIC que satisfagan esta condición, el que corresponda al modelo más parsimonioso se selecciona y que también contenga una parte estacional. Este procedimiento también favorece el hallazgo de modelos balanceados.

En el algoritmo previo, si los parámetros estimado para un modelo ARMA son tales que las raíces de los polinomios AR o MA caen dentro del círculo unitario, este hecho se considera como un indicio de un modelo inadecuado por lo que será rechazado.

El modelo tentativo  $ARMA(0,3)$  especificado en el Paso 1 parece ser robusto y la investigación secuencial del algoritmo descrito ha dado resultados muy satisfactorios en la totalidad de los tests desarrollados con series reales y simuladas.

Si hay una media o efectos de regresión en el modelo  $\phi(B)\omega_t = \theta(B)\alpha_t$ , el procedimiento de Gómez obtiene primero los estimadores OLS de los parámetros de regresión. Luego, estos efectos son sustraídos de la serie diferenciada antes de estimar los parámetros del modelo  $\phi(B)\omega_t = \theta(B)\alpha_t$  y también antes de calcular los residuos  $r_t$  necesarios para obtener  $\hat{\sigma}_{p,q}^2$  y el estadístico BIC.

### **2.1.2.3 Métodos de Modelación Automática en Presencia de Outliers**

La presencia de observaciones atípicas (outliers) puede hacer extremadamente difícil el proceso de identificación del modelo, por lo que todo método de identificación debería incorporar su tratamiento. Debido a que los modelos ARIMA están diseñados para recoger la información contenida en el proceso con un patrón de memoria homogéneo, la presencia de observaciones atípicas o cambios estructurales pueden influenciar la eficiencia y la bondad de ajuste de estos modelos.

#### **2.1.2.3a. Definición de outlier**

A menudo cuando se analiza una serie de tiempo económica se encuentra observaciones distantes, denominadas atípicas o aberrantes (outliers). Entre las causas que pueden originar este tipo de observaciones se encuentran: huelgas, cambios importantes en la política económica, la ocurrencia de desastres naturales, etc.

El enfoque tradicional para abordar el problema de los outliers, una vez que el modelo apropiado a sido identificado para la serie, consiste, en primer lugar, en la identificación de la localización y el tipo de outlier. Luego, usar el análisis de intervención propuesto por Box y Tiao (1975). Este procedimiento requiere que un experto en series de tiempo primero examine la data y luego analice las funciones de autocorrelación y autocorrelación parcial muestrales de los residuos, gráficos de la serie y residuos , etc. Es decir, se trata de un método manual.

La presencia de outliers: i) puede resultar en un modelo incorrectamente especificado, ii) incluso si el modelo ha sido apropiadamente especificado, los outliers podrían todavía producir un sesgo importante en la estimación de los parámetros, iii) algunos outliers podrían no ser identificados debido a un efecto oculto (masking effect).

El método propuesto por Gómez para la detección y corrección de outliers intenta resolver los problemas ii) y iii) .

Suponga primero que no hay efectos de regresión. Permita que la serie  $\{z_t\}$  siga el modelo  $ARIMA\{p, d, q\}$  dado por  $\phi(B)(\delta(B)z_t - \mu) = \theta(B)\alpha_t$ , entendiéndose que este es un modelo estacional multiplicativo. Para modelar el efecto de outliers considere el modelo

$$z_t^* = z_t + \omega v(B)I_t^{Tm},$$

Donde:

$v(B)$	es un cociente de polinomios en B
$\{z_t\}$	es una serie limpia de outliers

$I_t^{Tm} = 1$ si $t = Tm$ y $I_t^T = 0$ en otro caso	función que indica el momento en el cual el outlier toma lugar. $Tm$ denota el momento de ocurrencia del outlier.
$\omega$	Representa la magnitud del outlier

Cuatro tipos de outliers serán considerados:

IO: $\nu(B) = \frac{\theta(B)}{\delta(B)\phi(B)}$	Outlier innovacional: se propaga en función del modelo que sigue la serie.
AO: $\nu(B) = 1$	Outlier aditivo: afecta sólo a un periodo.
TC: $\nu(B) = \frac{1}{1 - \eta B}$	Cambio temporal: representa saltos en el nivel de la serie que, de forma amortiguada, eventualmente regresa a su nivel anterior.
LS: $\nu(B) = \frac{1}{1 - B}$	Cambio en nivel: captura un salto en el nivel medio de la serie, que se mantiene en los siguientes periodos.

El valor de  $\eta$  es fijo e igual a 0,7. Estos cuatro tipos de outliers corresponden a tipos simples.

Outliers más complicados pueden ser usualmente aproximados mediante al combinación de los 4 tipos mencionados.

El IO puede tener un gran efecto sobre el nivel de la serie, especialmente para una serie no estacionaria debido al factor  $\delta(B)$  en el denominador. Por esta razón, el uso de un IO se

debería evitar. Gómez y Maravall (2000a, p. 22) opinan que el IO es más un ruido que una ayuda en la identificación y ajuste de un modelo ARIMA.

### 2.1.2.3b. Algoritmos para la Detección y Corrección Automática de Outliers

#### Caso1: Presencia de un único tipo de outlier a la vez

Suponga que los parámetros en el modelo  $\phi(B)(\delta(B)z_t - \mu) = \theta(B)\alpha_t$  son conocidos. El modelo  $z_t^* = z_t + \omega v(B)I_t^{Tm}$  puede ser re-escrito como  $z^* = Y\omega + z$ , donde

$z^* = (z_1^*, \dots, z_T^*)'$	Serie observada
$Y = (v(B)I_1^{Tm}, \dots, v(B)I_T^{Tm})'$	
$z = (z_1, \dots, z_T)'$	Serie libre de outlier
$Var(z) = \sigma^2 \Omega$	Matriz de covarianzas de $z_t$
$\Omega = LL'$	$L$ resulta de la factorización de Cholesky de $\Omega$ (matriz de autocorrelaciones de $z$ ) y es una matriz triangular inferior
$r = L^{-1}z$	Vector de residuos de la serie libre de outlier (no observado)
$Var(r) = \sigma^2 I_{TxT}$	Matriz de covarianzas de los residuos
$r^* = L^{-1}z^*$	Residuos estimados
$X = L^{-1}Y$	

$$z^* = Y\omega + z$$

$$L^{-1}z^* = L^{-1}Y\omega + L^{-1}z$$

$$r^* = X\omega + r$$

Si  $Y=0$ , el modelo sería  $z^* = z$  y si se aplica el filtro de Kalman a este modelo, se obtendría  $L^{-1}z^*$ . Este resultado permite ver al filtro de Kalman como un algoritmo que, aplicado al vector  $v$  en lugar de  $z^*$ , produce  $L^{-1}v$ .

Se puede obtener  $\omega$  por OLS (en la ecuación  $r^* = X\omega + r$ )  $\hat{\omega} = (X'X)^{-1}X'r^*$ , donde la varianza del estimador es  $\text{Var}(\hat{\omega}) = (X'X)^{-1}\sigma^2$ . Para probar la hipótesis nula ( $H_0 =$  no existe outlier en  $t = Tm$ ) se puede usar el estadístico  $\tau = (X'X)^{1/2}\hat{\omega} / \sigma$ , el cual se distribuye  $N(0, I)$  bajo la hipótesis nula.

En la práctica, los parámetros del modelo  $\phi(B)(\delta(B)z_t - \mu) = \theta(B)a_t$  no son conocidos y requieren ser estimados. Para ello, el procedimiento usual consiste, primero, estimar los parámetros de este modelo por el método de máxima verosimilitud exacta (exact maximum likelihood), como si ellos no tuviesen observaciones atípicas, obteniéndose los estimadores de  $\omega$  y  $\tau$ :

$$\hat{\omega} = (\hat{X}'\hat{X})^{-1}\hat{X}'\hat{r}^*, \quad \hat{\tau} = (\hat{X}'\hat{X})^{1/2}\hat{\omega} / \hat{\sigma}$$

Cada matriz  $X$ , y por lo tanto  $X'X$ , depende del tipo de outlier.

Para ver si existe un outlier en  $t = Tm$ , los 4 estimadores  $\hat{\omega}_{IO}^{Tm}$ ,  $\hat{\omega}_{AO}^{Tm}$ ,  $\hat{\omega}_{TC}^{Tm}$  y  $\hat{\omega}_{LS}^{Tm}$  son primero calculados, junto con los estadísticos  $\hat{t}_{IO}^{Tm}$ ,  $\hat{t}_{AO}^{Tm}$ ,  $\hat{t}_{TC}^{Tm}$  y  $\hat{t}_{LS}^{Tm}$  (el subíndice hace referencia al tipo de outlier). Luego, se usa el estadístico  $\lambda_{Tm} = \max\{|\hat{t}_{IO}^{Tm}|, |\hat{t}_{AO}^{Tm}|, |\hat{t}_{TC}^{Tm}|, |\hat{t}_{LS}^{Tm}|\}$ . Si  $\lambda_{Tm} > C$ , entonces existe la posibilidad de un outlier del tipo correspondiente ( $C$  es un valor crítico predeterminado).

Debido a que el momento  $t = Tm$  en el cual ocurre el outlier es desconocido en la práctica, se repite la operación previa para  $t = 1, \dots, T$  y se calcula  $\lambda = \max_t \lambda_t = |\hat{t}_{tp}^{Tm}|$  ( $tp$  puede ser IO, AO, TC ó LS). Si  $\lambda > C$ , entonces existe una outlier del tipo  $tp$  en el momento  $Tm$ .

Una vez que el tipo de outlier en  $t=Tm$  es conocido, la serie y los residuos pueden ser corregidos usando  $z_t^* = z_t + \omega v(B)I_t^{Tm}$  y  $r^* = X\omega + r$ .

### Caso 2: El Caso de múltiples tipos de outliers a la vez

Cuando múltiples tipos de outliers están presentes a la vez en una observación, se debe usar el

$$\text{modelo } z_t^* = z_t + \sum_{i=1}^k \omega_i v_i(B) I_t^{t_i},$$

Los estimadores de  $\omega_i$  obtenidos simultáneamente usando la expresión anterior pueden ser muy diferentes de los obtenidos por un proceso iterativo usando los resultados del Caso 1. Esto es, obteniendo primero  $\hat{\omega}_1$ , luego  $\hat{\omega}_2$ , etc. Por esta razón es importante que cada algoritmo para la detección de outliers desarrolle, en alguna medida, regresiones múltiples

para detectar outliers espúreos y corregir el sesgo producido en los estimadores secuencialmente obtenidos.

### Estimación de la Desviación Estándar $\sigma$ de los Residuos

Cuando existen outliers en la serie observada, el estimador muestral usual puede sobreestimar  $\sigma$ . Por esta razón, es aconsejable usar un estimador robusto. El procedimiento de Gómez considera el uso del estimador MAD, definido por  $\hat{\sigma} = 1,483 \text{mediana}\{|r_t^* - \hat{\rho}^*|\}$ , donde  $\hat{\rho}^*$  es la mediana de los residuos estimados  $r^* = L^{-1}z^*$ . Si los parámetros del modelo son desconocidos, deberán reemplazarse por sus estimados (calculados de manera usual).

Para el tratamiento de outlier de manera iterativa, el procedimiento de Gómez asume que los órdenes  $(p, d, q)$  del modelo  $\phi(B)(\delta(B)z_t - \mu) = \theta(B)a_t$  son conocidos.

Etapa 1: Los outliers son detectados uno por uno y los parámetros del modelo son modificados luego que cada outlier ha sido detectado. Cuando no haya más outliers que detectar se pasa a la Etapa 2.

Etapa 2: Se desarrolla una regresión múltiple. Los outliers que tienen los valores  $t$  más bajos son descartados. Luego, se regresa a la Etapa 1 para iterar.

El procedimiento usado para incorporar o rechazar outliers es similar al procedimiento de regresión por pasos para seleccionar la mejor ecuación de regresión.

Para incorporar efectos de regresión en el procedimiento de Gómez se utiliza el siguiente modelo de regresión con errores ARIMA (también denotado como Reg-ARIMA)

$$z_t = y_t' \beta + v_t, t = 1, \dots, T$$

$\beta = (\beta_1, \dots, \beta_k)'$	Vector que contiene los parámetros de regresión, puede incluir una media como primer componente
$\{z_t\}$	Serie observada
$\{y_t\}$	Vectores que contienen las variables de regresión
$\{v_t\}$	Serie linealizada que sigue un modelo ARIMA con $\mu = 0$

A continuación se detalla el procedimiento de Gómez para la detección y corrección automática de outliers; vea Gómez y Maravall (2000a, p. 25).

### *Inicialización*

Si hay cualquier variable de regresión en el modelo, incluido la media, los coeficientes de regresión se estiman por OLS y la serie es corregida por sus efectos.

### *Etapas 1: Detección y Estimación de Outliers uno por uno*

Los parámetros ARIMA son estimados usando el método HR y la serie es corregida por la totalidad de los efectos de regresión presentes en el tiempo, incluidos los outliers hasta este punto detectados.

Considerando los estimados de los parámetros obtenidos en 1.1. como fijos, los coeficientes de regresión son estimados por GLS (mínimos cuadrados generalizados), así como su respectivos estadísticos  $t$ . Luego, se obtienen nuevos residuos.

Con los residuos obtenidos en 1.2. , se calcula el estimador MAD de la desviación estándar de los residuos.

Si  $u = (u_{d+1}, \dots, u_T)'$ , denota la serie diferenciada, los estadísticos  $\hat{t}_{IO}^t$ ,  $\hat{t}_{AO}^t$ ,  $\hat{t}_{TC}^t$  y  $\hat{t}_{LS}^t$  son calculados para  $t = d + 1, \dots, T$ . Para este fin los residuos obtenidos en 1.2 y 1.3 son usados. Sea  $\lambda_t = \max\{|\hat{t}_{IO}^t|, |\hat{t}_{AO}^t|, |\hat{t}_{TC}^t|, |\hat{t}_{LS}^t|\}$ , si

$\lambda = \max_t \lambda_t = |\hat{t}_{TP}^t| > C$ , donde  $C$  es el valor crítico preseleccionado, luego hay un posible outlier de tipo  $t_P$  en el momento  $T$ .

### *Etapa 2: Regresión Múltiple*

Usando los estimados de la regresión múltiple y sus respectivos estadísticos  $t$  que se obtuvieron la última vez que el algoritmo ejecutó 1.2 de la Etapa 1, verifique si hay outliers cuyo estadístico  $t < C$ , donde  $C$  es el mismo valor crítico de 1.4 de la Etapa 1. Si no hay outliers, pare. Si, por el contrario, hay algunos, entonces remueva el outlier con el valor  $t$  más bajo (en valor absoluto) y regrese a 1.2 para iterar.

### **2.1.2.3c. Un Algoritmo para la Identificación Automática del Modelo en Presencia de Outliers**

A continuación se resume el algoritmo, implementado en TRAMO, para la identificación automática del modelo en presencia de outliers:

#### Pruebas Preliminares

Si el usuario lo desea, el procedimiento puede desarrollar una prueba para una especificación logarítmica en niveles, efectos especiales tipo *días calendario* (trading day) y *Semana Santa* (Easter). Estas dos últimas pruebas se desarrollan usando el modelo por omisión (modelo de Líneas Aéreas).

#### Inicialización

Si el usuario lo prefiere, la serie a corregirse por outliers, acepta un modelo especificado por el usuario (el modelo de Líneas Aéreas es el modelo por omisión) y el algoritmo va al Paso 3, en otro caso, va al Paso 1. El valor crítico  $C$  para la detección de outlier puede ser introducido por el usuario o especificado por el procedimiento. En este último caso,  $C$  se selecciona dependiendo de la longitud de la serie.

Paso 1 Si el usuario ha especificado los órdenes de diferenciación, una media o no en el modelo, el algoritmo va al Paso 2. En otro caso, la serie es primero corregida por la

totalidad de efectos de regresión si los hubiese. Luego, usando la serie corregida, los órdenes de diferenciación para el modelo ARIMA son automáticamente obtenidos y, también automáticamente, se decide si se especifica una media para la serie o no. Vaya al Paso 2.

Paso 2 Desarrolla la identificación automática de un modelo  $ARMA(p, q)$  para la serie diferenciada, corregida por outliers y otros efectos de regresión, si los hubiese. Si el usuario quiere probar efectos *días comerciales* y *Semana Santa* y cualquiera de estos efectos hubiese sido especificado en pruebas preliminares, el algoritmo chequea si los efectos especificados son significativos para el nuevo modelo. Si el usuario quiere corregir la serie por outliers, se ejecuta el Paso 3. En otro caso, el algoritmo se detiene.

Paso 3 Asumiendo que el modelo es conocido, desarrolla la detección y corrección automática de outliers usando  $C$  como valor crítico. Si una condición de paro no es satisfecha, quizás se deba decrecer el valor crítico  $C$  y el algoritmo va al Paso 1.

#### **2.1.2.4 Un Procedimiento Automático para el Modelo General Regresión-ARIMA en Presencia de Outliers, Efectos Especiales y Observaciones Perdidas**

El algoritmo fue construido para manipular cualquier tipo de efecto de regresión. Efectos especiales, como Días Calendario (Trading Day) y de Semana Santa (Easter) son considerados, así también son considerados efectos de intervención y otros efectos de regresión.

#### **2.1.2.4a. Observaciones Perdidas**

Las observaciones perdidas son tratadas como outliers aditivos, lo cual implica que se puede trabajar con una serie completa. A las observaciones perdidas, en una primera instancia se le asigna valores tentativos igual a la semisuma de los dos valores adyacentes. Luego, después de que el modelo ha sido estimado, la diferencia entre el valor tentativo y el coeficiente de regresión estimado es el valor interpolado.

#### **2.1.2.4b. Efectos Día de la Semana y Semana Santa**

Seis variables son usadas para modelar el efecto día de la semana (trading day), estos son:

N° de lunes – N° de domingos
N° de martes – N° de domingos
N° de miércoles – N° de domingos
N° de jueves – N° de domingos
N° de viernes – N° de domingos
N° de sábados – N° de domingos

La razón para usar estas variables estriba en que es deseable que la suma de los efectos de

cada día de la semana se cancele. Matemáticamente  $\sum_{j=1}^7 \beta_j = 0$ , entonces  $\beta_7 = -\sum_{j=1}^6 \beta_j$ , donde

$\beta_j$  es el coeficiente día de la semana.

A veces, una variable denominada *longitud de la variable mes* es incluida. Esta variable es

definida como  $m_t - \bar{m}$ ,

$m_t$	Longitud del mes en días
$\bar{m} = 30,4375$	Longitud mensual promedio

Otra variable que puede usarse es la *variable año bisiesto*. Esta es igual a 0 para todos los meses distintos de febrero. En febrero, toma el valor de  $-0,25$  si tiene 28 días y  $-0,75$  si tiene 29 días (año bisiesto)

Existe también la posibilidad de considerar una modelación más parsimoniosa del efecto día de la semana usando una variable en lugar de 6. En este caso, los días de la semana son primero divididos en dos categorías: días laborables y días no laborables. Luego la variable es

definida como  $[(N^\circ \text{ de L,M,M,J,V}) - \frac{5}{2}(N^\circ \text{ de S,D})]$ . Otras vez, la razón de este procedimiento

es que es deseable de que los coeficientes días de la semana cumplan  $\sum_{j=1}^7 \beta_j = 0$ . Desde que

$\beta_1 = \beta_2 = \beta_3 = \beta_4 = \beta_5$  y  $\beta_6 = \beta_7$ , se tiene  $5\beta_1 = -2\beta_6$ .

La variable Semana Santa (Easter) modela un cambio constante en el nivel de la actividad diaria durante  $d$  días antes de Semana Santa. El valor de  $d$  es usualmente fijado por el usuario.

$d = 0$	Para los meses $\neq$ de marzo y abril
$d = p_M - m_M$	Para el mes de marzo.  $p_M$ : proporción de $d$ días que caen en marzo  $m_M$ : valor medio de las proporciones de $d$ días que caen en marzo durante un largo periodo de tiempo.
$d = p_A - m_A$	Para el mes de abril.  $p_A$ : proporción de $d$ días que caen en abril  $m_A$ : valor medio de las proporciones de $d$ días que caen en abril durante un largo periodo de tiempo.
$m_M = m_A = 1/2$	Es una buena aproximación

Debido a que los efectos día de la semana y Semana Santa son modelados por medio de variables de regresión, una prueba estadística para estos efectos es el siguiente: Si ningún modelo ha sido identificado, especifique un modelo de Líneas Aéreas con media. En otro caso, use el modelo identificado. Luego, usando la serie diferenciada  $y$ , se aplica el filtro de Kalman para pasar de  $y = X\beta + \nu$  al modelo  $L^{-1}y = L^{-1}X\beta + L^{-1}\nu$ , donde  $\beta$  es un vector de parámetros de regresión que también incluye parámetros Trading Day y/o Easter. Debido a

que el modelo  $L^{-1}y = L^{-1}X\beta + L^{-1}v$  es un modelo OLS (mínimos cuadrados ordinarios), se puede usar el estadístico  $F$  para probar si todos los parámetros Trading Day son 0 ó no. El estadístico  $t$  puede usarse para probar si el parámetro Easter es 0.

#### **2.1.2.4c. Efectos de Intervención y de Regresión**

Las variables de intervención son variables de regresión que son usadas para modelar ciertos efectos anormales, tales como huelgas, cambios muy significativos en la política económica, desastres naturales, etc. Entre estas variables se tiene a impulsos, cambios de nivel, cambios momentáneos y saltos.

Estas variables usualmente consisten de una secuencias de 0 y 1. Otros efectos de regresión, como por ejemplo pueden ser variables económicas que se piensa que están relacionadas con la serie observada, también pueden ser incorporadas.

## **2.2. Componentes No Observados en Series de Tiempo Económicas**

En esta sección se expone el método de extracción de señales basado en modelos ARIMA, el cual fue implementado en el programa SEATS (Signal Extraction in ARIMA Time Series).

### **2.2.1. Conceptos y Definiciones Previas**

A continuación se presenta un conjunto de conceptos y definiciones cuyo fin es facilitar la comprensión de las siguientes secciones del presente capítulo. Lectores interesados pueden consultar Kayser y Maraval (2000), las referencias contenidas ahí, y Planas (1997)

**Tendencia.-** Es una lenta variación sobre un largo periodo de tiempo, generalmente asociado con causas estructurales del fenómeno en cuestión. En algunos casos, la tendencia muestra un crecimiento estable (steady growth), en otros, puede moverse hacia arriba y también hacia abajo..

**Ciclo.-** Es una oscilación cuasi periódica caracterizado por periodos alternos de expansión y contracción, en la mayoría de los casos está relacionado a fluctuaciones en la actividad económica.

**Variaciones estacionales.-** Representa el efecto del clima y eventos institucionales que se repiten más o menos con regularidad cada año.

**Fluctuaciones irregulares.-** representa movimientos no previsibles relacionados a eventos de toda clase. Estas fluctuaciones se supone que tienen una apariencia aleatoria estable, pero en algunos casos valores extremos pueden estar presentes. Estos valores extremos, o outliers, pueden tener causas identificables tales como huelgas o terremotos y por lo tanto pueden ser distinguidos de muchas variaciones irregulares pequeñas.

### Representación de Wold

Para empezar la modelación de una serie de tiempo, un resultado general particularmente útil sobre un proceso lineal es la representación de Wold o Fundamental. Si  $z_t$  es un proceso estacionario estocástico lineal sin ningún componente determinístico, entonces puede ser expresado como un proceso de medias móviles:

$$z_t = a_t + \psi_1 a_{t-1} + \psi_2 a_{t-2} + \dots = \sum_{j=0}^{\infty} \psi_j a_{t-j} = \psi(B)a_t \quad \text{donde } a_t \text{ es ruido blanco}$$

$\sim(0; V_a)$ ; donde  $\psi(B)$  satisface: i)  $\psi_j \rightarrow 0$  cuando  $j \rightarrow \infty$  y ii)  $\sum_{j=0}^{\infty} |\psi_j| < \infty$ . Dado los

coeficientes  $\psi_j$ ,  $a_t$  representa el error del pronóstico de  $z_t$  realizado en el momento  $t-1$ , esto es:  $a_t = z_t - \hat{z}_{t|t-1}$ . Debido a que  $a_t$  representa algo nuevo en  $z_t$ , teniendo en cuenta de que no está contenido en su pasado  $\{z_{t-1}, z_{t-2}, z_{t-3}, \dots\}$  se le suele llamar innovación del proceso.

### Función Generadora de Autocovarianzas

La Función Generadora de Autocovarianzas de  $z_t$  (Autocovariance generating function-AGF),  $\gamma(B, F)$ , está dado por:  $\gamma(B, F) = \psi(B)\psi(F)V_a$ . Para el caso de la varianza del proceso  $z_t$ ,  $V_z = (1 + \psi_1^2 + \psi_2^2 + \dots)V_a$ .

## El Espectro

El espectro es la herramienta básica en el análisis de las series de tiempo en el dominio de las frecuencias. Representa una forma alternativa de analizar la información contenida en los momentos de segundo orden de la serie. El análisis de las series de tiempo en el dominio de las frecuencias es particularmente conveniente para el análisis de los componentes no observados de una serie, tales como la tendencia, el ciclo, la estacionalidad, etc.

## Espectro Muestral del Proceso $z_t$

$H(\omega) = \frac{1}{2\pi}(\hat{\gamma}_0 + 2\sum_{t=1}^{T-1}\hat{\gamma}_t \cos \omega t)$ , donde  $\hat{\gamma}_j$  es el estimado de la autocovarianza de rezago  $j$ . A

esta expresión también se le conoce como la transformación de Fourier de la función de autocovarianzas muestral de  $z_t$ .

## Espectro del Proceso $z_t$

Sea  $\gamma(B, F)$  la AGF del proceso estacionario  $z_t$ ,  $\gamma(B, F) = \gamma_0 + \sum_{j=1}^{\infty} \gamma_j (B^j + F^j)$ , donde  $B$  es un número complejo de módulo unitario. Reemplazando  $B$  y  $F$  por su representación compleja

se llega a  $g(\omega) = \gamma_0 + \sum_{j=1}^{\infty} \gamma_j (e^{-i\omega j} + e^{i\omega j})$ .

Teniendo en cuenta que:  $B = m + ni \Rightarrow B | e^{i\omega} = |B| (\cos(\omega) + \text{sen}(\omega)i)$

$$B^j = (e^{i\omega})^j = e^{i\omega j} = \cos(\omega j) + \text{sen}(\omega j)i$$

$$B^{-j} = (B^{-1})^j = B^{-j} = (e^{i\omega})^{-j} = e^{-i\omega j} = \cos(-\omega j) + \text{sen}(-\omega j)i = \cos(\omega j) - \text{sen}(\omega j)i$$

Entonces,  $g(\omega) = \gamma_0 + \sum_{j=1}^{\infty} \gamma_j 2 \cos \omega j$ , dividiendo esta expresión por  $2\pi$  se obtiene el Power

Spectrum (o simplemente espectro) del proceso  $z_t$ ,  $g_1(\omega) = \frac{1}{2\pi} (\gamma_0 + 2 \sum_{j=1}^{\infty} \gamma_j \cos \omega j)$ . Dado

que  $g_1(\omega)$  es una función periódica, el rango de frecuencias para el análisis puede ser restringido a  $[-\pi, \pi]$  ó  $[0, 2\pi]$ . Adicionalmente, por ser la función coseno simétrico alrededor de cero, se suele considerar para fines analíticos el rango  $[0, \pi]$ .

Al dividir  $g_1(\omega)$  por  $\gamma_0$ , se obtiene la Función de Densidad Espectral (Spectral density

function) del proceso  $z_t$ ,  $g_1^*(\omega) = \frac{1}{2\pi} (1 + 2 \sum_{j=1}^{\infty} \rho_j \cos \omega j)$ .

Conocido la AGF de un proceso se puede obtener fácilmente su espectro. El camino inverso también se puede llevarse a cabo, esto es, conocido el espectro se puede obtener la AGF por

medio de la transformación inversa de Fourier, dado por  $\gamma_k = \int_{-\pi}^{\pi} g(\omega) \cos(\omega k) d\omega$ ; para  $k=0$

se obtiene  $\gamma_0 = \int_{-\pi}^{\pi} g(\omega) d\omega$ , es decir, el área bajo el espectro para el intervalo  $d\omega$  es la

contribución a la varianza de la serie que corresponde al rango de frecuencias  $d\omega$ . A grosso

modo, el espectro puede ser visto como la descomposición de la varianza por frecuencias.

Ejemplos:

$$1) z_t + 0,81z_{t-2} = a_t$$

$z_t = \frac{1}{1 + 0,81 B^2} a_t$ , es la representación de Wold del proceso  $z_t$ , tal que

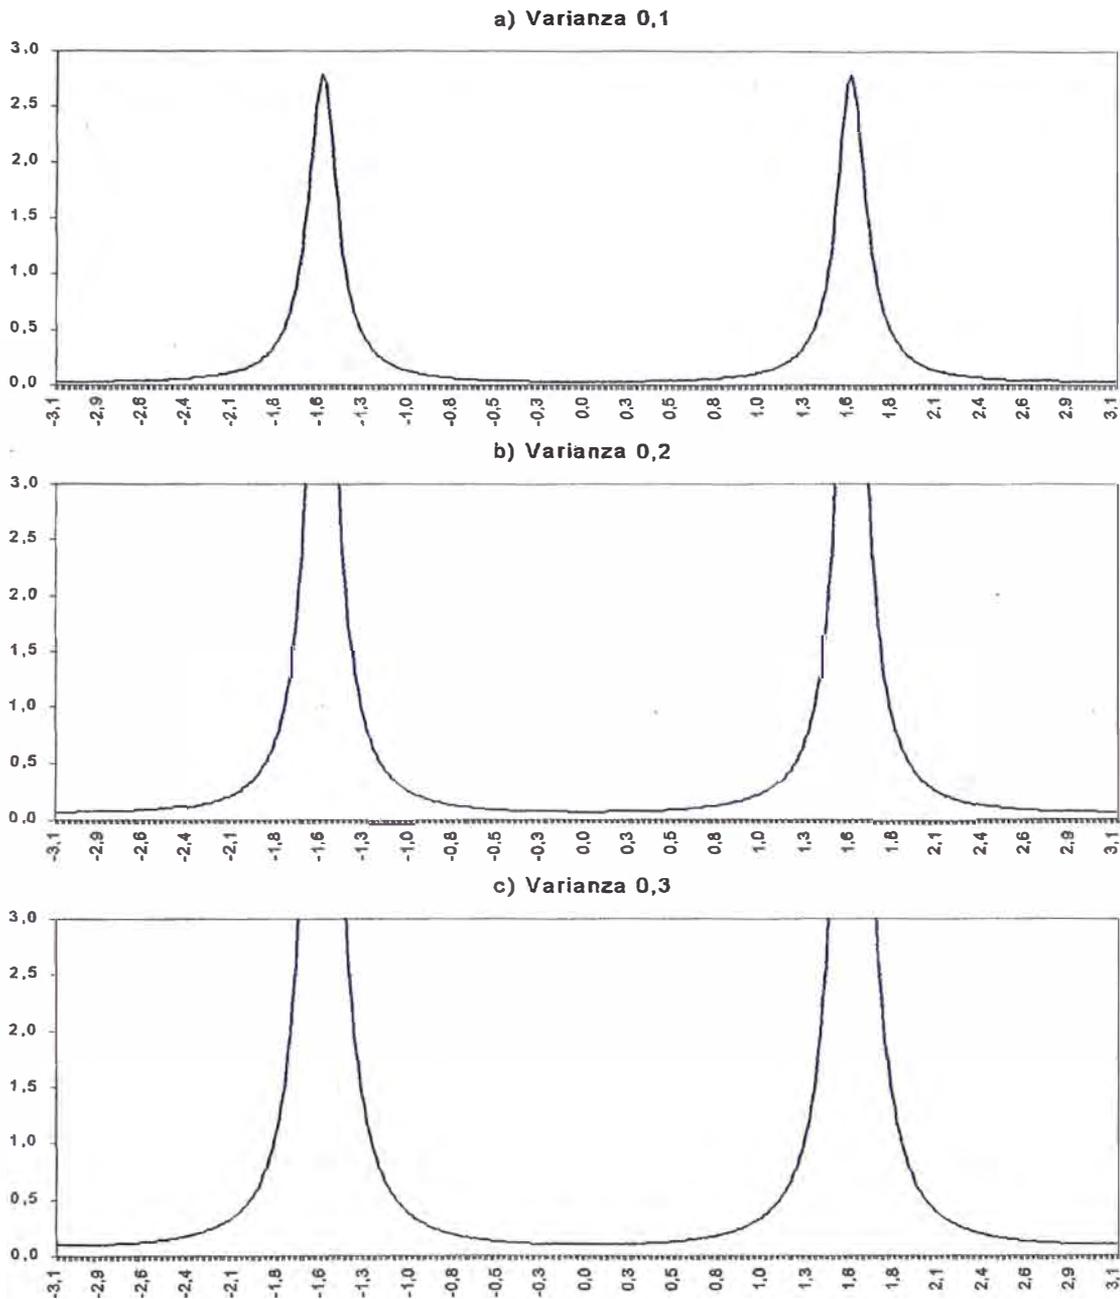
$$\psi(B) = \frac{1}{1 + 0,81B^2}$$

La AGF está dado por

$$\gamma(B, F) = \psi(B)\psi(F)V_a = \left(\frac{1}{1 + 0,81B^2}\right)\left(\frac{1}{1 + 0,81F^2}\right)V_a = \frac{1}{1,656 + 0,81(B^2 + F^2)}V_a$$

Reemplazando  $B^2 + F^2 = 2 \cos 2\omega$  en esta ultima expresión se obtiene el espectro del

proceso.  $g(\omega) = \frac{1}{1,656 + 1,62 \cos 2\omega} V_a$



$$\gamma_k = \int_{-\pi}^{\pi} g(\omega) \cos(\omega k) d\omega = \int_{-\pi}^{\pi} g(\omega) \cos(\omega k) d\omega$$

Nota: Si una serie contiene un componente importante para una determinada frecuencia  $\omega_0$ , entonces su espectro debería mostrar un pico alrededor de esa frecuencia.

## 2) Ruido Blanco

$$z_t = \alpha_t$$

$$\gamma(B, F) = \psi(B)\psi(F)V_a = (1)(1)V_a = V_a = Cte$$

## 3) Proceso MA(1)

$$z_t = \alpha_t + \theta_1 B \alpha_t = (1 + \theta_1 B) \alpha_t$$

$$\gamma(B, F) = \psi(B)\psi(F)V_a = (1 + \theta_1 B)(1 + \theta_1 F)V_a = [1 + \theta_1^2 + \theta_1(B + F)]V_a$$

Reemplazando  $B + F = 2 \cos \omega$ , se obtiene el espectro  $g(\omega) = [1 + \theta_1^2 + 2\theta_1 \cos \omega]V_a$ .

## 4) Proceso AR(1)

$$z_t + \phi_1 z_{t-1} = \alpha_t$$

$z_t = \frac{1}{1 + \phi_1 B} \alpha_t$ ; Para que el proceso sea estacionario se asume que  $|\phi_1| < 1$ .

$$\gamma(B, F) = \psi(B)\psi(F)V_a = \left(\frac{1}{1 + \phi_1 B}\right)\left(\frac{1}{1 + \phi_1 F}\right)V_a = \frac{1}{1 + \phi_1^2 + \phi_1(B + F)}V_a$$

Reemplazando  $B + F = 2 \cos \omega$ , se obtiene el espectro  $g(\omega) = \frac{1}{1 + \phi_1^2 + 2\phi_1 \cos \omega}V_a$

La ecuación característica del proceso AR(1) es  $r + \phi_1 = 0$ , luego  $r = -\phi_1$

Si  $r < 0$  ( lo que implica que  $\phi_1 > 0$ ), el espectro mostrará un pico en  $\omega = \pi$  (si  $r > 0$  mostrará un pico en  $\omega = 0$ ), el cual está asociado al periodo  $\tau = 2\pi / \pi = 2$ . Esto implica: i) Para una serie mensual corresponde a un comportamiento de frecuencia estacional de 6 veces al año; ii) para una serie trimestral corresponde a un comportamiento de frecuencia estacional de

2 veces al año; iii) para una serie anual corresponde a un ciclo que tiene una duración de 2 años.

### 5) Proceso AR(2)

$$z_t + \phi_1 z_{t-1} + \phi_2 z_{t-2} = a_t$$

$$z_t = \frac{1}{1 + \phi_1 B + \phi_2 B^2} a_t$$

$$\begin{aligned} \gamma(B, F) &= \psi(B)\psi(F)V_a = \left(\frac{1}{1 + \phi_1 B + \phi_2 B^2}\right)\left(\frac{1}{1 + \phi_1 F + \phi_2 F^2}\right)V_a \\ &= \frac{1}{1 + \phi_1^2 + \phi_2^2 + \phi_1(1 + \phi_2)(B + F) + \phi_2(B^2 + F^2)}V_a \end{aligned}$$

Reemplazando  $B + F = 2 \cos \omega$  y  $B^2 + F^2 = 2 \cos 2\omega$ , se obtiene el espectro

$$g(\omega) = \frac{1}{1 + \phi_1^2 + \phi_2^2 + 2\phi_1(1 + \phi_2)\cos\omega + 2\phi_2 \cos 2\omega}V_a$$

Teniendo en cuenta que la ecuación característica del proceso AR(2) es  $r^2 + \phi_1 r + \phi_2 = 0$ , algunos resultados útiles son:

i) Si las raíces son reales y están dentro del círculo unitario ( $|r_1| < 1$ ,  $|r_2| < 1$ ).

Si  $r_1, r_2 > 0$ , entonces el espectro mostrará un pico en  $\omega = 0$

Si  $r_1 > 0, r_2 < 0$ , entonces el espectro tendrá dos picos: uno en  $\omega = 0$  y el otro en  $\omega = \pi$

Si  $r_1, r_2 < 0$ , entonces el espectro tendrá un pico en  $\omega = \pi$

ii) Si las raíces son números complejos conjugados. Entonces tendrá un pico en

$$\omega = \cos^{-1}\left(\frac{\phi_1}{2\sqrt{\phi_2}}\right)$$

Para un proceso AR(p), un procedimiento seguido consiste en factorizar el polinomio AR.

Las raíces reales implicará picos en el espectro de acuerdo a un AR(1) y AR(2).

Rango de Frecuencias (para una serie trimestral)		
Valor de $\omega$	Periodo ( $\tau = 2\pi / \omega$ )	Correspondencia con el tipo de componente
0	$\infty$	Tendencia
$\pi / 2$	4	Estacionalidad, 1 vez al año
$\pi$	2	Estacionalidad, 2 veces al año
$[\pi / 2; \pi]$ ,	[2;4]	Estacionalidad, de 1 a 2 veces al año. Estos no son de interés para el análisis de los ciclos económicos. Al rango que resulta de excluir los valores extremos se le denomina rango de frecuencias intraestacionales.
$[0 + \varepsilon_1; \pi / 2 - \varepsilon_2]$ ; $\varepsilon_1, \varepsilon_2 > 0$	$\left[\frac{2\pi}{\frac{\pi}{2} - \varepsilon_2}, \frac{2\pi}{\varepsilon_1}\right]$	Componentes cíclicos de más de un año. Los ciclos económicos tienen su espectro concentrado en este rango de frecuencias, al cual se le

		denomina rango de frecuencias cíclicas.
--	--	--

La determinación de los valores de  $\varepsilon_1$  y  $\varepsilon_2$  a fin de precisar el rango de frecuencias cíclicas es fundamentalmente subjetivo y depende del tipo de análisis que se haga. Por ejemplo, tratándose de data trimestral, para el análisis de los ciclos económicos, es claro que un ciclo de periodo de 10000 años debe de ser incluido en el componente de la tendencia, y no en el del ciclo económico. Si el ciclo más largo que se está considerando para el análisis de los ciclos económicos tiene un periodo de 12 años (48 trimestres), entonces  $\varepsilon_1 = \pi / 24$ . Si el ciclo más corto que se está considerando tiene un periodo de 2 años (8 trimestres), entonces  $\varepsilon_2 = \pi / 4$ . Por lo tanto, el rango de frecuencias cíclicas corresponde a  $[\pi / 24; \pi / 4]$ .

Si el proceso  $z_t$  fuese no estacionario, por ejemplo el paseo aleatorio  $z_t = z_{t-1} + a_t$ , donde  $a_t$  es un ruido blanco, se tiene que  $z_t = \frac{1}{1-B} a_t$ . La AGF de este proceso es

$$\gamma(B, F) = \psi(B)\psi(F)V_a = \left(\frac{1}{1-B}\right)\left(\frac{1}{1-F}\right)V_a = \frac{1}{2-(B+F)}V_a, \text{ luego el espectro es}$$

$$g(\omega) = \frac{1}{2(1-\cos\omega)}V_a. \text{ Para la frecuencia } \omega = 0, g(\omega) \rightarrow \infty, \text{ por lo que resulta claro que la}$$

integral de  $g(\omega)$  no converge. Es decir, la varianza del paseo aleatorio es ilimitada. Este es un resultado general aplicable a un proceso que tiene un AR(p). Si este polinomio AR contiene a  $S = 1 + B + B^2 + B^3 = (1+B)(1+B^2)$ , las raíces del polinomio característico son  $-1, i$  y  $-i$ . El primero está asociado a la frecuencia  $\omega = \pi$  y el par de complejos conjugados a  $\omega = \pi / 2$ . En

estos puntos el espectro será infinito. Para el caso de procesos no estacionarios se usa la terminología pseudo espectro y pseudo AGF.

### Filtros Lineales y su Squared Gain

Sea  $y_t = c_{-k_1}x_{t-k_1} + \dots + c_{-1}x_{t-1} + c_0x_t + c_1x_{t+1} + \dots + c_{-k_2}x_{t-k_2} = C(B, F)x_t$  donde

$$C(B, F) = \sum_{j=1}^{k_1} c_{-j}B^j + c_0 + \sum_{j=1}^{k_2} c_jF^j$$

Si el filtro  $C(B, F)$  es centrado y simétrico, es decir,  $k_1 = k_2$  y  $c_j = c_{-j}, \forall j$  se tiene la expresión

$$C(B, F) = c_0 + \sum_{j=1}^k c_j(B^j + F^j). \quad \text{Reemplazando, } B^j + F^j = 2\cos(j\omega) \quad \text{se obtiene la}$$

transformación de Fourier de  $C(B, F)$ ;  $G(\omega) = c_0 + 2\sum_{j=1}^k c_j \cos(j\omega)$ .

Aplicando la transformación de Fourier a  $AGF(y) = [C(B, F)]^2 AGF(x)$  se obtiene  $g_y(\omega) = [G(\omega)]^2 g_x(\omega)$ . El primer miembro es el espectro de  $y_t$ ,  $G(\omega)$  es el Gain del filtro y el segundo factor del miembro derecho es el espectro de  $x_t$ . El cuadrado de  $G(\omega)$  determina cuál es la contribución de la varianza de  $x_t$  al explicar la varianza de  $y_t$  para cada frecuencia diferente.

Ejemplos:

Si  $G(\omega) = 1$ , entonces la variación de  $x_t$  para esa frecuencia es completamente trasladada a  $y_t$ .

Si  $G(\omega) = 0$ , entonces la variación de  $x_t$  para esa frecuencia es completamente ignorada en la estimación de  $y_t$ .

Cuando el interés se centra en los componentes de una serie, los mismos que están fundamentalmente caracterizados por sus propiedades de frecuencia, la función  $[G(\omega)]^2$  se convierte en una herramienta fundamental. Ello debido a que nos dice cuáles son las frecuencias que contribuirán al componente y cuáles no.

Ejemplo:

Rango de Frecuencias (para una serie trimestral)		
Valor de $\omega$	Periodo ( $\tau = 2\pi / \omega$ )	Correspondencia con el tipo de componente
0	$\infty$	Tendencia
$\pi / 2$	4	Estacionalidad, 1 vez al año
$\pi$	2	Estacionalidad, 2 veces al año

Un filtro de ajuste estacional será uno cuyo Squared Gain,  $[G(\omega)]^2$ , muestre agujeros o huecos para las frecuencias estacionales que removerá picos espectrales estacionales, dejando el resto básicamente sin variación. Son los casos de las frecuencias  $\pi$  y  $\pi/2$ .

*Un filtro de remoción de tendencia será uno cuyo Squared Gain removerá los picos espectrales para la frecuencia cero y dejará el resto aproximadamente invariable.*

### 2.2.2. Método de Extracción de Señales Basado en Modelos ARIMA

Este método se basa en un conjunto de supuestos, los cuales son utilizados en la modelación de los componentes no observados de una serie. En el método AMB los componentes son modelados como procesos estocásticos lineales paramétricos, los cuales se eligen para capturar picos espectrales asociados con cada componente. Los componentes son derivados a partir del modelo ARIMA estimado para la serie observada. Referencias relevantes son Gómez y Maravall (2000b), Maravall (1995), (1993), (1989) y (1987). Este procedimiento fue implementado en el programa SEATS y su operación se encuentra en Caporello y Maravall (2000a) y (2000b)

Sea  $x_t$  la serie linealizada, es decir, removida por outliers y otros efectos especiales. En la sección 2.1. se describió el procedimiento para llevar a cabo este ajuste el cual fue implementado en el programa TRAMO. Para propósitos del presente estudio un componente de importancia es la serie desestacionalizada o ajustada por estacionalidad. El principal propósito de remover la estacionalidad es obtener una mejor señal de la evolución subyacente de la serie.

$x_t$  puede expresarse como 
$$x_t = \sum_{i=1}^k x_{it} .$$

$x_{1t}, x_{2t}, \dots, x_{kt}$  representan los  $k$  componentes no observados de  $x_t$ .

### Supuesto 1

Cada componente puede ser expresado como el resultado de un proceso estocástico lineal del tipo  $\phi_i(B)\delta_i(B)x_{it} = \theta_i(B)a_{it}$ , en forma más compacta  $\phi_i(B)x_{it} = \theta_i(B)a_{it}$  es un modelo  $ARMA(p_i, q_i)$

Donde:

$a_{it}$	Ruido blanco
$\delta_i(B)$	Tiene sus raíces =1
$\phi_i(B)$	Tiene sus raíces >1(en valor absoluto)
$\theta_i(B)$	Tiene sus raíces >1(en valor absoluto)

Para cada  $i$ , los tres polinomios en  $B$  son primos entre sí.

### Supuesto 2

Los polinomios  $\phi_i(B)$  y  $\theta_j(B)$ ,  $i \neq j$ , no comparten ninguna raíz en común. Consecuentemente, son primos entre sí.

Teniendo en cuenta que  $x_t = \sum_{i=1}^k x_{it} = \sum_{i=1}^k \frac{\theta_i(B)}{\phi_i(B)} a_{it}$ , esto implica, bajo el Supuesto 2, que  $x_t$  es

también el resultado de un proceso lineal. Entonces,  $x_t$  se puede también expresar como

$\phi(B)\delta(B)x_t = \theta(B)a_t$ , donde  $\delta(B) = \prod_{i=1}^k \delta_i(B)$ ,  $\phi(B) = \prod_{i=1}^k \phi_i(B)$ ,  $\theta(B)$  es un polinomio de

orden  $q$  en  $B$  y  $\alpha_t$  es una innovación ruido blanco. Luego,  $\phi(B)x_t = \theta(B)\alpha_t$ , donde  $\phi(B) = \varphi(B)\delta(B)$ , es la forma reducida del modelo de  $x_t$ .

La consistencia entre la forma reducida del modelo para  $x_t$  y sus componentes, implica

$$\phi(B) = \prod_{i=1}^k \phi_i(B) \text{ y } \theta(B)\alpha_t = \sum_{i=1}^k \theta_i(B)\phi_{ni}(B)\alpha_{it}, \text{ donde } \phi_{ni} = \prod_{j=1(j \neq i)}^k \phi_j, \text{ es el producto de todos}$$

los polinomios AR, excluyendo  $\phi_i(B)$ .

### Supuesto 3

Los polinomios  $\theta_i(B)$  no comparten raíces unitarias en común.

#### 2.2.3. Especificación de los Componentes No Observados

Al igual que no hay una definición universalmente aceptada de una tendencia o de un componente estacional, tampoco hay una especificación de modelo universalmente aceptada para un componente en particular.

El procedimiento seguido por el método basado en modelos ARIMA (ARIMA model-based, AMB) para la especificación de los modelos de los componentes no observados de una serie empieza identificando un modelo para la serie observada y luego deriva modelos apropiados para sus componentes compatibles con el modelo para la serie observada; vea Gómez y Maravall (2000b) y Maravall (1995).

Mnemónico	Componente
$x_t = p_t + n_t + u_t$	Serie a ser descompuesta
$p_t$	Tendencia-ciclo
$n_t$	Estacional
$u_t$	Irregular
$s_t = x_t - n_t = p_t + u_t$	Serie ajustada por estacionalidad

### Componente Tendencia

El concepto de un componente de tendencia está lejos de tener una definición precisa y universalmente aceptada. La tendencia ha sido modelada como funciones determinísticas del tiempo, como un proceso puramente estocástico o como una combinación de ambos.

Bajo el método AMB el modelo general es del tipo  $\nabla^d p_t = \psi_p(B)\alpha_{pt}$ , el cual tiene una parte determinística y una parte estocástica. Alternativamente, también puede expresarse como

$$\phi_p(B)\nabla^d p_t = \theta_p(B)a_{pt}.$$

### Componente Estacional

Si la serie bajo análisis contiene estacionalidad, típicamente se emplea data ajustada por estacionalidad.

Por ejemplo, en el método AMB el componente estacional para el modelo  $\nabla\nabla_4 x_t = (1 - \theta_1 B)(1 - \theta_4 B^4) a_t$  es de la forma  $S n_t = \theta_n(B) a_{nt}$ . Un modelo general para este componente es del tipo  $\phi_n(B) S n_t = \theta_n(B) a_{nt}$ .

### **Componente Irregular y Componente Transitorio**

En el método AMB el irregular se asume que es un ruido blanco. Cuando un componente transitorio se incluye por separado, se puede asumir que sigue un proceso ARMA estacionario del tipo  $\phi_c(B) C_t = \theta_c(B) a_{ct}$ .

Los componentes transitorios (o temporales) son usados en econometría para captar la variabilidad de corto plazo de la serie y es igual a la serie menos su componente permanente. De aquí que el componente transitorio puede ser visto como la serie (a menudo ajustada por estacionalidad) removido por su tendencia. El componente transitorio será un proceso ARMA estacionario.

#### **2.2.4. Identificación de los Componentes No Observados**

##### **Supuesto 4**

Los polinomios  $\phi(B)$  y  $\theta(B)$ , así como la varianza de  $a_t$ ,  $\sigma_a^2$ , son conocidos.

Considerando que  $\phi(B) = \prod_{i=1}^k \phi_i(B)$  y bajo el Supuesto 2, la factorización de  $\phi(B)$  produce directamente los polinomios  $\phi_i(B)$ . Las raíces diferentes de  $\phi(B)$  pueden ser asignados a componentes diferentes, de acuerdo al comportamiento que ellos inducen en la serie observada. Así, los polinomios AR de los componentes están identificados y pueden ser obtenidos del polinomio AR del modelo para la serie observada.

Los parámetros que requieren ser determinados son los de los polinomios MA,  $\theta_i(B)$ , y la matriz  $\Sigma$  de covarianzas contemporáneas del vector de pseudo-innovaciones  $(a_{it}, \dots, a_{kt})$ :

$\Sigma = [\text{cov}(a_{it}, a_{jt})]$ . Estos parámetros tienen que ser obtenidos de la igualdad

$$\theta(B)a_t = \sum_{i=1}^k \theta_i(B)\phi_{ni}(B)a_{it}.$$

Bajo el supuesto de normalidad, si el sistema de ecuaciones que

resulta de igualar las autocovarianzas del miembro izquierdo a las autocovarianzas del

miembro derecho de  $\theta(B)a_t = \sum_{i=1}^k \theta_i(B)\phi_{ni}(B)a_{it}$  se encuentra una solución aislada localmente

para los parámetros en  $\theta_i(B)$  y  $\Sigma$  por lo que los modelos para los componentes resultarán

identificados. Naturalmente, sin ningún supuesto adicional habrá un número infinito de

posibles especificaciones que satisfarán con la igualdad  $\theta(B)a_t = \sum_{i=1}^k \theta_i(B)\phi_{ni}(B)a_{it}$  y un

sistema de ecuaciones de covarianzas. Para obtener una solución particular es necesario algunas restricciones adicionales.

**Supuesto 5**

Las pseudo-innovaciones  $a_{it}$  y  $a_{jt}$  están incorrelacionadas para todo  $i \neq j$ .

Consecuentemente,  $\Sigma = \begin{bmatrix} \sigma_1^2 & 0 & \Lambda & 0 \\ 0 & \sigma_2^2 & \Lambda & 0 \\ M & M & O & M \\ 0 & 0 & \Lambda & \sigma_k^2 \end{bmatrix}$

**Restricciones Adicionales para Alcanzar la Identificación bajo el Método AMB**

El Supuesto 5 no es suficiente para identificar al modelo porque se requiere algunas restricciones adicionales. Por fines didácticos se trabajará con el siguiente ejemplo: sea  $\nabla\nabla_4 x_t = (1 - \theta_1 B)(1 - \theta_4 B^4)a_t$  el modelo a descomponer. Si se desea descomponer la serie en sus componentes tendencia, estacional e irregular,  $x_t = p_t + n_t + u_t$ .

Entonces,  $\nabla^2 p_t = \theta_p(B)a_{pt}$ ,  $Sn_t = \theta_n(B)a_{nt}$  y  $u_t = a_{ut}$ , también se tiene que

$\theta(B)a_t = \theta_p(B)Sa_{pt} + \theta_n(B)\nabla^2 a_{nt} + \nabla\nabla^4 a_{ut} \dots \dots \dots (\alpha)$

El miembro derecho de esta última igualdad es un  $MA(5)$ , luego  $\theta_p(B)$  es un  $MA(2)$  y  $\theta_n(B)$  es un  $MA(3)$ , los cuales pueden especificarse como:

$\nabla^2 p_t = \theta_p(B)a_{pt} = (1 + \theta_{p1}B + \theta_{p2}B^2)a_{pt}$
$Sn_t = \theta_n(B)a_{nt} = (1 + \theta_{n1}B + \theta_{n2}B^2 + \theta_{n3}B^3)a_{nt}$
$u_t = a_{ut}$

Igualando las autocovarianzas del lado derecho e izquierdo de  $(\alpha)$  se obtiene un sistema de 6 ecuaciones. Estas ecuaciones expresan la relación entre los parámetros del modelo ARIMA para la serie observada y los parámetros desconocidos en los modelos de los componentes. El número de parámetros desconocidos es 8  $(\theta_{p1}, \theta_{p2}, \theta_{n1}, \theta_{n2}, \theta_{n3}, \sigma_p^2, \sigma_n^2, \sigma_u^2)$  y sólo hay 6 ecuaciones, por lo que el sistema está subidentificado. El modelo del  $i$ -ésimo componente está identificado si el orden de su polinomio AR,  $p_i$ , excede el de su polinomio MA,  $q_i$ .

En la descomposición de  $x_t$ , sea  $u_t$  un componente de ruido y asúmase para todos los componentes, excepto para  $u_t$ , que se cumple  $p_i \geq q_i$ . Si  $p \geq q$ ,  $u_t$  será un ruido blanco; si  $p < q$ ,  $u_t$  será un  $MA(q-p)$ , un ruido no blanco. Luego, considere todas las especificaciones posibles (bajo los supuestos 1- 5) que satisfacen la identidad  $(\alpha)$  y que el espectro del componente sea no negativo. Para un modelo en su forma reducida para la serie, dichas especificaciones forman el conjunto de descomposiciones admisibles. Cada descomposición admisible mostrará propiedades diferentes.

En la descomposición del modelo  $\nabla\nabla_4 x_t = (1 - \theta_1 B)(1 - \theta_4 B^4) a_t$  en tres componentes ortogonales  $(p_t, n_t, u_t)$ , la suma de los espectros de los componentes es igual al espectro de la serie observada.

Los componentes, de los cuales ningún ruido aditivo puede extraerse se les denomina *componentes canónicos* y fueron primeramente propuestos por Box, Hillmer y Tiao (1978). Si una descomposición admisible existe, el requerimiento canónico identifica el componente, debido a que el componente canónico se obtiene sustituyendo del espectro del componente admisible su valor mínimo. La condición canónica también minimiza la varianza de la pseudo-innovación,  $a_{pt}$ . Debido a que  $a_{pt}$  es la fuente de variabilidad estocástica, el componente canónico puede ser visto como el más cercano a un componente determinístico que sea compatible con la estructura estocástica de la serie. Al igual que para el caso de la tendencia, cualquier componente estacional admisible puede ser visto como la suma de uno canónico y un ruido. Luego, si un componente estacional está disponible, el componente canónico puede obtenerse fácilmente. Finalmente, la descomposición canónica conlleva a una maximización de la varianza del componente irregular.

En el análisis de las series de tiempo en el dominio de las frecuencias, el requerimiento canónico para identificar el sistema de 6 ecuaciones de covarianzas implica agregar las siguiente 2 restricciones: una tendencia canónica implica  $\theta_p(-1) = 1 + \theta_{p1}(-1) + \theta_{p2}(1)^2 = 0$  y un componente estacional canónico implica  $\theta_n(1) = 1 + \theta_{n1}(1) + \theta_{n2}(1)^2 + \theta_{n3}(1)^3 = 0$ , para el caso en el que el espectro 0 ocurre en  $\omega = 0$ . Estas dos restricciones se agregan al sistema de

6 ecuaciones, obteniéndose un sistema de 8 ecuaciones con 8 variables, por lo que resultará identificado.

### **2.2.5. Estimación de los Componentes No Observados**

Para la estimación de los componentes no observados (las señales) se utilizan estimadores MMSE. En Gómez y Maravall (2000b) y Maravall (1995) se encuentra los detalles de este procedimiento.

#### **2.2.5.1. Estimadores MMSE (Error Cuadrático Medio Mínimo)**

Para la consistencia del modelo  $x_t = \sum_{i=1}^k x_{it}$  y el conjunto de supuesto 1-5, el siguiente supuesto define el estimador de interés.

#### **Supuesto 6**

Sea  $X_T = [x_1, \dots, x_T]$  la serie de observaciones disponibles. El estimador óptimo del componente no observado  $x_{it}$  está dado por  $x_{it|T} = E(x_{it} | X_T)$ .

El supuesto 6 es un supuesto estándar en la estimación de componentes no observados basado en modelos. Conjuntamente con los supuesto 1-5 implica que  $x_{it|T}$  es una estimador lineal y será el estimador MMSE.

Para calcular la esperanza condicional  $x_{it|T}$  hay dos procedimientos conocidos. Uno está basado en el filtro de Kalman y el otro en el filtro de Wiener-Kolmogorov (WK). La metodología AMB (en el cual se basa el programa SEATS) usa el filtro WK.

### 2.2.5.2. Filtro Wiener-Kolmogorov

Si  $x_t = s_t + n_t$ , donde  $s_t$  es la señal de interés (v.g. la serie desestacionalizada) y  $n_t$ , la suma de los demás componentes (v.g. el componente estacional). Los componentes siguen los modelos:

$\phi_s(B) = \theta_s(B)a_{st}$
$\phi_n(B) = \theta_n(B)a_{nt}$
$\phi(B) = \prod_i \phi_i(B) = \phi_s(B)\phi_n(B)$
$\theta(B)a_t = \theta_s(B)\phi_n(B)a_{st} + \theta_n(B)\phi_s(B)a_{nt}$

Para una realización completa, cuya notación es  $X = [x_{-\infty}, \dots, x_t, \dots, x_{\infty}]$ , y el caso de una serie estacionaria para el modelo UCARIMA

$x_t = S_t + n_t$
-------------------

$s_t = \psi_s(B)a_{st}$
$n_t = \psi_n(B)a_{nt}$

el estimador para la señal  $s_t$  es  $\hat{s}_t = s_{t|\infty} = E(m_t | X) = k_s \frac{\psi_s(B)\psi_s(F)}{\psi(B)\psi(F)} x_t$ , donde

$k_s = \sigma_s^2 / \sigma_a^2$ . La expresión  $v(B,F) = k_s \frac{\psi_s(B)\psi_s(F)}{\psi(B)\psi(F)}$  es el filtro WK.

El filtro WK, bajo el supuesto 3, siempre convergerá.  $v(B,F)$  es un filtro centrado en  $t$ , simétrico, y convergente en  $B$  y  $F$ . Este filtro será finito cuando el modelo en su forma reducida del proceso tiene un AR finito.

Cuando se dispone de una realización finita  $X = [x_1, \dots, x_T]$  y la serie continúa siendo estacionaria el filtro se aplica a la serie extendida con forecasts y backcasts.

Por su propia naturaleza, conceptos tales como la tendencia o estacionalidad conllevan a una media no constante asociado a una serie no estacionaria. El tipo de no estacionariedad que se considera está referido a las raíces unitarias de los polinomios AR.

Bajo los supuestos estándar se puede demostrar que el filtro WK usado para el caso de una serie estacionaria, sigue siendo válido para el caso de una serie no estacionaria. Es decir, nos provee el estimador MMSE para la señal de interés y para una realización completa. Para una realización finita se aplica el filtro a la serie extendida con forecasts y backcasts de modo análogo al del caso de la serie estacionaria.

En general, para una descomposición del tipo  $x_t = \sum_{i=1}^k x_{it}$ , el estimador MMSE del  $i$ -ésimo

componente es  $\hat{x}_{it} = k_i \frac{\psi_i(B)\psi_i(F)}{\psi(B)\psi(F)} x_t = \frac{ACGF(x_{it})}{ACGF(x_t)} x_t$ , donde  $k_i = \sigma_i^2 / \sigma_a^2$ .

### 2.2.5.3. Estructura y Subestimación Estructural del Estimador Optimo

Expresando el estimador  $\hat{s}_t$  en términos de la innovación  $a_t$  de la serie observada se tiene

$\phi_s(B)\hat{s}_t = \theta_s(B)\alpha_s(F)a_t$ , el modelo del estimador, donde  $\alpha_s(F) = k_s \frac{\theta_s(F)\phi_n(F)}{\theta(F)}$

Comparandolo con  $\phi_s(B)s_t = \theta_s(B)a_{mt}$  (el modelo del componente no observado), se nota que comparten el mismo polinomio AR. La transformación estacionaria es la misma en ambos; el componente y su estimador tienen el mismo orden de integración. Además, los dos modelos comparten los mismos polinomios en B. La diferencia básica radica en la presencia del polinomio  $\alpha_s(F)$  en el modelo del estimador. Este filtro en F expresa el carácter de dos lados del filtro Wiener-Kolmogorov, esto es, la dependencia del estimador final de  $s_t$ ,  $\hat{s}_t$ , de las innovaciones posteriores al periodo  $t$ .

En cualquier caso, los modelos para  $s_t$  y  $\hat{s}_t$  son estructuralmente diferentes. Ellos mostrarán covarianzas (para la transformación estacionaria) y espectros diferentes.

Para entender las diferencias entre el espectro de  $s_t$  y  $\hat{s}_t$  se tiene que:

$$\hat{s}_t = v(B, F)x_t$$

$$g_{\hat{s}}(\omega) = R^2(\omega)g_x(\omega); \text{ donde } R(\omega) = \frac{g_s(\omega)}{g_x(\omega)} = \frac{1}{1 + 1/r(\omega)}$$

Dado que  $r(\omega) \geq 0$ , entonces  $0 \leq R(\omega) \leq 1$ ;  $g_{\hat{s}}(\omega) = R(\omega)g_s(\omega)$ ;  $0 \leq g_{\hat{s}}(\omega) \leq g_s(\omega)$  se nota que el estimador siempre subestimará el componente. Si se considera que  $g_{\hat{s}}(\omega) / g_s(\omega)$  es una función creciente en  $\sigma_s^2 / \sigma_a^2$ , la subestimación relativa es grande cuando la varianza de la innovación del componente ( $\sigma_s^2$ ) es pequeña. La subestimación es pequeña cuando la innovación del componente es grande, o lo que es lo mismo, componentes relativamente más estocásticos implicará una subestimación más pequeña.

La función de autocorrelación y la varianza teóricas de la transformación estacionaria del estimador puede fácilmente obtenerse de  $\phi_s(B)\hat{s}_t = \theta_s(B)\alpha_s(F)a_t$ . La función de autocorrelación y la varianza empíricas de la transformación estacionaria del estimador se deriva a partir de la aplicación del filtro WK a la serie observada,  $\hat{s}_t = k_s \frac{\psi_s(B)\psi_s(F)}{\psi(B)\psi(F)} x_t$ .

El modelo teórico para el estimador óptimo ofrece una herramienta natural para un diagnóstico adicional. Esto se ilustra con el siguiente ejemplo para el componente irregular ruido blanco ( $0, \sigma_u^2$ ): el estimador MMSE de  $u_t$  es  $\theta(F)\hat{u}_t = k_u\phi(F)a_t = \phi(F)a_t'$ ; en la práctica,  $\hat{u}_t$  se obtiene de manera residual, una vez que los demás componentes han sido estimados. No obstante, si en una aplicación el residual se usa para llevar a cabo un diagnóstico, su ACF y varianza no deberían ser comparados con los de  $u_t$ , sino con los del estimador teórico, dado por  $\theta(F)\hat{u}_t = k_u\phi(F)a_t = \phi(F)a_t'$ . Diferencias significativas entre

las auto-correlaciones de  $\hat{\alpha}_t$  teórico y el empírico (que se obtiene por diferencia) estaría indicando una mala especificación. La estructura de la diferencias provee además un indicio del tipo de error de especificación. Más detalles pueden encontrarse en Maravall (1987)

#### 2.2.5.4. Covarianza entre los Estimadores

Debido a que la suma de los componentes es igual a la de sus estimadores, la subestimación del componente implica que mientras las covarianzas cruzadas entre los diferentes componentes son cero, este no será el caso para los estimadores.

La CCGF (función generadora de covarianzas cruzadas) entre  $\hat{s}_t$  y  $\hat{n}_t$  es

$$\Gamma(B, F) = \sum_{j=-\infty}^{\infty} \gamma_j B^j, \text{ donde } \gamma_j = E(\hat{s}_t \hat{n}_t).$$

Teniendo en cuenta que  $\hat{s}_t = \frac{\sigma_s^2}{\sigma_a^2} \frac{\psi_s(B)\psi_s(F)}{\psi(B)\psi(F)} x_t$  ;  $\hat{n}_t = \frac{\sigma_n^2}{\sigma_a^2} \frac{\psi_n(B)\psi_n(F)}{\psi(B)\psi(F)} x_t$  y

$$x_t = \psi(B)a_t = \frac{\theta(B)}{\phi(B)} a_t, \text{ se tiene: } \Gamma(B, F) = \frac{\theta_s(B)\theta_n(B)\theta_s(F)\theta_n(F)}{\theta(B)\theta(F)} \frac{\sigma_s^2 \sigma_n^2}{\sigma_a^2} \text{ (expresión}$$

simétrica y convergente)

También puede verse a la CCGF( $\hat{s}_t, \hat{n}_t$ ) como el ACGF del proceso  $\theta(B)y_t = \theta_s(B)\theta_n(B)b_t$ ,

$$\text{tal que } \sigma_b^2 = \sigma_s^2 \sigma_n^2 / \sigma_a^2$$

Incluso cuando los componentes son no estacionarios, las covarianza cruzadas entre los estimadores serán finitas.

La discrepancia entre los componentes teóricamente no correlacionados y la existencia de covarianzas cruzadas distintas de cero entre los estimadores MMSE, en el método basado en modelos, ha sido causa de preocupaciones. Esta preocupación, no obstante, sería algo limitada. Para una realización completa de la serie, el hecho que las covarianzas cruzadas es finita, implica que (cuando al menos uno de los componentes es no estacionario, lo cual es usual en la práctica) la correlación cruzada entre los estimadores también es cero. Así, los estimadores MMSE de los componente no correlacionados estarán también no correlacionados.

La estimación de la p-innovación de la señal (en nuestro ejemplo  $\hat{a}_{st}$  puede ser calculado por

$$\text{la fórmula } \hat{a}_{st} = \sigma_s^2 \frac{\theta_s(F)\phi_n(F)}{\theta(F)} a_t$$

### 2.2.6. Estimador Preliminar y Pronóstico

Debido a que  $\nu(B, F)$  es un filtro de dos lados, el estimador para la señal estará sujeto al problema de estimación preliminar y revisiones. La estimación preliminar típicamente afecta a unos pocos años, ubicados al principio y al final de la serie.

El estimador óptimo para la señal  $s_t$  para una realización finita  $X_T$  es:

$$s_{t|T} = E(s_t | X_T) = E(E(s_t | X)X_T) = E(\hat{s}_t | X_T) = \nu(B, F)X_{t|T}^e$$

$X_T$	Realización finita de $x_t$
-------	-----------------------------

$X$	Realización completa de $x_t$
$T$	Nº de observaciones disponibles
$\nu(B, F)$	Filtro WK
$x_{t T}^e = E(x_t   X_T) = \begin{cases} x_t, \forall t \leq T \\ \text{Forecast } x_t \end{cases}$	Es el pronóstico de $x_t$ en el momento $T$ , es igual a la esperanza de $x_t$ condicionado al vector de observaciones $X_T$ . Cuando $t \leq T$ es igual a la observación disponible.
$x_{t T}^e$	Denota la serie extendida con forecasts y backcasts
Cuando $t \rightarrow T$	El estimador es preliminar
Cuando $t > T$	Es el pronóstico $t - T$ periodos hacia delante de la señal.

Si el modelo para la serie observada es  $\phi(B)x_t = \theta(B)a_t$ , a menos que  $q = 0$ , el filtro  $\nu(B, F)$  contendrá un número infinito de ponderaciones. Dado que el filtro es convergente, puede ser truncado y aproximado por un filtro finito. No obstante, en la práctica no hay necesidad de truncar el filtro, ya que el filtro exacto puede aplicarse de manera fácil y eficiente usando el algoritmo de Burman-Wilson (Burman, 1980). Este algoritmo permite aplicar el filtro con unos pocos forecasts y backcasts. A la serie que incorpora los forecasts y backcasts se le denomina *serie extendida*.

### 2.2.7. Estimador Final

Asúmase que el filtro WK  $\nu(B, F) = k_s \frac{\psi_s(B)\psi_s(F)}{\psi(B)\psi(F)}$  puede ser aproximado por un filtro

simétrico y centrado de  $(2L+1)$  términos:  $\nu(B, F) = \nu_0 + \sum_{j=1}^L \nu_j(B^j + F^j)$ . En la práctica

para el ajuste estacional, típicamente  $L$  se expande de 3 a 5 años. Por lo tanto, cuando  $T > 2L + 1$  pueden obtenerse los estimadores finales o históricos para las observaciones centrales de la serie.

### 2.2.8. Revisiones en el Estimador

Comenzando con el estimador concurrente de la señal,  $\hat{s}_{t|t}$ , cuando nuevas observaciones están disponibles el estimador de  $s_t$  es revisado, obteniéndose la secuencia  $(\hat{s}_{t|t}, \hat{s}_{t|t+1}, \dots, \hat{s}_{t|t+k}, \dots)$ . Cuando  $k \rightarrow \infty$ ,  $\hat{s}_{t|t+k}$  converge a  $\hat{s}_t$ , el estimador final.

Teniendo en cuenta que  $\phi_s(B)\hat{s}_t = \theta_s(B)\alpha_s(F)a_t$  (Ver sección 2.2.5.3.), expresión que se puede convertir a  $\hat{s}_t = \xi_s(B, F)a_t$  se tiene:  $\hat{s}_t = \xi_s(B)^- a_t + \xi_s(B)^+ a_{t+1}$ .

Cuando  $x_t$  es la última observación, el primer término de esta última igualdad contiene el efecto de las condiciones iniciales y de las innovaciones presentes y pasadas en la serie. El segundo término refleja el efecto de las innovaciones futuras. Tomándole la esperanza

condicional en el momento  $t$  se obtiene  $\hat{s}_{t|t} = \xi_s(B)^{-1} a_t$ . Luego el error de la revisión del estimador concurrente está dado por

$$\hat{s}_t - \hat{s}_{t|t} = r_t = \xi_s(F)^+ a_{t+1},$$

un proceso estacionario de media cero.

El estimador concurrente constituye una primera impresión, usualmente insuficiente para formarse un juicio correcto.

$$\hat{s}_t = \dots + v_1 x_{t-1} + v_0 x_t + v_1 x_{t+1} + v_2 x_{t+2} + \dots$$

$$\hat{s}_{t|t} = \dots + v_1 x_{t-1} + v_0 x_t + v_1 \hat{x}_{t+1|t} + v_2 \hat{x}_{t+2|t} + \dots$$

$$\hat{s}_t - \hat{s}_{t|t} = r_t = v_1(x_{t+1} - \hat{x}_{t+1|t}) + v_2(x_{t+2} - \hat{x}_{t+2|t}) + \dots = \sum_{j=1}^{\infty} v_j e_t(j), \text{ donde}$$

$e_t(j)$  es el error de pronóstico  $j$  periodos hacia delante de la serie. Es claro que el error de la revisión depende de los errores de pronóstico y de las ponderaciones del filtro WK. Esto justifica el interés en errores de pronóstico pequeños. Las ponderaciones  $v_j$  dependen de la estructura estocástica de la serie.

En el método MBSE, las revisiones son óptimas (en términos de tamaño y duración) debido a que tanto los pronósticos MMSE como las estimaciones MMSE de los componentes son óptimos. Debido a que los pronósticos MMSE implican errores de pronóstico óptimos, las revisiones tenderán a ser pequeñas.

### 2.2.9. Inferencia

El pronóstico  $k$  periodos hacia delante, para la señal  $s_t$  está dado por

$$\hat{s}_{T+k|T} = \dots + \mathbf{U}_k \mathbf{x}_T + \mathbf{U}_{k-1} \hat{\mathbf{x}}_{T+1|T} + \dots + \mathbf{U}_0 \hat{\mathbf{x}}_{T+k|T} + \dots + \mathbf{U}_L \hat{\mathbf{x}}_{T+k+L|T}$$

Luego, las propiedades del error de pronóstico  $s_{T+k} - \hat{s}_{T+k|T}$  puede obtenerse de modo análogo al del error del estimador preliminar. Una característica conveniente del método MBSE es que provee pronósticos óptimos de los componentes, así como sus respectivos MSE (error cuadrático medio).

#### 2.2.9.1. Error de Estimación

La medida de la precisión del estimador de un componente es de gran interés. Por ejemplo, cuando se tienen objetivos para algunas variables clave en política monetaria (vg. Algún agregado monetario e IPC) el monitoreo a lo largo del año y la reacción de la política se basa en una serie ajustada por estacionalidad.

Debido a la naturaleza estocástica de  $s_t$ , su estimador final  $\hat{s}_t$  contiene un error,  $e_t$ . Aunque

$e_t$  no es observable puede verse como el resultado de un modelo ARMA estacionario

$$\theta(B)y_t = \theta_s(B)\theta_n(B)b_t, \text{ con } \sigma_b^2 = \sigma_s^2\sigma_n^2 / \sigma_a^2 \text{ (Ver sección 2.2.5.4.)}$$

Debido a que  $ACGF(e_t) = CCGF(s_t, n_t)$ , la varianza del error del estimador final es igual a la covarianza

de rezago cero entre los estimadores de  $s_t$  y  $n_t$ .

Para el caso del estimador concurrente se tiene el error total de estimación

$$\varepsilon_T = S_T - \hat{S}_{T|T} = (S_T - \hat{S}_T) + (\hat{S}_T - \hat{S}_{T|T}) = e_T + r_T$$

$\varepsilon_T = S_T - \hat{S}_{T T}$	Error total de estimación
$e_T = S_T - \hat{S}_T$	Error de la estimación final
$r_T = \hat{S}_T - \hat{S}_{T T}$	Error de la revisión

### 2.2.9.2. La Mejora de Un Ajuste Concurrente

Un punto de especial interés para las agencias productoras de estadísticas es la frecuencia con la cual el ajuste estacional debe de hacerse. Normalmente, este ajuste se realiza una o dos veces al año ya que llevarlo a cabo de manera concurrente es costoso. Por ello los factores estacionales pronosticados son utilizados hasta que el siguiente ajuste estacional es hecho.

Ciertamente, el uso de factores pronosticados incrementa el error cuadrático medio (MSE) de la serie ajustada por estacionalidad. El método AMB provee una forma simple a la cuestión de cuanto se gana si el ajuste concurrente es realizado en lugar de un ajuste de una vez al año.

Teniendo en cuenta que el error de la revisión del estimador concurrente está dado por

$$\hat{s}_t = \xi_s(B)^- a_t + \xi_s(B)^+ a_{t+1} \quad (\text{Ver Sección 2.2.8.}), \quad \text{se tiene que}$$

$$MSE(\hat{s}_{t+k|t} - s_{t|t}) = \sigma_a^2 \sum_{j=0}^{k-1} \xi_{-j}^2, \quad \text{donde } \xi_0, \dots, \xi_{-k+1} \text{ son los primeros } k \text{ coeficientes del}$$

polinomio  $\xi_s(B)^+$ . Consecuentemente, la pérdida de precisión debido al uso de factores pronosticados puede ser medido.

### 2.3. Procedimiento Metodológico

Para la evaluación del método de ajuste estacional TRAMO-SEATS se siguió una metodología aplicable, en principio, a cualquier procedimiento de desestacionalización. El procedimiento metodológico es como sigue: (i) se realizó una prueba estadística para verificar si la serie desestacionalizada efectivamente está libre de autocorrelación en los rezagos estacionales y (ii) si la tendencia, posiblemente estocástica, no ha sido removida por el ajuste estacional.<sup>3</sup>

Franses (1997) propone llevar a cabo las siguientes pruebas:

$$\text{Test 1: ¿Se removió la estacionalidad? } \Delta x_t^{SA} = \mu + \sum_{i=1}^p \phi_i \Delta x_{t-i}^{SA} + a_t, p = 4,8,12$$

$$\text{Test 2: ¿Se mantuvo la tendencia? } \varepsilon_t = x_t - x_t^{SA} \sim I(0)$$

Donde,  $x_t$  es la serie original y  $x_t^{SA}$  la serie ajustada por estacionalidad o desestacionalizada.

La primera prueba se sustenta en la idea de que si el componente estacional ha sido apropiadamente removido no debiese haber correlaciones estacionales en la serie ajustada por estacionalidad. Para evaluar la significancia estadística de los coeficientes de la ecuación

autorregresiva  $\Delta x_t^{SA} = \mu + \sum_{i=1}^p \phi_i \Delta x_{t-i}^{SA} + a_t$  se usa la prueba  $t$ . Se considera 2 rezagos

---

<sup>3</sup> Soto (2000) utiliza también este procedimiento para hacer una evaluación de los resultados de aplicar el XI I-ARIMA a 15 variables macroeconómicas chilenas

estacionales en la mencionada ecuación. Si un coeficiente es estadísticamente igual a cero (hipótesis nula de la prueba  $t$ ), entonces el estadístico  $t = \phi_i / SE(\phi_i)$  debe encontrarse en el rango  $[-2, 2]$ . Si este estadístico se encuentra fuera de dicho rango, el coeficiente es estadísticamente significativo (se acepta la hipótesis alternativa).

El presente estudio, adicionalmente, usa el estadístico Box-Pierce de dos rezagos estacionales para evaluar la presencia o no de autocorrelación estacional en la serie desestacionalizada. El estadístico de Box-Pierce es  $Q_s = T \sum_{k=4:8} \rho_k^2$ . Bajo la hipótesis nula (no autocorrelación estacional de dos rezagos) tiene una distribución de probabilidad aproximada  $\chi^2$  con 2 grados de libertad, cuyo valor crítico es 5,99. En Pierce (1978) se encuentra la descripción de la prueba estadística  $Q_s$ .

La segunda prueba investiga si la tendencia de la serie original y la serie desestacionalizada se separan en el tiempo. Si ello ocurre significa que el residuo de la ecuación  $x_t = c + x_t^{SA} + \varepsilon_t$  no es estacionario. Si el proceso de remoción de estacionalidad es “neutro con respecto a la tendencia” la serie original y la serie desestacionalizada deberían de cointegrar. En la aplicación de esta prueba se trató dos versiones: en la primera se excluyó la constante del vector de cointegración y en la segunda se dejó la constante como un coeficiente libre.

Para determinar el orden de integración de los residuos de la (posible) ecuación cointegradora se utilizó los bien conocidos test de Phillips-Perron (PP) y Dickey-Fuller Aumentado (ADF).

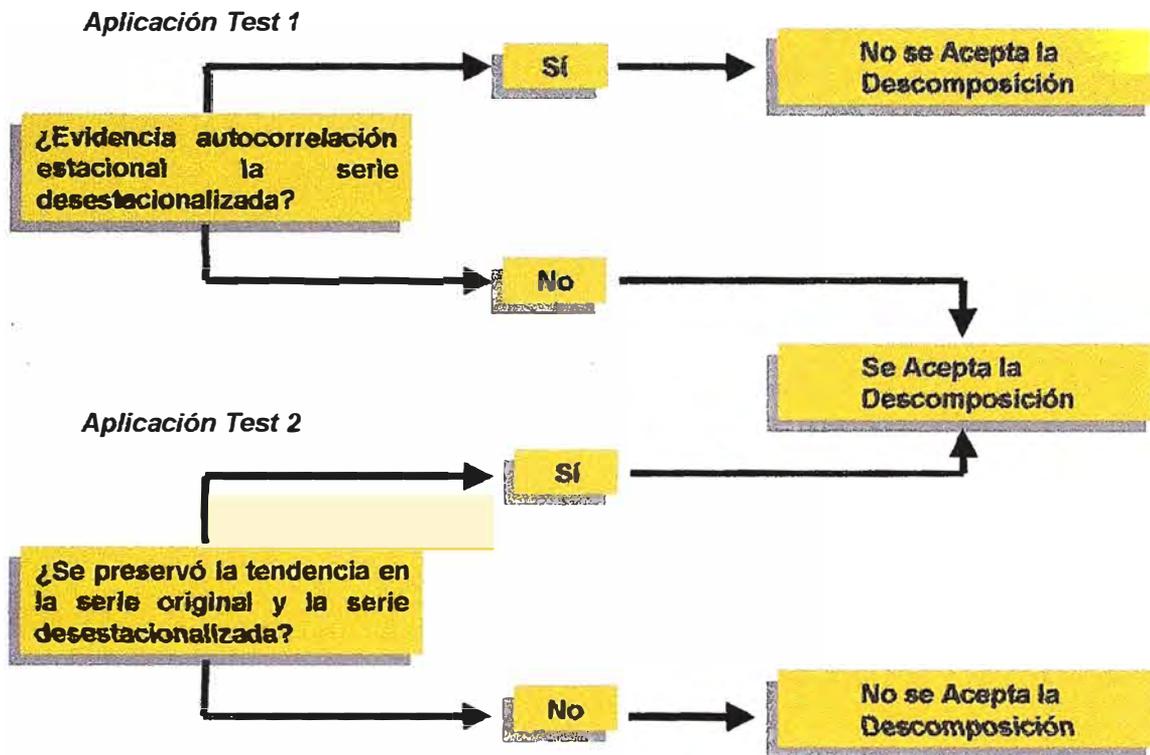
Una referencia para los lectores interesados en las pruebas de raíces unitarias es Reinsel (1997).

Es necesario tener en cuenta que cuando una serie de tiempo presenta ciertos tipos de correlación serial, entre ellas la estacional, las pruebas “clásicas” PP y ADF exhiben poco poder. Estos resultados fueron encontrados por Schwert (1989) mediante simulación de Monte Carlo.

En el estado actual de las artes, no hay un acuerdo general de cómo proceder a probar la existencia de raíces unitarias en series de tiempo que muestran estacionalidad, Gómez y Maravall (2000a, sección 1.2.1).

Debido a que el presente estudio trata con series trimestrales, es de esperarse que, en el caso general, muestren correlación estacional. Consecuentemente, los tests PP y ADF podrían tener poco poder. No obstante, parece ser que el primero de ellos es más robusto, Soto (2000, p. 15).

Evaluación del Método de Ajuste Estacional TRAMO-SEATS: Procedimiento Metodológico



## **Capítulo 3**

# **Resultados del Ajuste Estacional TRAMO-SEATS**

### **3. Resultados del Ajuste Estacional TRAMO-SEATS**

#### **3.1. Variables del Sector Real**

En el sector real, las series consideradas fueron el PBI por actividades económicas y el PBI global, expresados a precios de 1994. A fin de llevar a cabo un análisis de los resultados del ajuste estacional se confeccionaron cuadros resumen de los archivos de salida de TRAMO y SEATS. El archivo de salida de TRAMO muestra los resultados muy detalladamente del proceso de identificación, estimación y validación del modelo ARIMA, así como la identificación y corrección por outliers y efectos calendario. Para cada modelo se corrió el programa en la opción automática (ITER=0, RSA=6). Los resultados, en general, arrojan modelos muy parsimoniosos y satisfactorios en términos de ajuste y del comportamiento de la innovaciones del modelo para la serie observada.

Para el caso de la variable AGRP las pruebas estadísticas (Cuadro N° 3.1.4) indican que no hay evidencia de que las innovaciones no se comportan como ruido blanco. Para la descripción de los residuos, TRAMO utiliza el test de normalidad de Bowman-Shenton ( $H_0$  = Normalidad) y los estadísticos Skewness ( $H_0$  = Asimetría cero) y Kurtosis ( $H_0$  = exceso de Kurtosis cero). Se nota claramente, de la primera columna del Cuadro N° 3.1.4, que el estadístico de normalidad (0,2813) es menor que el valor crítico (5,99),

aceptándose por tanto la hipótesis nula. Igualmente, el Skewness es estadísticamente igual a cero y no existe evidencia de exceso de Kurtosis.

Para el análisis de autocorrelación de los residuos el programa TRAMO presenta los estadísticos  $Q$  de Ljung-Box ( $H_0$  = Autocorrelación hasta el orden 16 iguales a cero) y  $Q_s$  de Box-Pierce ( $H_0$  = Autocorrelación hasta dos rezagos estacionales iguales a cero). La independencia de los residuos puede analizarse haciendo uso de los cuadrados de los residuos con los mismos estadísticos. Se puede ver fácilmente, Cuadro N° 3.1.4, que los residuos del modelo ARIMA de la serie AGRP pasan la prueba de no autocorrelación e independencia estadística.

Siguiendo este mismo procedimiento para el caso de las demás series, se llega a la conclusión de que las innovaciones del modelo ARIMA, en cada caso, se comportan como un ruido blanco, a excepción de PES en donde hay evidencia de que la distribución de probabilidad de los errores no es simétrica. Excluyendo el caso de la serie PES, los modelos identificados y estimados, para la serie observada, por TRAMO son aceptables (desde el punto de vista estadístico).

Un porcentaje considerado usualmente como aceptable para el número de outliers, no debe ser mayor a 5% (del número de observaciones). El Cuadro N° 3.1.2 muestra que todas las series

tienen un número de outliers inferior al 5%, excepto para la serie PES. Más adelante se llegará a la conclusión de que para esta serie se requerirá la identificación de modelos alternativos, al proporcionado por el modo automático de TRAMO, cuyos residuos se comporten como un ruido blanco.

El programa SEATS descompone la serie a partir del modelo ARIMA estimado por TRAMO para la serie observada. El archivo de salida de este programa muestra muy detalladamente los resultados; un resumen de los mismos se encuentra en los cuadros N° 3.1.5, 3.1.6 y 3.1.7.

Teniendo en cuenta que en el corto plazo el ruido contenido en una serie oscurece la visión de su evolución subyacente, se debe de prestar especial interés en el análisis del componente irregular. Asimismo, se debe de tener en cuenta que una diferencia significativa de la autocorrelación entre el estimador empírico y el estimador teórico del componente irregular indica una incorrecta especificación del modelo ARIMA para la serie observada (Maravall, 1987, p. 117). Del Cuadro N° 3.1.5 se puede ver que la autocorrelación del estimado empírico del componente irregular de las series AGRP, MIN, CONSTR, COMERC, OTROS y PBI94 PERU, se encuentra próximo a la de su respectivo estimador teórico. En el caso de la series PES y MANUF, éstos muestran alguna divergencia, lo cual da indicios de una mala especificación del modelo.

El Cuadro N° 3.1.6 presenta la correlación cruzada de los componentes (transformados en estacionario), los cuales en general son aceptables. Para el caso de las series PES y MANUF

será necesario realizar una mayor investigación a fin identificar modelos ARIMA alternativos para la serie observada.

La varianza de las innovaciones de los componentes de una serie mide el grado de aleatoriedad del componente. Como se puede observar del Cuadro N° 3.1.7, las variables AGRP, MANUF, CONSTR, COMERC, OTROS y PBI94 PERU, muestran un componente estacional estable; MIN muestra un componente estacional cercano al determinístico, en tanto que PES tendría una estacionalidad no muy estable.

Se puede observar del Cuadro N° 3.1.7 que a mayor varianza de la innovación del componente, la varianza del error total de estimación también será mayor, y viceversa. Intuitivamente, esto se debe a que cuanto más volátil es un componente, menor será la precisión de su estimación. La varianza del error total de estimación de las series desestacionalizadas MANUF, CONSTR, COMERC, OTROS y PBI94 PERU, es de tamaño moderado, (ver Fila 11 del Cuadro N° 3.1.7) lo cual indica una precisión en su estimación. Debido a la naturaleza cercana a la determinística del componente estacional de la serie MIN, la varianza del error total de estimación de la serie ajustada por estacionalidad es también muy pequeña. Por su parte, las series desestacionalizadas de PES y AGRP tienen varianzas de errores de estimación relativamente grandes. La variable PES, debido a que su componente estacional es menos estable, su serie ajustada por estacionalidad tiene una varianza del error de estimación relativamente grande.

Puesto que la varianza del error de revisión es relativamente pequeña de la serie ajustada por estacionalidad para las variables MANUF, CONSTR, COMERC, OTROS y PBI94 PERU, su convergencia será relativamente lenta, requiriendo en promedio 5 años para converger a su estimador final. Como consecuencia, en cada caso, muestra una mejora no muy significativa de realizar un ajuste concurrente en lugar de un ajuste de una sola vez al año.

El caso de las series AGRP y PES es distinto, la varianza del error total y del error de la revisión de la estimación de la serie desestacionalizada es relativamente grande, lo cual conduce a una rápida convergencia, requiriendo en promedio de 2 años para converger a su estimador final o histórico. Debido a su rápida convergencia, la mejora de pasar de un ajuste de una sola vez al año a un ajuste concurrente es significativa.

Cuadro N° 3.1.1: Parámetros de TRAMO-SEATS, Sector Real

Series		Parameters
AGRP	PBI Agropecuario, S/. MM de 1994	RSA=6, IDUR=4
PES	PBI Pesca, S/. MM de 1994	RSA=6, IDUR=4
MIN	PBI Minería, S/. MM de 1994	RSA=6, IDUR=4
MANUF	PBI Manufactura, S/. MM de 1994	RSA=6, IDUR=4
CONSTR	PBI Construcción, S/. MM de 1994	RSA=6, IDUR=4
COMERC	PBI Comercio, S/. MM de 1994	RSA=6, IDUR=4
OTROS	PBI Otros, S/. MM de 1994	RSA=6, IDUR=4
PBI94 PERU	PBI global del Perú, S/. MM de 1994	RSA=6, IDUR=4

Cuadro N° 3.1.2: Parámetros de TRAMO-SEATS, Sector Real

Series	N° obs.	Transformation	Model

AGRP	45	Log	$y_t = 2 \text{ outliers} + x_t$
			$(1 - B) (1 - B^4)x_t = (1 - 0,22479B) (1 - 0,18226B^4)a_t$ (-1,31) (-1,05)
			(0,1,1)(0,1,1)
PES	45	Level	$y_t = 4 \text{ outliers} + EE + x_t$
			$(1 - 0,1593B) (1 - B) (1 - B^4)x_t = a_t$ (-1,02)
			(1,1,0)(0,1,0)
MIN	45	Log	$y_t = EE + x_t$
			$(1 - B) (1 - B^4)x_t = (1 - 0,08311B) (1 - 0,95434B^4)a_t$ (-0,53) (-20,21)
			(0,1,1)(0,1,1)
MANUF	45	Level	$y_t = 1 \text{ outliers} + x_t$
			$(1 - B) (1 - B^4)x_t = (1 - 0,58686B^4)a_t$ (-4,58)
			(0,1,0)(0,1,1)
CONSTR	45	Level	$y_t = 2 \text{ outliers} + x_t$
			$(1 - B) (1 - B^4)x_t = (1 - 0,61281B^4)a_t$ (-4,9)
			(0,1,0)(0,1,1)
COMERC	45	Level	$y_t = x_t$
			$(1 - B) (1 - B^4)x_t = (1 - 0,50613B^4)a_t$ (-3,7)
			(0,1,0)(0,1,1)
OTROS	45	Level	$y_t = 1 \text{ outliers} + x_t$
			$(1 - B) (1 - B^4)x_t = (1 - 0,41922B^4)a_t$ (-2,9)
			(0,1,0)(0,1,1)
PBI94 PERU	45	Level	$y_t = 1 \text{ outlier} + x_t$

			$(1 - B) (1 - B^4)x_t = (1 - 0,54218B^4)a_t$
			(-4.08)
			(0,1,0)(0,1,1)

Cuadro N° 3.1.3: Outliers y Efectos Calendario, Sector Real

Mnemonic	1990	1991	1992	1993	1994	1995	1996	1997	1998	1999	2000	2001	%
AGRP		2 TC (4,7)							4 LS (3,5)				4,4
PES			4 AO (6,5)				4 LS (5,1)		3 LS (6,5)	4 TC (5,2)			8,9
MIN													0,0
MANUF	3 TC (-4,7)												2,2
CONSTR	3 LS (-4,9)								3 AO (3,6)				4,4
COMERC													0,0
OTROS	3 TC (-4,3)												2,2
PBI94 PERU	3 TC (-4,1)												2,2

Cuadro N° 3.1.4: Resumen Estadístico TRAMO, Sector Real

Model	AGRP	PES	MIN	MANUF	CONSTR
1. S.E of Residuals	0.04648566	19.60883	0.02639643	186.6227	86.94663
2. BIC	-5.8737	6.3428	-7.0703	10.5913	9.1293
3.. Normality	0.2813	5.313	0.338	2.931	1.797
4. Skewness	-0.1162 SE=0.3974	-0.8699 SE=0.4140	0.1683 SE=0.3922	0.6429 SE=0.3922	-0.3110 SE=0.3974
5. Kurtosis	3.3517 SE=0.7947	3.7850 SE=0.8281	2.6923 SE=0.7845	2.6123 SE=0.7845	2.1352 SE=0.7947
6. Ljung-Box Q Stat	15.90 16 Autoc. $\chi^2(14)$	13.67 16 Autoc. $\chi^2(15)$	13.66 16 Autoc. $\chi^2(14)$	24.38 16 Autoc. $\chi^2(15)$	16.48 16 Autoc. $\chi^2(15)$
7. Pierce $Q_s$ - Stat	0.05	1.09	0.99	2.10	0.16
8. Q -stat for squared res.	16.90 $\chi^2(14)$	10.12 $\chi^2(15)$	8.60 $\chi^2(14)$	10.40 $\chi^2(15)$	8.34 $\chi^2(15)$
9. Run of residuals	-0.3289	1.0303	0.9743	0.3248	-1.3157
Diagnostics	OK	OK	OK	OK	OK

Model	COMERC	OTROS	PBI94 PERU
1. S.E of Residuals	190.9027	359.0597	764.6872
2. BIC	10.5704	11.9001	13.4121
3.. Normality	0.7112	1.726	1.125
4. Skewness	0.3143 SE=0.3873	-0.3717 SE=0.3922	0.0714 SE=0.3922
5. Kurtosis	3.1775 SE=0.7746	2.2862 SE=0.7845	2.1804 SE=0.7845
6. Ljung-Box Q Stat	11.02 16 Autoc.	18.12 16 Autoc.	8.04 16 Autoc.

	$\chi^2(15)$	$\chi^2(15)$	$\chi^2(15)$
7. Pierce $Q_s$ - Stat	1.65	2.57	0.05
8. $Q$ -stat for squared res.	11.63 $\chi^2(15)$	21.36 $\chi^2(15)$	20.11 $\chi^2(15)$
9. Run of residuals	-1.2814	0.0000	-0.6495
Diagnostics	OK	OK	OK

Criterio:

1. Tan pequeño como sea posible
2. Tan pequeño como sea posible
3.  $< 5.99$  (95%  $\chi^2(2)$ )
4.  $|\cdot| < 1.96(\text{SE})$
5.  $|\cdot| < 3 + 1.96(\text{SE})$
6.  $|\cdot| < 23.69$  (95%  $\chi^2(14)$ );  $|\cdot| < 25.00$  (95%  $\chi^2(15)$ )
7.  $|\cdot| < 5.99$  (95%  $\chi^2(2)$ )
8.  $|\cdot| < 23.69$  (95%  $\chi^2(14)$ );  $|\cdot| < 25.00$  (95%  $\chi^2(15)$ )
9.  $|\cdot| < 2$  (95% t-value)

$|\cdot|$  denota valor absoluto

Cuadro N° 3.1.5: ACF del Componente Irregular, Sector Real

	Component	Theoretical Estimator	Estimate	Component	Theoretical Estimator	Estimate

AGRP	0.000	-0.378	-0.374	0.000	-0.411	-0.443
PES	0.000	-0.567	-0.418	0.000	-0.500	-0.428
MIN	0.000	-0.458	-0.512	0.000	-0.023	-0.169
MANUF	0.000	-0.500	-0.622	0.000	-0.207	-0.430
CONSTR	0.000	-0.500	-0.582	0.000	-0.194	-0.080
COMER	0.000	-0.500	-0.362	0.000	-0.247	-0.419
OTROS	0.000	-0.500	-0.572	0.000	-0.290	-0.219
PBI94 PERU	0.000	-0.500	-0.493	0.000	-0.229	-0.410

Cuadro N° 3.1.6: CCF entre los Estimadores (Transformados en Estacionario) , Sector Real

	Trend-Seasonal	Seasonal-Irregular	Trend-Irregular	Transitory-Irregular
AGRP				
Theor. Estimator	-0.280	0.202	-0.150	
Estimate	-0.139	0.328	-0.066	
PES				
Theor. Estimator	-0.435	0.134	-0.043	0.611
Estimate	-0.572	0.102	-0.147	0.660
MIN				
Theor. Estimator	-0.075	0.037	-0.031	
Estimate	0.060	0.219	0.041	
MANUF				
Theor. Estimator	-0.260	0.104	0.006	
Estimate	-0.346	0.087	0.022	
CONSTR				
Theor. Estimator	-0.251	0.101	-0.005	
Estimate	-0.294	0.126	-0.137	
COMERC				
Theor. Estimator	-0.287	0.113	-0.010	
Estimate	-0.331	0.221	-0.050	
OTROS				
Theor. Estimator	-0.313	0.120	-0.015	
Estimate	-0.394	0.150	-0.067	

PBI94 PERU				
Theor. Estimator	-0.275	0.109	-0.008	
Estimate	-0.271	0.178	-0.028	

Cuadro N° 3.1.7: Resumen Estadístico: SEATS, Sector Real

Model	AGRP	PES	MIN	MANUF	CONSTR
10. Component innovation variance (in units of $V_a$ )					
• Trend-cycle	0.05828	0.06653	0.20298	0.17214	0.17708
• Seasonal	0.06341	0.10847	0.00017	0.01676	0.01472
• Irregular	0.11855	0.05228	0.28005	0.15836	0.16343
• SA series	0.41564	0.31724	0.96592	0.70293	0.72083
• Transitory		0.00002			
11. Total Estimation error variance (in units of $V_a$ )					
• Trend	0.160	0.176	0.206	0.184	0.184
• SA series	0.135	0.157	0.014	0.097	0.093
12. Variance of revision in concurrent estimator (Units $V_a$ )					
• Trend	0.1083	0.1252	0.07629	0.09411	0.09253
• SA series	0.0788	0.1011	0.00723	0.05221	0.04960
13. Significance of seasonality (95%): # significant quarters per year					
• Historical estimation	4	3	4	1	3
• Preliminary estimation	4	4	4	2	3
• Next year forecast	4	3	3	0	2
14. Convergence of concurrent estimator in 2 years (% decrease in revision SE)					
• Trend	98.90	100.0	89.70	88.81	87.97
• SA series	95.48	100.0	8.902	64.37	61.37
15. Gain from concurrent adjustment (% decrease in RMSE)	31.62	25.33	1.84	13.93	13.14
16. Diagnostics: comparison of ACF and CCF	OK	NO	OK	NO	OK

Model	COMERC	OTROS	PBI94 PERU
10. Component innovation variance (in units of $V_a$ )			
• Trend-cycle	0.15669	0.13986	0.16360
• Seasonal	0.02395	0.03312	0.02058
• Irregular	0.14317	0.12781	0.14984
• SA series	0.64789	0.58974	0.67235
• Transitory			
11. Total Estimation error variance (in units of $V_a$ )			
• Trend	0.182	0.180	0.183
• SA series	0.109	0.120	0.104
12. Variance of revision in concurrent estimator (Units $V_a$ )			
• Trend	0.09871	0.10310	0.09671
• SA series	0.05980	0.06715	0.05650
13. Significance of seasonality (95%): # significant quarters per year			
• Historical estimation	4	2	3
• Preliminary estimation	4	0	3
• Next year forecast	3	0	3
14. Convergence of concurrent estimator in 2 years (% decrease in revision SE)			
• Trend	91.43	94.04	90.27
• SA series	72.89	80.68	69.24
15. Gain from concurrent adjustment (% decrease in RMSE)	16.34	18.83	15.28
16. Diagnostics: comparison of ACF and CCF	OK	OK	OK

Criterio:

10. Para los componentes tendencia y estacional, tan pequeño como sea posible; para el componente irregular, tan grande como sea posible.

11. Tan pequeño como sea posible (Tendencia y SA Serie)

12. Tan pequeño como sea posible

13. Tantos como sean posibles

#### 14. Tan grande como sea posible

Comentarios a las tablas resumen de TRAMO y SEATS:

Filas 2-9

BIC denota el Criterio de Información Bayesiano (Bayesian information criterion). El estadístico  $Q_s$  de Pierce prueba la carencia de autocorrelación estacional en los residuos. El estadístico residual-run prueba la aleatoriedad en las señales de los residuos.

Filas 10-11

Las varianzas son expresadas en términos de la varianza de los residuos  $a_t$

Fila 10

Las innovaciones en los componentes son la causa de su comportamiento aleatorio. El que tenga una varianza más grande, será el componente más volátil.

Fila 11

Representa el *error total de estimación*, el cual es igual a la suma del *error de la estimación final* y el *error de la revisión*.

### Fila 13

La significancia de la estacionalidad es determinada para el estimador final y para el estimador preliminar y para los pronósticos un año hacia delante del componente estacional. Un componente estacional es significativo si su estimado (en valor absoluto) tiene un valor mayor a 2 veces su desviación estándar.

### Fila 14

Muestra el porcentaje de la varianza del error de la revisión que ha desaparecido después de 4 trimestres que la data esté disponible.

### Fila 15

*Representa la disminución esperada en la raíz del error cuadrático medio (RMSE) asociado con el movimiento de una práctica de ajuste estacional de una vez al año a uno concurrente.*

### Fila 16

Los diagnósticos SEATS están asociados con la comparación de los ACF y CCF de la transformación estacionaria de los componentes, sus estimadores teóricos y sus estimados empíricos. La varianza del componente teórico debería ser más grande y estar cerca de la del

estimador teórico y los estimados empíricos; los estimadores teóricos y empíricos deberían de estar cercanos entre sí.

### **3.2. Variables del Sector Monetario**

Las series analizadas en el sector monetario son la liquidez en moneda nacional, nominal y real, del sistema bancario y el saldo de la emisión primaria, nominal y real.

A partir de los estadísticos para el análisis de los residuos de los modelos ARIMA estimados por TRAMO se obtienen los siguientes resultados (Ver Cuadro N° 3.2.4): i) los residuos del modelo para la liquidez nominal (LIQ\_MN\_N) se comportan como un ruido blanco; la prueba de normalidad es aceptado (el estadístico Bowman-Shenton igual a 1.011 es menor que el valor crítico 5,99), y no hay evidencia ni de asimetría (el estadístico Skewness se encuentra en el intervalo  $[-1,96; 1,96]$ ) ni de exceso de kurtosis (el estadístico de Kurtosis se encuentra en el intervalo  $[3 - 1,96 \times 0,7385; 3 + 1,96 \times 0,7385]$ ). De igual modo, los estadísticos  $Q = 9,02$  y  $Q_s = 1,88$  son menores a sus respectivos valores críticos 25 y 5,99. En el caso de la misma serie expresada en términos reales (LIQ\_MN\_R) se llega a los mismo conclusiones. ii) los residuos del modelo para el saldo de emisión primaria nominal (EPRIM\_N) se comportan también como ruido blanco. Para el caso de la misma serie expresada en términos reales (EPRIM\_R) se llega a los mismos resultados, aunque la distribución de probabilidad muestral de los residuos muestra evidencia de una pequeña asimetría.

El diagnóstico de la descomposición desarrollada por SEATS muestra los siguientes resultados: i) la autocorrelación del estimador empírico del componente irregular se encuentran cercano al de su estimador teórico (Cuadro N° 3.2.5) y ii) la correlación cruzada de los estimadores empíricos de los componentes (transformados en estacionario) también se encuentra cercano a la de sus estimadores teóricos (Cuadro N° 3.2.6). Estos resultados apuntan hacia una validación de la descomposición.

La descomposición de la serie llevada a cabo por SEATS no identificó estacionalidad para la liquidez nominal y la real. En cambio, el saldo de la emisión primaria nominal y real sí presenta estacionalidad, en ambos casos estable (Cuadro N° 3.2.7). Como consecuencia, el error total de estimación y el error de la revisión de la serie desestacionalizada de la emisión primaria nominal y real, tienen varianzas relativamente pequeñas. Esto a su vez, conlleva a que el estimador preliminar converja muy lentamente a su estimador final, requiriéndose para ello más de 5 años.

Los resultados para el saldo de la emisión primaria nominal también da cuenta de una mejora no muy significativa (10,87%) de realizar un ajuste concurrente en lugar de una práctica de una vez al año. En el caso del saldo de la emisión primaria real esta mejora sólo es del 5,83%.

Cuadro N° 3.2.1: Parámetros de TRAMO-SEATS, Sector Monetario

Series		Parameters
LIQ_MN_N	Liquidez del sistema bancario en moneda	RSA=6, IDUR=4

	nacional, promedio trimestral S/. MM	
EPRIM_N	Saldo de la Emisión Primaria, promedio trimestral S/. MM	RSA=6, IDUR=4
LIQ_MN_R	Liquidez del sistema bancario en moneda nacional, promedio trimestral S/. MM de 1994	RSA=6, IDUR=4
EPRIM_R	Saldo de la Emisión Primaria, promedio trimestral S/. MM de 1994	RSA=6, IDUR=4

Cuadro N° 3.2.2: Modelos Identificados, Sector Monetario

Series	N° obs.	Transformation	Model
LIQ_MN_N	46	Level	$y_t = x_t$
			$(1 - 0,44229B) (1 - B) (x_t - 310,26) = a_t$ (-3,3) (4,3)
			(1,1,0)(0,0,0)
EPRIM_N	46	Level	$y_t = x_t$
			$(1 - B^4) (1 - B)x_t = (1 - 0,28097B) (1 - 0,58278B^4)a_t$ (1,8) (-3,8)
			(0,1,1)(0,1,1)
LIQ_MN_R	46	Level	$y_t = 4 \text{ outliers} + x_t$
			$(1 - 0,3868B) (1 - B) (x_t - 148,73) = a_t$ (-2,8) (2,8)
			(1,1,0)(0,0,0)
EPRIM_R	46	Level	$y_t = 2 \text{ outliers} + x_t$
			$(1 - B^4) (1 - B)x_t = (1 + 0,47598B) (1 - 0,75103B^4)a_t$ (3,0) (-5,6)
			(0,1,1)(0,1,1)

Cuadro N° 3.2.3: Outliers, Sector Monetario

Mnemonic	1990	1991	1992	1993	1994	1995	1996	1997	1998	1999	2000	2001	%
LIQ_MN_N													0,0
EPRIM_N													0,0

LIQ_MN_R	1 TC (4.9)	3 AO (-13.5)	1 AO (-3.7)			3 LS (3.1)												8,7
EPRIM_R	3 AO (-18.9)		1 LS (-7.5)															

Cuadro N° 3.2.4: Resumen Estadístico TRAMO, Sector Monetario

Model	LIQ_MN_N	EPRIM_N	LIQ_MN_R	EPRIM_R
1. S.E of Residuals	274.9675	99.89477	205.9429	89.43983
2. BIC	11.3570	9.3394	11.0197	9.2468
3.. Normality	1.011	3.657	0.1109	4.600
4. Skewness	0.0594 (SE=0.3693)	0.6473 (SE=0.3825)	0.1048 (SE=0.3873)	0.8296 (SE=0.3922)
5. Kurtosis	3.7330 (SE=0.7385)	3.6816 (SE=0.7651)	2.8497 (SE=0.7746)	3.2794 (SE=0.7845)
6. Ljung-Box Q Stat	9.02 $\chi^2(15)$	9.32 $\chi^2(14)$	6.87 $\chi^2(15)$	13.40 $\chi^2(14)$
7. Pierce $Q_s$ -Stat	1.88	2.82	3.31	5.09
8. Q -stat for squared res.	21.55 $\chi^2(15)$	10.53 $\chi^2(14)$	6.64 $\chi^2(15)$	5.84 $\chi^2(14)$
9. Run of residuals	-0.3051	-0.6330	0.9611	1.2991
Diagnostics	OK	OK	OK	OK

Cuadro N° 3.2.5: ACF del Componente Irregular, Sector Monetario

	$\rho_1$			$\rho_4$		
	Component	Theoretical Estimator	Estimate	Component	Theoretical Estimator	Estimate
LIQ_MN_N	0.000	-0.685	-0.757	0.000	0.035	0.330

EPRIM_N	0.000	-0.633	-0.595	0.000	-0.197	-0.316
LIQ_MN_R	0.000	-0.680	-0.717	0.000	0.031	-0.015
EPRIM_R	0.000	-0.726	-0.722	0.000	-0.054	-0.252

Cuadro N° 3.2.6: CCF entre los Estimadores (Transformados en Estacionario), Sector Monetario

	Trend-Seasonal	Seasonal-Irregular	Trend-Irregular
LIQ_MN_N			
Theor. Estimator			0.286
Estimate			0.212
EPRIM_N			
Theor. Estimator	-0.318	0.092	0.105
Estimate	-0.364	0.127	0.113
LIQ_MN_R			OK
Theor. Estimator			0.287
Estimate			0.244
EPRIM_R			
Theor. Estimator	-0.250	0.061	0.158
Estimate	-0.363	0.039	0.220

Cuadro N° 3.2.7: Resumen Estadístico: SEATS, Sector Monetario

Model	LIQ_MN_N	EPRIM_N	LIQ_MN_R	EPRIM_R
10. Component innovation variace (in units of $V_a$ )				
• Trend-cycle				
• Seasonal	0.46974	0.28037	0.46178	0.44229

<ul style="list-style-type: none"> <li>• Irregular</li> <li>• SA series</li> </ul>	0.09899 1.00000	0.02054 0.08260 0.69871	0.10269 1.00000	0.00757 0.05336 0.81769
11. Total Estimation error variance (in units of $V_a$ ) <ul style="list-style-type: none"> <li>• Trend</li> <li>• SA series</li> </ul>	0.089	0.161 0.104	0.092	0.119 0.074
12. Variance of revision in concurrent estimator (Units $V_a$ ) <ul style="list-style-type: none"> <li>• Trend</li> <li>• SA series</li> </ul>	0.021	0.080 0.055	0.02	0.052 0.037
13. Significance of seasonality (95%): # significant quarters per year <ul style="list-style-type: none"> <li>• Historical estimation</li> <li>• Preliminary estimation</li> <li>• Next year forecast</li> </ul>		2 3 1		2 1 1
14. Convergence (% decrease in SE of revision error after two years) <ul style="list-style-type: none"> <li>• Trend</li> <li>• SA series</li> </ul>	99.96	80.37 65.05	99.97	59.05 43.23
15. Gain from concurrent adjustment (% decrease in RMSE)		10.87		5.826
16. Diagnostics: comparison of ACF and CCF	OK	OK	OK	OK

### 3.3. Variables del Sector Fiscal

Las series consideradas en el sector fiscal corresponden a los principales componentes de los ingresos tributarios del gobierno central, expresados en millones de Nuevos Soles de 1994. En todo momento que se haga referencia al ajuste estacional de la serie agregada ITRIB\_R (ingresos tributarios del gobierno central), nos referiremos al modo directo de

desestacionalización. El Cuadro N° 3.3.1 describe el mnemónico utilizado para cada variable y su respectiva descripción, así como los parámetros utilizados por TRAMO-SEATS para la descomposición de la serie en cada caso.

De las 5 series consideradas, en todas ellas TRAMO detectó un número de outliers inferior a 5% (del número de observaciones), excepto para la serie IMP\_ING\_R (6,7%). Los modelos ARIMA estacional multiplicativo identificados por el programa para la serie observada de las variables consideradas arrojan resultados, en general, aceptables en términos de ajuste y comportamiento de las innovaciones.

Por ejemplo, de la segunda columna del Cuadro N° 3.3.4, para la serie IMP\_ING\_R los estadísticos Bowman-Shenton (1,65), Skewness (0,24) y Kurtosis (2,09), los cuales describen el comportamiento de las innovaciones del modelo ARIMA  $(1 - B)(1 - B^4)Ln(x_t) = (1 - 0,4074B^4)a_t$ , son menores a 5,99;  $1,96 \times 0,4027$ ; y  $3 + 1,96 \times (0,4027)$ , respectivamente. Por tanto se acepta la hipótesis nula de normalidad, asimetría cero, y exceso de Kurtosis cero. Los estadísticos  $Q$  de Ljung-Box (6,54) y  $Q_s$  de Box-Pierce (0,86) son menores a 25 y 5,99, sus respectivos valores críticos con un nivel de confianza del 95%, indicando por tanto no autocorrelación (hasta el orden 16) y no autocorrelación estacional (hasta el orden 2) de las innovaciones. Igualmente, el estadístico  $Q$  de los cuadrados de los residuos (11,83) es menor a 25 (95%,  $\chi^2(15)$ ), lo cual indica independencia de los residuos. En resumen, las innovaciones del modelo para la serie IMP\_ING\_R tienen las características deseadas: no tienen autocorrelación, son independientes y se distribuyen como una normal.

Siguiendo este mismo análisis se llega a la conclusión de que las innovaciones de los modelos ARIMA estacional multiplicativo de las variables IMP\_IMP\_R, IGV\_R e ITRIB\_R, no tienen autocorrelación, son independientes y se distribuyen como una normal.

El caso de la serie ISC\_R es distinto: las innovaciones de su modelo ARIMA  $(1 - 1,3099B + 0,5497B^2) (\ln(x_t) - 6.3881) = a_t$  no pasan el test de normalidad con un nivel de confianza del 95% (con 97,5% si se acepta H0) y las hipótesis nulas de los estadísticos Skewness y Kurtosis se aceptan ajustadamente. Adicionalmente, las innovaciones presentan autocorrelación estacional, lo cual se deriva del estadístico  $Q_s$ . Estos resultados apuntan hacia una mayor investigación a fin de identificar modelos ARIMA alternativos para ISC\_R cuyos errores se comporten como variable ruido blanco.

Del Cuadro N° 3.3.5, se puede ver que la descomposición elegida para las 5 series consideradas, tienen componentes irregulares cuya autocorrelación de orden 1 y 4 correspondientes a las estimaciones empíricas se encuentran próximos a la de sus respectivos estimadores teóricos, lo cual apunta hacia la validación de la descomposición.

Del Cuadro N° 3.3.6, la correlación cruzada entre los componentes de los estimados empíricos (transformados en estacionario) y estimadores teóricos (transformados en estacionario) se encuentran próximos entre sí, lo cual también va en sentido de la validación de la descomposición. Para el caso de la serie IMP\_IMP\_R sólo se observa una sobreestimación de la correlación tendencia-estacional por parte del estimado empírico (-0,287) en comparación a

su estimador empírico (-0.084). No obstante, dicha sobreestimación es pequeña en términos absolutos.

La variable  $IMP\_ING\_R$  muestra un componente estacional muy estable (primera columna del Cuadro N° 3.3.5), lo cual se desprende al considerar que la varianza de la innovación del componente estacional es sólo el 3% de la varianza del error de pronóstico un periodo hacia adelante para la serie observada. Por su parte, la serie  $IMP\_IMP\_R$  tiene una estacionalidad cercana a la determinística y la de  $ITRIB\_R$  es moderadamente estable.

Las series  $IGV\_R$  e  $ISC\_R$  no tienen un componente estacional, por lo que la serie ajustada por estacionalidad será la misma que la serie observada en ambos casos. Las gráficas de ambas series, a groso modo, parecen confirmar la ausencia de estacionalidad. Así, SEATS descompone la serie  $IGV\_R$  en un componente de tendencia-ciclo más un componente irregular;  $ISC\_R$ , en un componente transitorio más un componente irregular. En este último caso, el componente transitorio captura los movimientos de corto plazo asociados a las frecuencias entre 0 y  $\pi / 2$ . Así,  $ISC\_R$  está dominado principalmente por el componente transitorio, predecible, y en menor medida por un componente irregular.

La convergencia de la serie desestacionalizada y la tendencia hacia sus estimadores finales es relativamente rápida para la variable  $IMP\_ING\_R$ , de aquí que hay una mejora importante de realizar un ajuste concurrente en lugar de un ajuste de una vez al año. Similarmente, esto sucede para la variable  $ITRIB\_R$ . El caso de la variable  $IMP\_IMP\_R$  es distinto: la serie ajustada por estacionalidad posee una lenta convergencia hacia su estimador final, y por tanto

una mejora muy pequeña (1,7%) de realizar un ajuste concurrente en lugar de un ajuste de una vez al año.

Cuadro N° 3.3.1: Parámetros de TRAMO-SEATS, Sector Fiscal

Series		Parameters
IMP_ING_R	Impuestos a los Ingresos-Gob. Central	RSA=6, IDUR=4
IMP_IMP_R	Imp. a las Importaciones-Gob. Central	RSA=6, IDUR=4
IGV_R	Recaudación por IGV-Gob. Central	RSA=6, IDUR=4
ISC_R	Recaudación por ISC-Gob. Central	RSA=6, IDUR=4
ITRIB_R	Ingresos Tributarios-Gob. Central	RSA=6, IDUR=4

Cuadro N° 3.3.2: Modelos Identificados, Sector Fiscal

Series	N° obs.	Transformatio n	Model
IMP_ING_R	45	Log	$y_t = 3 \text{ outliers} + x_t$
			$(1 - B) (1 - B^4) \text{Ln}(x_t) = (1 - 0,4074B^4)a_t$ (-2,82)
			(0,1,0)(0,1,1)
IMP_IMP_R	45	Level	$y_t = 1 \text{ outliers} + x_t$
			$(1 - B) (1 - B^4)x_t = (1 - 0,9538B^4)a_t$ (-20,08)
			(0,1,0)(0,1,1)
IGV_R	45	Level	$y_t = 2 \text{ outliers} + x_t$
			$(1 - 0,1947B) (1 - B)x_t = a_t$ (-1,32)
			(1,1,0)(0,0,0)
ISC_R	45	Log	$y_t = x_t$
			$(1 - 1,3099B + 0,5497B^2) (\text{Ln}(x_t) - 6.3881) = a_t$

			(-9,85)	(4,33)	(90,18)
			(2,0,0)(0,0,0)		
ITRIB_R	45	Level	$y_t = 1 outliers + x_t$		
			$(1 + 0,4474B) (1 - 0,5014B^4) (1 - B) (x_t - 41,9) = a$		
			(3366,9)	(-3,7)	(1,2)
			(1,1,0)(1,0,0)		

Cuadro N° 3.3.3: Outliers, Sector Fiscal

Mnemonic	1990	1991	1992	1993	1994	1995	1996	1997	1998	1999	2000	2001	%
IMP_ING_R	3 AO (-7,4)		2 LS (4.7)				2 AO (5.1)						6,7
IMP_IMP_R	3 LS (-5.6)												2,2
IGV_R	3 TC (-6.2)									4 TC (3.8)			4,4
ISC_R													0,0
ITRIB_R	4 AO (4.3)												2,2

Cuadro N° 3.3.4: Resumen Estadístico TRAMO, Sector Fiscal

Model	IMP_ING_R	IMP_IMP_R	IGV_R	ISC_R	ITRIB_R
1. S.E of Residuals	0.09358806	28.59270	63.95837	0.1161559	185.3741
2. BIC	-4.4742	6.8395	8.5652	-4.1209	10.6935
3.. Normality	1.647	0.5501	1.947	7.118	2.325
4. Skewness	0.2428 (SE=0.4027)	-0.2745 (SE=0.3922)	0.3431 (SE=0.3825)	-0.6911 (SE=0.3693)	0.5716 (SE=0.3780)
5. Kurtosis	2.0875	2.8075	2.1820	4.4044	3.1475

	(SE=0.8054)	(SE=0.7845)	(SE=0.7651)	(SE=0.7385)	(SE=0.7559)
6. Ljung-Box $Q$ Stat	6.54 $\chi^2(15)$	14.38 $\chi^2(15)$	10.78 $\chi^2(15)$	23.62 $\chi^2(14)$	6.62 $\chi^2(14)$
7. Pierce $Q_s$ -Stat	0.86	1.11	2.65	13.17	0.27
8. $Q$ -stat for squared res.	11.83 $\chi^2(15)$	15.36 $\chi^2(15)$	20.90 $\chi^2(15)$	14.48 $\chi^2(14)$	20.45 $\chi^2(14)$
9. Run of residuals	0.6674	-0.6495	1.8991	-0.3051	-1.5622
Diagnostics	OK	OK	OK		OK

Cuadro N° 3.3.5: ACF del Componente Irregular, Sector Fiscal

	$\rho_1$			$\rho_4$		
	Component	Theoretical Estimator	Estimate	Component	Theoretical Estimator	Estimate
IMP_ING_R	0.000	-0.500	-0.506	0.000	-0.296	-0.476
IMP_IMP_R	0.000	-0.500	-0.599	0.000	-0.023	-0.357
IGV_R	0.000	-0.569	-0.656	0.000	0.002	0.154
ISC_R	0.000	-0.673	-0.645	0.000	0.000	0.092
ITRIB_R	0.000	-0.203	-0.272	0.000	-0.401	-0.347

Cuadro N° 3.3.6: CCF entre los Estimadores (Transformados en Estacionario) , Sector Fiscal

	Trend-Seasonal	Seasonal-Irregular	Trend-Irregular	Trans.-Irregular
IMP_ING_R				
Theor. Estimator	-0.316	0.121	-0.016	
Estimate	-0.377	0.102	0.041	
IMP_IMP_R				
Theor. Estimator	-0.084	0.037	0.000	
Estimate	-0.287	0.067	0.065	
IGV_R				

Theor. Estimator			0.293	
Estimate			0.225	
ISC_R				
Theor. Estimator				0.241
Estimate				0.204
ITRIB_R				
Theor. Estimator	0.042	0.625	0.110	0.938
Estimate	0.044	0.644	0.104	0.932

Cuadro N° 3.3.7: Resumen Estadístico: SEATS, Sector Fiscal

Model	IMP_ING_R	IMP_IMP_R	IGV_R*	ISC_R	ITRIB_R
10. Component innovation variance (in units of $V_a$ )					
• Trend-cycle	0.13756	0.24134	0.32411		0.04227
• Seasonal	0.03447	0.00021			0.12922
• Irregular	0.12580	0.23860	0.18550	0.12228	0.04386
• SA series	0.58193	0.96551	1.0000	1.00000	0.27696
• Transitory				0.37049	0.02771
11. Total Estimation error variance (in units of $V_a$ )					
• Trend	0.179	0.187	0.151		0.142
• SA series	0.121	0.014	0.000	0.000	0.129
12. Variance of revision in concurrent estimator (Units $V_a$ )					
• Trend	0.104				
• SA series	0.068	0.067	0.045		0.098
		0.007	0.000	0.000	0.072

13. Significance of seasonality (95%): # significant quarters per year					
• Historical estimation	4	4			2
• Preliminary estimation	4	4			2
• Next year forecast	4	4			0
14. Convergence (% decrease in SE of revision error after two years)					
• Trend	94.37	86.78	100.00		100.00
• SA series	81.63	9.01	0.00	0.00	100.00
15. Gain from concurrent adjustment (% decrease in RMSE)	19.16	1.711			42.09
16. Diagnostics: comparison of ACF and CCF	OK	OK	OK	OK	OK

\* Los resultados de SEATS son los de la aproximación al Modelo estimado por TRAMO

### 3.4. Variables del Sector Externo

En el sector externo, las series consideradas corresponden a los principales componentes de la cuenta corriente de la balanza de pagos, expresado en millones de dólares estadounidenses. El Cuadro N° 3.4.1 describe el mnemónico utilizado para cada variable y su respectiva descripción, así como los parámetros utilizados por TRAMO-SEATS para la descomposición de la serie en cada caso.

De las 4 series consideradas, en 2 de ellas TRAMO identificó un outlier y en las otras 2 restantes el programa no encontró observación atípica (Cuadro N° 3.4.3). Los estadísticos

considerados para la descripción de las innovaciones de los modelos ARIMA identificados y estimados por TRAMO, la autocorrelación e independencia de los errores, conducen en todos los casos a aceptar la hipótesis nula (Cuadro N° 3.4.4). Gráficamente, también se puede observar que los residuos caen dentro del intervalo de confianza, lo cual apunta a inferir que se comportan como ruido blanco.

Las autocorrelaciones de orden 1 y 4 correspondientes a las estimaciones empíricas del componente irregular están próximos a los de los estimadores teóricos, lo cual va en el sentido correcto para la validación de la descomposición (Cuadro N° 3.4.5). De igual modo, las correlaciones cruzadas de las estimaciones empíricas de los componentes (transformados en estacionario) están próximos a la de los estimadores teóricos (transformados en estacionario), lo cual también apunta también hacia la validación de la calidad de la descomposición (Cuadro N° 3.4.6)

La serie EXP\_SS posee un componente estacional estable; IMP\_SS, cercana a una determinística; IMP\_BS, no muy estable y la serie EXP\_BS no presenta estacionalidad (Cuadro N° 3.4.7). La relativamente alta aleatoriedad del componente estacional de IMP\_BS conduce a una nula significancia de la estacionalidad tanto para los estimadores históricos, como para los preliminares y pronóstico. En el caso de la serie EXP\_SS la alta estabilidad de su estacionalidad conlleva a una menor varianza del error de revisión de la serie desestacionalizada y hacia una rápida convergencia hacia su estimador final, produciéndose una mejora importante al hacer un ajuste concurrente en lugar de un ajuste de una vez al año. La variable IMP\_SS presenta una muy pequeña varianza del error de revisión de la serie

desestacionalizada. Su lenta convergencia, lo cual no es importante debido a la pequeña varianza del error de revisión, conlleva hacia una mejora moderada de hacer un ajuste concurrente en lugar de un ajuste de una vez al año.

Cuadro N° 3.4.1: Parámetros de TRAMO-SEATS, Sector Externo

Series		Parameters
EXP_BS	Exportaciones de Bienes	RSA=6, IDUR=4
IMP_BS	Importaciones de Bienes	RSA=6, IDUR=4
EXP_SS	Exportaciones de Servicios	RSA=6, IDUR=4
IMP_SS	Importaciones de Servicios	RSA=6, IDUR=4

Cuadro N° 3.4.2: Modelos Identificados, Sector Externo

Series	N° obs.	Transformatio n	Model
EXP_BS	45	Log	$y_t = 1 \text{ outlier} + x_t$
			$(1 - B) (\ln(x_t) - 0,29494) = a_t$ (1,26)
			(0,1,0)(0,0,0)
IMP_BS	45	Level	$(1 - 0,21342B) (1 - 0,37934B^4) (1 - B)x = a_t$ (-1.42) (-2.54)
			(1,1,0)(1,0,0)
EXP_SS	45	Log	$y_t = 1 \text{ outlier} + x_t$
			$(1 + 0,39969B) (1 - B) (1 - B^4) \ln(x_t) = (1 - 0,48234$ (2.57) (-3.02)
			(1,1,0)(0,1,1)
IMP_SS	45	Level	$y_t = x_t$

			$(1 - B) (1 - B^4)x_t = (1 - 0,25609B) (1 - 0,74334B^4)$
			(-1.62)                      (-4.65)
			(0,1,1)(0,1,1)

Cuadro N° 3.4.3: Outliers, Sector Externo

Mnemonic	1990	1991	1992	1993	1994	1995	1996	1997	1998	1999	2000	2001	%
EXP_BS									1 TC (-3.6)				2.2
IMP_BS													0.0
EXP_SS									2 AO (3.34)				2.2
IMP_SS													0.0

Cuadro N° 3.4.4: Resumen Estadístico TRAMO, Sector Externo

Model	EXP_BS	IMP_BS	EXP_SS	IMP_SS
1. S.E of Residuals	0.08973939	129.6022	0.08058389	26.01083
2. BIC	-4.6962	9.8544	-4.8382	6.6502
3.. Normality	0.7231	1.409	2.402	2.013
4. Skewness	-0.3207 (SE=0.3780)	-0.4143 (SE=0.3693)	0.5766 (SE=0.3922)	-0.5407 (SE=0.3873)
5. Kurtosis	2.9572 (SE=0.7559)	2.7137 (SE=0.7385)	3.3847 (SE=0.7845)	3.1953 (SE=0.7746)
6. Ljung-Box Q Stat	8.28 $\chi^2(16)$	13.00 $\chi^2(14)$	8.89 $\chi^2(14)$	6.14 $\chi^2(14)$
7. Pierce $Q_s$ -Stat	0.01	3.45	1.60	0.08
8. Q -stat for squared res.	7.56	10.83	12.65	5.44

	$\chi^2(16)$	$\chi^2(14)$	$\chi^2(14)$	$\chi^2(14)$
9. Run of residuals	0.9373	0.0000	-0.3248	-0.9611
Diagnostics	OK	OK	OK	OK

Cuadro N° 3.4.5: ACF del Componente Irregular, Sector Externo

	$\rho_1$			$\rho_4$		
	Component	Theoretical Estimator	Estimate	Component	Theoretical Estimator	Estimate
EXP_BS	0.000	-0.500	-0.374	0.000	0.000	-0.021
IMP_BS	0.000	-0.585	-0.602	0.000	-0.332	-0.360
EXP_SS	0.000	-0.237	-0.170	0.000	-0.259	-0.291
IMP_SS	0.000	-0.368	-0.444	0.000	-0.134	-0.233

Cuadro N° 3.4.6: CCF entre los Estimadores (Transformados en Estacionario), Sector Externo

	Trend-Seasonal	Seasonal-Irregular	Trend-Irregular	Trans.-Irregular
EXP_BS				
Theor. Estimator			0.289	
Estimate			0.435	
IMP_BS				
Theor. Estimator	0.112	0.516	0.108	0.586
Estimate	0.149	0.517	0.182	0.557
EXP_SS				
Theor. Estimator	-0.200	0.226	-0.182	0.783
Estimate	-0.197	0.290	-0.220	0.752
IMP_SS				
Theor. Estimator	-0.164	0.115	-0.109	
Estimate	-0.188	0.149	-0.028	

Cuadro N° 3.4.7: Resumen Estadístico: SEATS, Sector Externo

Model	EXP_BS	IMP_BS	EXP_SS	IMP_SS
10. Component innovation variance (in units of $V_a$ )				
• Trend-cycle				
• Seasonal	0.25000	0.13014	0.07811	0.11194
• Irregular		0.11303	0.02984	0.00658
• SA series	0.25000	0.09954	0.12704	0.29806
• Transitory	1.00000	0.55825	0.61063	0.81023
		0.00028	0.01978	
11. Total Estimation error variance (in units of $V_a$ )				
• Trend	0.188	0.229	0.154	0.215
• SA series	0.000	0.173	0.123	0.076
12. Variance of revision in concurrent estimator (Units $V_a$ )				
• Trend	0.063	0.120	0.094	0.102
• SA series	0.000	0.065	0.061	0.038
13. Significance of seasonality (95%): # significant quarters per year				
• Historical estimation		0	4	2
• Preliminary estimation		0	4	2
• Next year forecast		0	4	2
14. Convergence (% decrease in SE of revision error after two years)				
• Trend	100.0	100.0	95.62	92.47
• SA series	0.000	100.0	76.42	44.43
15. Gain from concurrent		18.34	25.38	11.57

adjustment (% decrease in RMSE)				
16. Diagnostics: comparison of ACF and CCF	OK	OK	OK	OK

## **Capítulo 4**

# **Evaluación del Ajuste Estacional TRAMO-SEATS**

#### **4. Evaluación del Ajuste Estacional TRAMO-SEATS**

En este capítulo se expone la evaluación del ajuste estacional TRAMO-SEATS, siguiendo la metodología descrita en la sección 2.3.

##### **4.1. Variables del Sector Real**

Los resultados de la prueba de autocorrelación para las series ajustadas por estacionalidad (en primeras diferencias), dan cuenta de que todas ellas, excepto para el caso de MANUF, no muestran evidencia de autocorrelación estacional (Columna 5 del Cuadro N° 4.1.1). Esto se confirma tanto aplicando la prueba sugerida por Franses (et. al.) como el test de Box-Pierce. El número de rezagos estacionales considerados fue de 2. Por lo tanto, hay evidencia de que el ajuste estacional removi6 adecuadamente el componente estacional en 7 de las 8 series consideradas del sector real.

Por ejemplo, para la serie desestacionalizada AGRP (diferenciada), los coeficientes correspondientes al primer y segundo rezago estacional son  $-1,1$  y  $-0,8$ , respectivamente, los mismos que se encuentran dentro del rango de aceptaci6n de la hip6tesis nula  $\langle -2; 2 \rangle$ , bajo una prueba  $t$  con un nivel de significaci6n  $\alpha = 5\%$ , por lo que ambos coeficientes son estadisticamente iguales a cero. El estadístico  $Q_s$  Box-Pierce (dos rezagos estacionales) es

igual a 0,71, menor al valor crítico 5,99.; lo cual significa que no hay evidencia de autorrelación estacional.

El caso de la serie desestacionalizada MANUF es distinto. El coeficiente correspondiente al primer rezago estacional es  $-3,3$  el mismo que se encuentra fuera del rango de aceptación de la hipótesis nula  $\langle -2; 2 \rangle$ , bajo una prueba  $t$  con un nivel de significación  $\alpha = 5\%$ , dando evidencia de que es significativo. El estadístico  $Q_s$  (1 rezago estacional) es igual a 3,91 mayor al valor crítico de 3,84 para una  $\chi^2(1)$ . Por lo tanto, el ajuste no removi6 totalmente el componente estacional de la serie MANUF.

Cuadro N° 4.1.1: Prueba de Autocorrelación Estacional en la Serie Desestacionalizada, Sector Real

	Constante	Rezago Estacional 1	Rezago Estacional 2	¿Son significativos?	$Q_s$ Box-Pierce	Valor Crítico =5,99 (5%, $\chi^2(2)$ )
		$\Phi_1$	$\Phi_2$			¿Autocorrelación estacional?
AGRP	3.702059	-1.079697	-0.762853	No	0,705	No
PES	0.440243	-0.798947	-0.759137	No	0.990	No
MIN	5.668278	-1.477814	-1.478070	No	1.444	No

MANUF	2.851577	-3.273949	-0.363751	Sólo en 1	4.440	No
CONSTR	1.091302	-0.631391	0.686848	No	0.672	No
COMERC	2.570430	-1.561391	0.010671	No	3.916	No
OTROS	3.807197	-1.139356	-0.588923	No	0.850	No
PBI94 PERU	4.133218	-1.927139	-0.274041	No	1.867	No

En la aplicación de la prueba de cointegración (Test 2) entre la serie original y la desestacionalizada se contempló dos versiones: en la primera se excluye la constante en la ecuación cointegradora y en la segunda se dejó a la constante como un coeficiente libre. Para la prueba de raíces unitarias de los residuos se usó el test de Phillips-Perron (PP) y el de Dickey-Fuller Aumentado (ADF).

La prueba PP de raíces unitarias sobre los residuos (de la ecuación cointegradora) para las 8 variables consideradas indica que éstos son integrados de orden cero o estacionarios. Por tanto, el proceso de ajuste estacional no distorsionó la tendencia de la serie original. La prueba ADF para los mismos residuos, muestra resultados distintos sólo para el caso de AGRP y PBI94 PERU.

Cuadro N° 4.1.2: Prueba de Cointegración entre la Serie Original y la Desestacionalizada-PP,  
Sector Real

	Ec. Cointegradora Sin Media		Ec. Cointegradora con Media		Errores de la Ec. Cointegradora
	PP (4 rezagos)	Valor Crítico 5%	PP (4 rezagos)	Valor Crítico 5%	
AGRP	-10.13657	-1.9483	-10.24090	-1.9483	I(0)
PES	-17.73349		-17.75014		I(0)
MIN	-10.47092		-10.43128		I(0)
MANUF	-45.20901		-45.09230		I(0)
CONSTR	-8.824341		-8.818846		I(0)
COMERC	-13.40028		-13.46839		I(0)
OTROS	-13.40028		-13.46839		I(0)
PBI94 PERU	-25.98502		-26.04183		I(0)

Cuadro N° 4.1.3: Prueba de Cointegración entre la Serie Original y la Desestacionalizada-  
ADF, Sector Real

	Ec.Cointegradora Sin Media		Ec.Cointegradora con Media		Errores de la Ec. Cointegradora
	ADF (4 rezagos)	Valor Crítico 5%	ADF (4 rezagos)	Valor Crítico 5%	
AGRP	-1.586437	-1.9492	-0.766978	-1.9492	I(1)
PES	-5.967656	-1.9492	-5.929516	-1.9492	I(0)
MIN	-4.131894	-1.9492	-3.619922	-1.9492	I(0)
MANUF	-6.326879	-1.9492	-3.660125	-1.9492	I(0)
CONSTR	-6.400970	-1.9492	-2.223197	-1.9492	I(0)
COMERC	-4.126111	-1.9492	-2.654065	-1.9492	I(0)
OTROS	-4.126111	-1.9492	-2.654065	-1.9492	I(0)
PBI94 PERU	-0.896846	-1.9492	-0.867838	-1.9492	I(1)

#### 4.2. Variables del Sector Monetario

Los resultados de las pruebas de correlación estacional en el caso de las series desestacionalizadas (diferenciadas) EPRIM\_N y EPRIM\_R, apuntan a validar el ajuste estacional. En estos 2 casos, los coeficientes de los rezagos estacionales 1 y 2 en la ecuación

autorregresiva de la forma  $\Delta x_t^{SA} = \mu + \phi_1 \Delta x_{t-4}^{SA} + \phi_2 \Delta x_{t-8}^{SA} + a_t$  son estadísticamente iguales a cero. Igualmente, la aplicación del test  $Q_s$  muestra que no hay autocorrelación estacional (hasta el orden 2) en la series desestacionalizadas (diferenciadas). En el caso de las series LIQ\_MN\_N y LIQ\_MN\_R, SEATS no identificó un componente estacional, lo cual se valida ex post mediante la no detección de autocorrelación estacional tanto por el test sugerido por Franses como por el test de Box-Pierce

Cuadro N° 4.2.1: Prueba de Autocorrelación Estacional en la Serie Desestacionalizada, Sector Monetario

	Constante	Rezagó Estacional 1	Rezagó Estacional 2	¿Son significativos?	$Q_s$ Box- Pierce	Valor Crítico =5,99 (5%, $\chi^2(2)$ )
		$\Phi_1$	$\Phi_2$			¿Autocorrelación estacional?
LIQ_MN_N	342.6806	-0.083528	0.200503	NO	1.680	NO
EPRIM_N	8.726897	-1.091968	0.913942	NO	3.047	NO
LIQ_MN_R	3.549507	-0.432844	0.377953	NO	0.042	NO
EPRIM_R	3.678390	-1.200875	0.118697	NO	0.080	NO

La prueba de raíces unitarias sobre los residuos (de la ecuación cointegradora) se aplicó sólo para el caso de las series EPRIM\_N y EPRIM\_R. El test PP en el caso de estas dos variables conduce al resultado de que las serie original y la desestacionalizada cointegran (Cuadro N° 4.2.2). Por lo tanto, el proceso de ajuste estacional no distorsionó la tendencia de la serie

original. La prueba ADF muestra resultados distintos en el caso de ambas series (Cuadro N° 4.2.3). No se realizó la misma prueba para LIQ\_MN\_N y LIQ\_MN\_R debido a que éstas no presentan estacionalidad.

Cuadro N° 4.2.2: Prueba de Cointegración entre la Serie Original y la Desestacionalizada-PP, Sector Monetario

	Ec. Cointegradora Sin Media		Ec. Cointegradora con Media		Errores de la Ec. Cointegradora
	PP (4 rezagos)	Valor Crítico 5%	PP (4 rezagos)	Valor Crítico 5%	
LIQ_MN_N*					
EPRIM_N	-9.619665	-1.9481	-9.602701	-1.9481	I(0)
LIQ_MN_R*					
EPRIM_R	-10.58482	-1.9481	-10.56923	-1.9481	I(0)

\*: No tiene componente estacional

Cuadro N° 4.2.3: Prueba de Cointegración entre la Serie Original y la Desestacionalizada-  
ADF, Sector Monetario

	Ec.Cointegradora Sin Media		Ec.Cointegradora con Media		Errores de la Ec. Cointegradora
	ADF (4 rezagos)	Valor Crítico 5%	ADF (4 rezagos)	Valor Crítico 5%	
LIQ_MN_N*					
EPRIM_N	-1.663438	-1.9490	-1.681580	-1.9490	I(1)
LIQ_MN_R*					
EPRIM_R	-1.559282	-1.9490	-1.399769	-1.9490	I(1)

\*: No tiene componente estacional

### 4.3. Variables del Sector Fiscal

En el Cuadro N° 4.3.1 se puede observar que las series desestacionalizadas (diferenciadas) no muestran indicios de autocorrelación estacional. Igualmente, la aplicación del test  $Q_s$  conduce a los mismos resultados. Consecuentemente, hay evidencia de que el ajuste estacional TRAMO-SEATS ha removido adecuadamente el componente estacional en las 5 series consideradas del sector fiscal (gobierno central).

Cuadro N° 4.3.1: Prueba de Autocorrelación Estacional en la Serie Desestacionalizada, Sector Fiscal

	Constante	Rezago Estacional 1	Rezago Estacional 2	¿Son significativos?	$Q_s$ Box-Pierce	Valor Crítico =5,99 (5%, $\chi^2(2)$ )
						¿Autocorrelación estacional?
IMP_ING_R	1.142079	1.451050	-0.950860	No	2.202	No
IMP_IMP_R	1.592003	-1.497137	-0.489242	No	2.131	No
IGV_R	1.825251	0.644645	0.381937	No	0.316	No
ISC_R	-0.719988	1.066424	0.928272	No	1.036	No
ITRIB_R	1.688787	1.451332	0.035630	No	0.097	No

La prueba de raíces unitarias sobre los residuos (de la posible ecuación cointegradora) no se aplicó en el caso de las series IGV\_R e ISC\_R, debido a que éstas no presentarían estacionalidad. El test PP en el caso de las 3 variables restantes conduce al resultado de que las serie original y la desestacionalizada cointegran (Cuadro N° 4.3.2). Por lo tanto, el proceso de ajuste estacional no distorsionó la tendencia de la serie original. La prueba ADF muestra resultados distintos sólo en el caso de IMP\_IMP\_R (Cuadro N° 4.3.3).

Cuadro N° 4.3.2: Prueba de Cointegración entre la Serie Original y la Desestacionalizada-PP, Sector Fiscal

	Ec. Cointegradora Sin Media		Ec. Cointegradora con Media		Errores de la Ec. Cointegradora
	PP (4 rezagos)	Valor Crítico 5%	PP (4 rezagos)	Valor Crítico 5%	
IMP_ING_R	-11.59059	-1.9483	-11.45615	-1.9483	I(0)
IMP_IMP_R	-10.87430	-1.9483	-10.82526	-1.9483	I(0)
IGV_R*					
ISC_R*					
ITRIB_R	-20.29830	-1.9483	-20.17269	-1.9483	I(0)

\*: No tiene componente estacional

Cuadro N° 4.3.3: Prueba de Cointegración entre la Serie Original y la Desestacionalizada-  
ADF, Sector Fiscal

	Ec. Cointegradora Sin Media		Ec. Cointegradora con Media		Errores de la Ec. Cointegradora
	ADF (4 rezagos)	Valor Crítico 5%	ADF (4 rezagos)	Valor Crítico 5%	
IMP_ING_R	-2.742920	-1.9492	-2.529275	-1.9492	I(0)
IMP_IMP_R	1.258265	-1.9492	-0.409803	-1.9492	I(1)
IGV_R*					
ISC_R*					
ITRIB_R	-6.755891	-1.9492	-6.511519	-1.9492	I(0)

\*: No tiene componente estacional

#### 4.4. Variables del Sector Externo

Los resultados de las pruebas de correlación estacional en el caso de las series desestacionalizadas (diferenciadas) IMP\_BS, EXP\_SS e IMP\_SS, apuntan a validar el ajuste estacional. En estos 3 casos, los coeficientes de los rezagos estacionales 1 y 2 en la ecuación  $\Delta x_t^{SA} = \mu + \phi_1 \Delta x_{t-4}^{SA} + \phi_2 \Delta x_{t-8}^{SA} + a_t$  son estadísticamente iguales a cero. Igualmente, la aplicación del test  $Q_s$  muestra que no hay autocorrelación estacional (hasta el orden 2) en la series desestacionalizadas (diferenciadas). En el caso de la serie EXP\_BS, SEATS no identificó un componente estacional, lo cual se valida ex post mediante la no detección de autocorrelación estacional tanto por el test sugerido por Franses como por el test de Box-Pierce (Cuadro N° 4.1.1).

Cuadro N° 4.4.1: Prueba de Autocorrelación Estacional en la Serie Desestacionalizada, Sector Externo

	Constante	Rezago 4	Rezago 8	¿Son significativos?	$Q_s$ Box- Pierce	Valor Crítico =5,99 (5%, $\chi^2(2)$ )
						¿Autocorrelación estacional?
EXP_BS	0.640806	1.471227	0.599944	No	3.130	No
IMP_BS	1.583363	-0.504894	0.497001	No	1.978	No
EXP_SS	1.468530	-0.532701	-0.128935	No	0.385	No
IMP_SS	2.942177	-1.437726	-1.203282	No	2.098	No

El test PP de raíces unitarias sobre los residuos (de la ecuación cointegradora) para las variables IMP\_BS, EXP\_SS e IMP\_SS indica que los mismos son integrados de orden cero o estacionarios. Los resultados no se alteran si se incluye una constante como parámetro libre. De esto se infiere que el proceso de ajuste estacional no distorsionó la tendencia de la serie original. La prueba ADF para los mismos residuos, muestra resultados distintos sólo para el caso de IMP\_SS.

Cuadro N° 4.4.2: Prueba de Cointegración entre la Serie Original y la Desestacionalizada-PP, Sector Externo

	Ec.Cointegradora		Ec.Cointegradora		Errores de la Ec. Cointegradora
	Sin Media		con Media		
	PP (4 rezagos)	Valor Crítico 5%	PP (4 rezagos)	Valor Crítico 5%	
EXP_BS*					
IMP_BS	-10.15268	-1.9483	-10.27495	-1.9483	I(0)
EXP_SS	-11.50213	-1.9483	-11.50936	-1.9483	I(0)
IMP_SS	-11.44705	-1.9483	-11.36929	-1.9483	I(0)

\*: No tiene componente estacional

Cuadro N° 4.4.3: Prueba de Cointegración entre la Serie Original y la Desestacionalizada-  
ADF, Sector Externo

	Ec.Cointegradora Sin Media		Ec.Cointegradora con Media		Errores de la Ec. Cointegradora
	ADF (4 rezagos)	Valor Crítico 5%	ADF (4 rezagos)	Valor Crítico 5%	
EXP_BS*					
IMP_BS	-6.755336	-1.9492	-5.917897	-1.9492	I(0)
EXP_SS	-2.316233	-1.9492	-2.804815	-1.9492	I(0)
IMP_SS	-1.925858	-1.9492	-1.539825	-1.9492	I(1)

\*: No tiene componente estacional

## **Capítulo 5**

# **Conclusiones y Recomendaciones**

## **5. Conclusiones y Recomendaciones**

De las 21 series macroeconómicas trimestrales sometidas al proceso de ajuste estacional utilizando el procedimiento TRAMO-SEATS en un modo automático, sólo en dos de ellas (PBI pesca y manufactura) hay evidencia de que la descomposición no fue adecuada.

Series del sector real: la evaluación del ajuste estacional aceptó dicho ajuste en el caso de todas las variables, excepto en el del PBI manufactura, cuya serie desestacionalizada evidencia autocorrelación estacional de primer orden. Adicionalmente, las herramientas de diagnóstico con que cuenta TRAMO-SEATS, característica inherente al método de extracción de señales AMB, conlleva a recomendar un nuevo proceso tanto para el PBI pesca como para el PBI manufactura. Esto último no realizado en el presente estudio puesto que su propósito es evaluar el desempeño de TRAMO-SEATS en su modo automático. El PBI agropecuario, construcción, comercio, otros y el PBI global, procedimiento directo, muestran un componente estacional estable y el del PBI minero cercano al determinístico.

En el caso del PBI construcción, comercio, otros y el PBI global, la disminución de la raíz del error cuadrático medio (RMSE) de la serie desestacionalizada que resulta de una práctica de ajuste concurrente en lugar de una única vez al año es relativamente pequeña, por lo que se recomienda utilizar los factores estacionales pronosticados en el último trimestre del año

anterior para desestacionalizar la serie en los siguiente tres trimestres. Para la PBI agropecuario, se recomienda un ajuste concurrente, puesto que la reducción de la RMSF de su serie desestacionalizada es significativo.

Series del sector monetario: la descomposición no encontró un componente estacional en la liquidez en moneda nacional (nominal y real). En el caso del saldo de la emisión primaria, nominal y real, se encontró un componente estacional estable. La evaluación de la descomposición corrobora la no presencia de estacionalidad en la liquidez y no identifica correlación estacional en la serie desestacionalizada de la emisión primaria. Se recomienda llevar a cabo el ajuste estacional de la emisión primaria nominal y real una vez año, lo cual se deriva de que la mejora de realizar un ajuste concurrente en lugar de una práctica de una vez al año nos es muy significativa.

Series del sector fiscal (gobierno central): la recaudación del Impuesto General a las Ventas (IGV) e Impuesto Selectivo al Consumo (ISC) no muestra estacionalidad. Los impuestos a los ingresos y los impuestos a las importaciones tiene un componente estacional estable, en tanto que el de los ingresos tributarios (procedimiento directo) no es estable. En estas tres últimas variables, la serie desestacionalizada no muestra evidencia de autocorrelación estacional. En el caso del IGV e ISC, la serie original no tiene autocorrelación estacional. Consecuentemente, el ajuste estacional removi6 adecuadamente la estacionalidad. La frecuencia recomendada del ajuste estacional para los impuestos a los ingresos y los impuestos a las importaciones es una vez al año; para los ingresos tributarios, uno concurrente.

Series del sector externo: la variable exportaciones de bienes no muestra estacionalidad. La serie importaciones de bienes tiene una estacionalidad no muy estable en tanto que las exportaciones y las importaciones de servicios evidencian un componente estacional muy estable. La series desestacionalizadas pasan la prueba de no autocorrelación estacional, lo cual indica que se ha removido apropiadamente el componente estacional. Igualmente, en el caso de las exportaciones de servicios, la serie original no muestra autocorrelación estacional. Tanto para las exportaciones e importaciones de servicios se recomienda un ajuste de una única vez al año.

En todas las series sometidas al proceso de descomposición, sin considerar a las series que no muestran estacionalidad, la serie original y la serie desestacionalizada cointegran si la prueba Phillips-Perron se aplica a los residuos de la ecuación cointegradora. En la experiencia de algunos autores este test parece ser más robusto al problema de bajo poder de los pruebas de raíces unitarias en presencia de autocorrelación estacional.

En general, los resultados de TRAMO son confiables al elegir modelos ARIMA muy parsimoniosos y satisfactorios en términos de ajuste y del comportamiento de las innovaciones. De las 21 series consideradas en el presente estudio, sólo en dos casos hay evidencia de una pequeña asimetría de la distribución de probabilidad de los residuos (series PES y EPRIM\_R) y en uno se rechaza la normalidad (ISC\_R), considerando un nivel de confianza del 95%. No obstante, en estos tres casos el residuo continúa siendo estacionario. En conjunto, TRAMO-SEATS en un modo completamente automático arrojó resultados confiables en el 90,5% de los series sometidas al proceso de descomposición.

Estos resultados muestran la potencia del método de extracción de señales basados en modelos ARIMA implementado en TRAMO-SEATS. Este programa es oficialmente utilizado por Eurostat y el Banco Central Europeo, en este último caso, conjuntamente con el X12-ARIMA. A la luz de estos resultados, se recomienda su incorporación oficial por las instituciones gubernamentales como el Instituto de Estadística e Informática (INEI), el Banco Central de Reserva del Perú (BCRP) y el Ministerio de Economía y Finanzas (MEF).

Finalmente, algunos temas de investigación abiertos son: i) la vinculación existente entre los distintos métodos de identificación de cambio estructural y el outlier cambio en nivel (LS) identificado por TRAMO, ii) ajuste estacional directo o indirecto para series agregadas del Perú y iii) evaluación del método X12-ARIMA siguiendo la metodología seguida en el presente estudio.

## **Referencias Bibliográficas**

Bejarano, W. (2001). “Algunas Lecciones y Preferencias Reveladas de la Política Monetaria del Perú en la Última Década”, Mimeo

Caporello, G. y Maravall, A. (2000a). “Brief Description of the program TSW”, Banco de España

Caporello, G. y Maravall, A. (2000b). “New Program TSW”, Banco de España

Eurostat (2000). “Seasonal Adjustment Interface DEMETRA for TRAMO-SEATS and X12 ARIMA, User Manual”, Version 1.4.

Castillo, P. (1997). “Desestacionalización de Agregados Financieros: 1991-1996”, Estudios Económicos- Banco Central de Reserva del Perú, Octubre 1997, 93-104.

Depoutot, R. y Planas, Ch. (1998). “Comparing Seasonal Adjustment and Trend Extraction Filters with Application to a Model-Based Selection of X11 linear Filters”, Eurostat

Díaz, G. (1997). “Ajuste Estacional de Agregados Reales”, Estudios Económicos-Banco Central de Reserva del Perú, Octubre 1997, 105-123.

Fischer, B. (1995). "Decomposition of Time Series, Comparing Different Methods in Theory and Practice", Eurostat.

Franses Ph.H.B.F. (1997). "Are Many Current Seasonally Adjusted Data Downward Biased?", Discussion Paper, EUR-FEW-EI-97-17/A, Erasmus University at Rotterdam.

Franses Ph.H.B.F., Hans, H. Hoek R. Paap (1997). "Bayesian Analysis of Seasonal Unit Roots and Seasonal Mean Shifts", *Journal of Econometrics*, 78:359-380.

Franses, P.H. y M. MacAleer (1998). "Cointegration Analysis of Seasonal Time Series", *Econometric Institute Report 9836/A*, Erasmus University Rotterdam.

Franses, P.H., De Bruin P., and D. Van Dijk (2000). "Seasonal Smooth Transition Autoregression", *Econometric Institute Report EI2000-06/A*, Erasmus University Rotterdam.

Gómez, V. y Maravall, A. (1994). "Estimation, Prediction and Interpolation for Nonstationary Series with the Kalman Filter", *Journal of the American Statistical Association*, 89, 611-624.

Gómez, V. y Maravall, A. (2000a). "Automatic Modelling Methods for Univariate Series", Working Paper 9808, Banco de España. Aparece como el Capítulo 7 en Peña, D. Tiao, G.C., y Tsay, R.S. (eds.). *A Course in Advanced Time Series Analysis*, New York: J. Wiley & Sons.

Gómez, V. y Maravall, A. (2000b). “Seasonal Adjustment and Signal Extraction in Economic Time Series”, Working Paper 9809, Banco de España. Aparece como el Capítulo 8 en Peña, D. Tiao, G.C., y Tsay, R.S. (eds.). *A Course in Advanced Time Series Analysis*, New York: J. Wiley & Sons.

Gómez, V., y Maravall, A. y Peña, D. (1999). “Missing Observations in ARIMA Models: Skipping Approach versus Additive Outlier Approach”, *Journal of Econometrics*, 88, 341-363.

Gómez, V., y Maravall, A. (1997). “Programs TRAMO and SEATS, Instructions for the User (Beta Version”, Working Paper 97001, Dirección General de Análisis y P.P., Ministerio de Economía y Hacienda de España.

INEI (1997). “Desestacionalización de Series de Tiempo Económicas”, Libro 408 del Banco de Publicaciones del Instituto de Estadística e Informática INEI.

Kaiser, R. y Maravall, A. (2000). “Notes on Time Series Analysis, ARIMA Models and Signal Extraction”, Working Paper 0012, Banco de España.

Kaiser, R. y Maravall, A. (1999a). “Seasonal Outliers in Time Series”, Working Paper 9915, Banco de España.

Kaiser, R. y Maravall, A. (1999b). “Estimation of the Business Cycle: A Modified Hodrick-Prescott Filter”, *Spanish Economic Review* 1, 175-206.

Maravall, A. (1987). "Minimum Mean-Squared-Error Estimation of the Noise in Unobserved Component Models", *Journal of Business and Economic Statistics*, 5, 115-120.

Maravall, A. (1988). "The Use of ARIMA Models in Unobserved Components Estimation", en W. Barnett, E. Berndt y H. While (eds.), *Dynamic Econometric Modeling, Proceedings of the Third International Symposium in Economic Theory and Econometrics*, Austin. Cambridge: Cambridge University Press, 171-196.

Maravall, A. (1989). "On the Dynamic Structure of a Seasonal Component", *Journal of Economic Dynamics and Control*, 13, 81-89.

Maravall, A. (1993). "Stochastic Linear Trends: Models and Estimators", *Journal of Econometrics*, 56, 5-37.

Maravall, A. (1995). "Unobserved Components in Economic Time Series", H. Pesaran, P. Schmidt y M. Wickens (eds.), *The Handbook of Applied Econometrics*, Cap. 1, Oxford: Basil Blackwell, 12-72.

Maravall, A. (1999). "An Application of TRAMO and SEATS", Report for the Seasonal Adjustment Research Appraisal Project, Working Paper 9914. Aparece en *Seasonal Adjustment Procedures. Experiences and Perspectives*, Roma, ISTAT.

Maravall, A. (1999). "Short-Term Analysis of Macroeconomic Time Series", in A. Kirman y L.A. Gérard Varet (eds), *Economics: Beyond the Millennium*, Oxford: Oxford University Press.

Maravall, A. y D. Pierce (1987). "A Prototypical Seasonal Adjustment Model". *Journal of Time Series Analysis*, 8, pp. 177-193

Planas, Ch. (1997). "Applied Time Series Analysis: Modelling, Forecasting, Unobserved Components Analysis and the Wiener-Kolmogorov Filter", Eurostat.

Reinsel, G.C., (1997) . "Elements of Multivariate Time Series Analysis", segunda edición, Springer-Verlag, New York.

Soto, R. (2000). "Ajuste Estacional e Integración en Variables Macroeconómicas", Documento de Trabajo N° 73, Banco Central de Chile.

Schwert, G., W. (1989) . "Test for Unit Roots: A Monte Carlo Investigation", *Journal of Business and Economic Statistics*, 7, 118-124.

## **Direcciones URL de Interés**

Eurostat, en este sitio se encuentra documentos de investigación y la intarface DEMETRA de los programas TRAMO-SEATS y X12-ARIMA

<http://europa.eu.int/en/comm/eurostat/eurostat.html>

Se encuentra abundante literatura en texto completo sobre distintos métodos de desestacionalizacion.

<http://europa.eu.int/en/comm/eurostat/research/noris4/>

Banco de España, puede bajarse documentos y los programas TRAMO y SEATS

<http://www.bde.es>

Instituto de Econometría de la Erasmus University Rotterdam

<http://www.few.nl/few/research/pubs/ei/reports.htm>

U.S. Census Bureau; se puede bajar el programa X12-ARIMA y documentos de interés

<http://www.census.gov>

Instituto de Economía, University of Copenhagen

<http://www.econ.ku.dk>

Banco Central de Reserva del Perú, en la sección publicaciones se puede encontrar algunos documentos de trabajo sobre desestacionalización aplicado a variables económicas del Perú

<http://www.bcrp.gob.pe>

Oficina de Estadísticas de Canadá, Statistics Canada. Es de interés los documentos de Time Series Research and Analysis Division

<http://www.statcan.ca>

Home Pages de documentos de trabajo de economía

<http://netec.mcc.ac.uk/HoPEc.html>

# **ANEXOS**

## **Anexo 1**

# **Componentes No Observados de las Series Estimados por TRAMO-SEATS**

## Sector Real: Series Observadas y Componentes Estimados por TRAMO-SEATS

DATE	AGRP: Agropecuario, \$/ MM de 1994					PES: Pesca, \$/ MM de 1994					MIN: Minería, \$/ MM de 1994				
	Serie Original	Tendencia corto plazo	Desestacionalizada	Componente Estacional	Transitorio e Irregular	Serie Original	Tendencia corto plazo	Desestacionalizada	Componente Estacional	Transitorio e Irregular	Serie Original	Tendencia corto plazo	Desestacionalizada	Componente Estacional	Transitorio e Irregular
1-1990	1 463	1 652	1 630	89,79	99,86	198	157	157	41,02	0,03	872	878	883	98,74	100,54
2-1990	2 086	1 634	1 619	128,89	100,31	184	150	149	14,86	-0,58	887	888	877	98,83	98,81
3-1990	1 605	1 613	1 594	100,72	100,00	99	142	143	-44,59	0,86	922	899	912	101,02	101,45
4-1990	1 257	1 592	1 570	80,07	99,74	122	135	134	-11,50	-0,98	911	906	898	101,40	99,18
1-1991	1 403	1 572	1 562	89,84	100,48	148	125	128	19,51	3,34	886	915	913	97,03	99,81
2-1991	2 286	1 550	1 784	128,13	118,47	154	113	112	41,89	-1,27	939	927	934	100,58	100,77
3-1991	1 701	1 523	1 691	100,61	112,34	58	103	102	-43,91	-1,10	940	928	931	101,02	100,24
4-1991	1 281	1 496	1 578	81,17	106,77	88	101	100	-14,68	-0,88	934	924	921	101,40	99,67
1-1992	1 381	1 478	1 544	89,40	105,74	128	107	105	23,13	-2,75	909	924	921	98,74	99,71
2-1992	1 910	1 474	1 498	127,46	102,86	147	119	122	24,86	2,24	920	926	931	98,84	100,52
3-1992	1 487	1 492	1 496	99,42	101,44	97	130	132	-34,34	2,05	928	933	920	101,02	98,52
4-1992	1 286	1 531	1 556	82,80	102,82	195	135	194	1,22	59,00	974	951	960	101,41	101,04
1-1993	1 391	1 577	1 573	88,42	100,94	154	137	138	15,82	0,71	946	974	960	98,74	98,61
2-1993	2 076	1 634	1 611	128,88	99,78	157	142	139	18,00	-3,20	997	1 011	1 009	98,83	99,80
3-1993	1 691	1 703	1 720	98,33	102,17	105	152	152	-46,75	0,22	1 079	1 053	1 068	101,01	101,39
4-1993	1 456	1 763	1 752	83,10	100,52	172	164	164	8,88	0,08	1 090	1 083	1 074	101,41	99,17
1-1994	1 573	1 813	1 791	87,83	99,70	181	174	174	7,57	-0,24	1 092	1 118	1 116	97,88	99,82
2-1994	2 481	1 871	1 876	132,28	101,43	219	179	183	35,83	3,76	1 165	1 151	1 169	99,70	101,51
3-1994	1 800	1 924	1 869	96,29	98,32	125	178	175	-49,66	-2,86	1 173	1 162	1 162	101,01	99,96
4-1994	1 635	1 983	1 984	82,30	101,23	187	173	175	12,31	2,51	1 175	1 167	1 159	101,41	99,31
1-1995	1 779	2 031	2 024	87,93	100,82	175	184	164	11,11	-0,63	1 170	1 179	1 185	98,74	100,49
2-1995	2 745	2 058	2 026	135,48	99,60	180	157	154	25,69	-2,91	1 174	1 190	1 188	98,83	99,83
3-1995	1 995	2 074	2 074	96,21	101,20	102	154	155	-51,72	0,74	1 210	1 205	1 198	101,00	99,47
4-1995	1 647	2 078	2 040	80,72	99,31	181	151	152	9,15	0,86	1 251	1 223	1 233	101,42	100,85
1-1996	1 786	2 102	2 031	87,91	97,81	158	146	145	12,13	-0,32	1 212	1 233	1 228	98,75	99,18
2-1996	2 961	2 156	2 155	137,38	101,17	178	138	139	37,75	0,80	1 247	1 256	1 262	98,82	100,42
3-1996	2 079	2 206	2 191	94,91	100,49	77	127	127	-49,89	-0,48	1 287	1 275	1 275	101,00	99,95
4-1996	1 767	2 243	2 201	80,30	99,28	179	184	184	-5,35	-0,20	1 305	1 303	1 287	101,42	98,72
1-1997	2 055	2 275	2 270	90,51	100,97	159	171	171	-11,38	-0,68	1 322	1 344	1 363	97,04	101,40
2-1997	3 107	2 287	2 274	136,65	100,59	227	156	158	68,62	2,31	1 376	1 371	1 371	100,56	99,98
3-1997	2 067	2 285	2 236	92,44	99,00	92	135	136	-43,68	1,39	1 399	1 381	1 386	100,99	100,31
4-1997	1 831	2 288	2 267	80,77	100,24	100	113	109	-8,64	-4,18	1 406	1 384	1 366	101,43	100,20
1-1998	2 110	2 286	2 280	92,55	100,95	100	95	88	1,72	2,43	1 361	1 381	1 378	98,76	99,77
2-1998	3 005	2 273	2 223	135,15	98,97	122	81	80	43,02	-1,07	1 358	1 398	1 374	98,81	98,31
3-1998	2 054	2 270	2 243	91,56	99,98	118	160	159	-40,70	-0,72	1 469	1 446	1 455	100,99	100,56
4-1998	2 071	2 578	2 550	81,21	100,15	158	152	153	3,73	0,90	1 520	1 511	1 499	101,43	99,18
1-1999	2 370	2 584	2 554	92,78	99,99	136	146	146	-10,02	0,09	1 573	1 571	1 599	98,33	101,81
2-1999	3 468	2 598	2 561	135,43	99,76	183	142	141	42,17	-1,47	1 590	1 598	1 602	99,24	100,22
3-1999	2 359	2 622	2 582	91,37	99,82	102	141	143	-40,59	1,26	1 611	1 611	1 596	100,98	99,03
4-1999	2 128	2 664	2 620	81,21	99,53	221	141	206	15,87	64,77	1 671	1 636	1 647	101,44	100,89
1-2000	2 479	2 714	2 697	91,91	100,58	173	141	184	-11,09	42,78	1 638	1 649	1 658	98,76	100,59
2-2000	3 724	2 751	2 730	136,38	100,42	212	144	177	35,47	32,69	1 619	1 642	1 638	98,81	99,81
3-2000	2 520	2 768	2 743	91,89	100,24	124	148	169	-44,31	20,56	1 643	1 642	1 627	100,98	99,10
4-2000	2 246	2 787	2 748	81,72	100,48	191	154	170	20,77	16,33	1 700	1 643	1 676	101,45	102,01
1-2001	2 451	2 759	2 708	90,59	99,24	158	159	170	-11,30	10,68	1 579	1 627	1 599	98,76	98,28
2-2001	3 716	2 726	2 726	136,33	100,00	208	164	171	36,56	7,51	1 610	1 629	1 629	98,81	100,00
3-2001	2 516	2 732	2 732	92,14	100,00	128	169	174	-46,58	5,26	1 666	1 651	1 651	100,98	100,00
4-2001	2 247	2 739	2 739	82,06	100,00	199	174	177	21,32	3,68	1 698	1 674	1 674	101,45	100,00
1-2002	2 481	2 745	2 745	90,37	100,00	150	179	181	-31,53	2,58	1 647	1 697	1 697	97,04	100,00
2-2002	3 751	2 752	2 752	136,33	100,00	242	184	185	56,77	1,80	1 729	1 720	1 720	100,55	100,00
3-2002	2 541	2 758	2 758	92,14	100,00	143	189	190	-46,56	1,26	1 780	1 743	1 743	100,98	100,00
4-2002	2 269	2 765	2 765	82,06	100,00	216	193	184	21,32	0,88	1 793	1 767	1 767	101,45	100,00
1-2003	2 504	2 771	2 771	90,37	100,00	188	193	199	-11,32	0,62	1 769	1 791	1 791	98,75	100,00

## Sector Real: Series Observadas y Componentes Estimados por TRAMO-SEATS

MANUF, Manufactura, \$, MM de 1994						CONSTR: Construcción, \$, MM de 1994					COMERC: Comercio, \$, MM de 1994				
DATE	Original	Tendencia corto plazo	Desestacionalizada	Componente Estacional	Transitorio e Irregular	Serie Original	Tendencia corto plazo	Desestacionalizada	Componente Estacional	Transitorio e Irregular	Serie Original	Tendencia corto plazo	Desestacionalizada	Componente Estacional	Transitorio e Irregular
1-1990	3 771	3 644	3 698	72,53	53,88	941	986	863	-22,10	-2,66	3 354	3 238	3 312	41,88	74,03
2-1990	3 427	3 533	3 473	-45,75	-59,81	958	1 014	1 017	-59,12	2,66	3 333	3 004	2 988	345,58	-16,30
3-1990	2 652	3 482	2 708	-55,31	-774,61	842	846	828	15,83	-20,00	2 525	2 805	2 733	-208,19	-71,45
4-1990	2 987	3 533	2 937	29,40	-595,83	811	722	747	63,77	25,82	2 592	2 776	2 764	-171,64	-12,68
1-1991	3 351	3 619	3 300	51,13	-319,48	748	784	766	-20,63	-18,08	2 845	2 667	2 847	-1,68	-40,33
2-1991	3 345	3 658	3 389	-23,75	-289,43	797	841	856	-59,38	15,58	3 448	3 049	3 098	351,82	46,97
3-1991	3 449	3 612	3 498	-47,81	-115,25	903	867	884	18,95	16,58	3 012	3 104	3 171	-158,82	66,88
4-1991	3 359	3 495	3 318	40,81	-177,52	805	869	845	60,40	-23,94	2 841	3 055	2 990	-148,32	-65,78
1-1992	3 322	3 387	3 311	11,38	-75,74	882	874	901	-18,88	27,23	3 023	3 001	3 076	-53,89	75,17
2-1992	3 229	3 299	3 233	-3,79	-66,12	787	859	848	-61,78	-10,64	3 203	2 844	2 868	334,51	-75,79
3-1992	3 107	3 288	3 157	-49,97	-110,47	861	841	839	21,55	-1,84	2 831	2 974	2 965	-133,95	-9,10
4-1992	3 400	3 300	3 342	58,07	42,43	897	886	837	60,44	-29,28	2 983	3 016	3 104	-120,75	88,43
1-1993	3 209	3 313	3 235	-26,76	-77,43	930	935	951	-21,83	16,22	2 809	2 877	2 904	-94,85	-72,78
2-1993	3 375	3 363	3 352	22,47	-11,22	937	1 008	1 002	-85,01	-5,86	3 343	3 026	2 997	345,87	-29,00
3-1993	3 405	3 438	3 455	-50,05	19,09	1 103	1 080	1 078	25,30	17,68	3 082	3 161	3 209	-127,17	48,47
4-1993	3 512	3 510	3 443	68,82	-67,17	1 154	1 114	1 083	70,33	-31,10	3 118	3 253	3 237	-118,67	-15,79
1-1994	3 806	3 675	3 669	-62,39	-6,09	1 181	1 198	1 212	-30,93	14,21	3 214	3 354	3 333	-119,55	-21,17
2-1994	3 941	3 864	3 898	42,29	33,94	1 213	1 301	1 283	-70,68	-17,92	3 895	3 508	3 514	381,41	5,88
3-1994	3 930	4 013	3 978	-47,98	-34,82	1 450	1 425	1 424	25,32	-1,32	3 534	3 679	3 673	-138,95	-5,93
4-1994	4 271	4 130	4 187	83,85	58,95	1 853	1 537	1 568	65,05	31,41	3 721	3 843	3 854	-139,09	11,00
1-1995	4 071	4 171	4 180	-89,25	-11,28	1 546	1 800	1 585	-39,05	-14,90	3 863	3 957	3 991	-128,82	-34,39
2-1995	4 227	4 165	4 172	54,82	7,13	1 586	1 629	1 659	-78,63	30,73	4 420	4 021	3 989	430,84	-31,98
3-1995	4 103	4 146	4 150	-48,80	3,25	1 833	1 817	1 808	24,95	-8,37	3 950	4 062	4 110	-180,58	48,45
4-1995	4 204	4 125	4 110	93,92	-14,87	1 884	1 582	1 588	98,11	6,53	3 885	4 043	4 036	-151,34	-6,30
1-1996	4 010	4 129	4 128	-115,58	-3,00	1 493	1 557	1 540	-48,54	-17,25	3 845	4 023	3 984	-139,33	-38,65
2-1996	4 216	4 189	4 150	65,73	-18,82	1 477	1 557	1 557	-79,89	0,25	4 582	4 048	4 081	481,55	34,55
3-1996	4 203	4 240	4 248	-43,10	5,98	1 597	1 583	1 571	25,79	-11,38	3 847	4 084	4 037	-190,08	-47,73
4-1996	4 419	4 292	4 317	102,05	24,21	1 735	1 635	1 629	105,95	-6,20	4 008	4 180	4 177	-169,49	-2,12
1-1997	4 155	4 361	4 288	-132,92	-73,58	1 658	1 712	1 708	-49,78	-3,81	4 177	4 324	4 319	-142,82	-4,27
2-1997	4 820	4 453	4 549	71,34	95,67	1 711	1 785	1 789	-88,45	14,08	5 000	4 415	4 478	523,97	60,89
3-1997	4 387	4 470	4 427	-39,94	-42,86	1 881	1 841	1 831	29,48	-9,52	4 185	4 401	4 389	-204,71	-11,84
4-1997	4 583	4 437	4 475	108,31	38,00	2 013	1 868	1 898	115,01	31,75	4 170	4 339	4 347	-177,07	7,90
1-1998	4 233	4 389	4 389	-136,58	0,38	1 785	1 842	1 836	-50,93	-8,42	4 122	4 275	4 268	-146,20	-7,64
2-1998	4 327	4 328	4 260	86,85	-68,48	1 897	1 795	1 795	-98,81	0,15	4 751	4 221	4 216	534,88	-4,86
3-1998	4 370	4 308	4 415	-45,14	107,15	1 984	1 751	1 950	33,59	199,22	3 966	4 179	4 182	-218,05	2,75
4-1998	4 259	4 210	4 145	113,89	-64,59	1 623	1 892	1 705	118,50	12,90	3 959	4 128	4 138	-179,01	10,18
1-1999	4 007	4 155	4 134	-126,15	-21,36	1 558	1 831	1 805	-48,89	-25,90	3 916	4 078	4 055	-136,90	-22,74
2-1999	4 270	4 192	4 208	63,14	13,98	1 497	1 809	1 805	-108,21	-4,01	4 807	4 079	4 084	542,79	-15,12
3-1999	4 157	4 300	4 223	-85,86	-78,70	1 857	1 835	1 819	37,79	-16,19	3 900	4 144	4 132	-232,57	-11,96
4-1999	4 661	4 487	4 544	117,24	58,85	1 811	1 874	1 895	115,58	21,47	4 057	4 242	4 248	-191,19	6,44
1-2000	4 531	4 806	4 640	-109,15	33,89	1 643	1 681	1 685	-42,28	24,54	4 220	4 326	4 341	-120,82	14,33
2-2000	4 675	4 594	4 603	71,55	9,55	1 488	1 801	1 576	-110,45	-24,99	4 939	4 354	4 379	560,66	25,08
3-2000	4 451	4 534	4 528	-77,82	-5,31	1 609	1 532	1 566	42,67	34,35	4 079	4 328	4 319	-240,55	-8,25
4-2000	4 584	4 488	4 472	111,70	-15,64	1 525	1 457	1 418	107,33	-39,20	4 084	4 313	4 291	-207,57	-21,30
1-2001	4 368	4 479	4 477	-108,69	-2,24	1 383	1 418	1 425	-41,37	6,81	4 228	4 336	4 346	-117,70	9,67
2-2001	4 563	4 489	4 489	74,00	0,00	1 294	1 404	1 404	-110,47	0,00	4 829	4 362	4 362	567,33	0,00
3-2001	4 425	4 501	4 501	-78,33	0,00	1 430	1 384	1 384	46,32	0,00	4 139	4 379	4 379	-239,88	0,00
4-2001	4 625	4 513	4 513	111,14	0,00	1 489	1 383	1 383	105,25	0,00	4 185	4 396	4 396	-210,48	0,00
1-2002	4 417	4 528	4 528	-108,80	0,00	1 302	1 343	1 343	-41,10	0,00	4 296	4 412	4 412	-118,98	0,00
2-2002	4 812	4 538	4 538	74,00	0,00	1 212	1 323	1 323	-110,47	0,00	4 997	4 429	4 429	567,33	0,00
3-2002	4 473	4 550	4 550	-76,33	0,00	1 349	1 02	1 302	48,32	0,00	4 206	4 446	4 446	-239,89	0,00
4-2002	4 673	4 562	4 562	111,14	0,00	1 387	1 282	1 282	105,25	0,00	4 252	4 463	4 463	-210,48	0,00
1-2003	4 465	4 574	4 574	-108,80	0,00	1 221	1 282	1 282	-41,10	0,00	4 363	4 480	4 480	-118,87	0,00

## Sector Real: Series Observadas y Componentes Estimados por TRAMO-SEATS

OTROS: \$/ MM de 1994						PIB94: PBI Global. \$/ MM de 1994				
DATE	Serie Original	Tendencia corto plazo	Desestacionalizada	Componente Estacional	Transitorio e Irregular	Serie Original	Tendencia corto plazo	Desestacionalizada	Componente Estacional	Transitorio e Irregular
1-1990	11 288	11 666	11 767	-478,49	100,95	21 887	22 246	22 522	-635,31	276,92
2-1990	10 983	11 435	11 326	-343,25	-109,31	21 818	21 674	21 382	435,52	-291,31
3-1990	9 919	11 339	9 936	-17,72	-1402,63	18 364	21 421	18 575	-211,88	-2845,22
4-1990	11 254	11 348	10 429	824,98	-919,15	19 914	21 489	19 512	402,12	-1977,39
1-1991	10 086	11 366	10 618	-532,30	-747,47	19 464	21 695	20 191	-728,94	-1503,98
2-1991	10 751	11 441	11 007	-255,89	-433,85	21 720	21 986	21 173	546,93	-812,90
3-1991	11 200	11 463	11 189	11,40	-276,85	21 264	21 930	21 432	-168,56	-497,78
4-1991	11 906	11 390	11 128	777,92	-262,84	21 311	21 567	20 909	401,81	-658,32
1-1992	10 587	11 310	11 170	-583,32	-139,93	20 231	21 227	21 075	-844,14	-152,23
2-1992	10 942	11 223	11 117	-174,83	-105,89	21 136	20 893	20 506	830,12	-386,25
3-1992	11 050	11 178	11 032	17,75	-145,29	20 362	20 875	20 540	-177,69	-334,98
4-1992	11 932	11 213	11 215	716,96	2,25	21 670	21 112	21 268	402,41	156,25
1-1993	10 567	11 313	11 176	-609,35	-136,28	20 007	21 254	20 948	-940,76	-306,21
2-1993	11 425	11 489	11 538	-112,34	48,87	22 311	21 641	21 551	759,83	-90,49
3-1993	11 662	11 649	11 616	46,14	-33,30	22 127	22 218	22 312	-185,22	94,14
4-1993	12 427	11 762	11 776	651,54	13,70	22 929	22 666	22 577	352,34	-88,85
1-1994	11 252	11 950	11 839	-586,85	-111,38	22 100	23 268	23 103	-1002,60	-165,88
2-1994	12 202	12 328	12 305	-102,59	-22,98	25 116	24 177	24 215	901,28	38,48
3-1994	12 877	12 813	12 834	42,65	20,69	24 889	25 175	25 121	-232,41	-53,38
4-1994	13 831	13 264	13 263	567,77	-0,56	28 472	26 085	26 202	269,84	116,36
1-1995	13 196	13 528	13 690	-493,75	162,60	25 800	26 622	26 794	-994,01	172,34
2-1995	13 428	13 581	13 465	-37,01	-116,57	27 759	26 794	26 677	1081,93	-116,81
3-1995	13 703	13 586	13 691	11,33	105,66	26 697	26 828	27 001	-304,18	173,44
4-1995	13 936	13 598	13 483	453,32	-114,79	28 768	26 754	26 614	153,70	-139,92
1-1996	13 241	13 750	13 712	-470,73	-38,31	25 745	26 918	26 759	-1013,93	-158,83
2-1996	14 126	13 969	14 083	43,33	114,12	28 765	27 313	27 515	1250,22	202,19
3-1996	13 995	14 090	14 005	-10,83	-84,32	27 085	27 812	27 460	-374,83	-152,78
4-1996	14 675	14 232	14 259	416,21	26,33	28 087	27 988	28 001	86,27	12,59
1-1997	13 942	14 494	14 387	-444,93	-107,34	27 468	28 656	28 461	-992,83	-195,41
2-1997	14 967	14 799	14 929	37,73	130,59	31 010	29 290	29 684	1325,84	393,88
3-1997	14 916	15 001	14 944	-27,68	-56,85	28 907	29 497	29 329	-421,50	-188,80
4-1997	15 594	15 085	15 179	414,87	94,38	29 697	29 479	29 633	64,01	194,29
1-1998	14 682	15 021	15 033	-351,26	12,01	28 392	29 257	29 309	-916,15	51,84
2-1998	14 803	14 937	14 827	-23,54	-109,50	30 082	29 088	28 758	1304,20	-310,33
3-1998	14 977	14 963	15 036	-59,85	73,85	28 937	29 189	29 422	-485,09	292,46
4-1998	15 305	14 990	14 944	360,54	-46,46	29 094	29 183	29 074	19,36	-108,30
1-1999	14 801	14 971	15 039	-237,86	68,22	28 361	29 129	29 160	-799,76	31,08
2-1999	14 845	14 941	14 860	-15,57	-80,91	30 458	29 166	29 116	1342,12	-49,56
3-1999	14 897	15 027	14 993	-95,63	-34,56	28 583	29 447	29 256	-573,48	-190,29
4-1999	15 510	15 220	15 249	261,43	28,35	30 060	30 037	30 135	-75,81	97,95
1-2000	15 220	15 371	15 390	-169,91	18,13	29 903	30 517	30 617	-714,14	99,26
2-2000	15 519	15 399	15 461	58,74	61,81	32 154	30 562	30 708	1446,38	145,55
3-2000	15 196	15 275	15 291	-94,91	15,41	29 823	30 222	30 221	-598,16	-0,81
4-2000	15 229	15 148	15 054	175,42	-93,92	29 559	29 897	29 725	-166,14	-171,43
1-2001	15 007	15 148	15 176	-168,50	27,89	29 176	29 887	29 894	-717,60	26,35
2-2001	15 270	15 183	15 183	87,25	0,00	31 429	29 950	29 950	1478,64	0,00
3-2001	15 113	15 194	15 194	-80,62	0,00	29 425	30 008	30 008	-682,93	0,00
4-2001	15 383	15 204	15 204	158,58	0,00	29 887	30 066	30 066	-179,75	0,00
1-2002	15 050	15 215	15 215	-165,20	0,00	29 409	30 125	30 125	-715,95	0,00
2-2002	15 313	15 225	15 225	87,25	0,00	31 861	30 183	30 183	1478,64	0,00
3-2002	15 155	15 236	15 236	-80,62	0,00	29 658	30 241	30 241	-582,93	0,00
4-2002	15 405	15 246	15 246	158,58	0,00	30 119	30 299	30 299	-179,75	0,00
1-2003	15 092	15 257	15 257	-165,20	0,00	29 641	30 357	30 357	-715,95	0,00

## Sector Monetario: Series Observadas y Componentes Estimados por TRAMO-SEATS

LIQ_MN_N: Liquidez en M/N Nominal, Promedio, S/, MM						EPRIM_N: Saldo de Emisión Primaria Nominal, Promedio, S/,					LIQ_MN_R: Liquidez en M/N Real, Promedio, S/, MM de 1994				
DATE	Serie Original	Tendencia corto plazo	Desestaciona nalizada	Componente Estacional	Transitorio e Irregular	Serie Original	Tendencia corto plazo	Desestaciona nalizada	Componente Estacional	Transitorio e Irregular	Serie Original	Tendencia corto plazo	Desestaciona nalizada	Componente Estacional	Transitorio e Irregular
1-1990	21	-1	21	0,00	21,26	11	-12	-8	18,41	4,51	5 223	1 713	5 223	0,00	3509,35
2-1990	42	50	42	0,00	-8,27	24	58	60	-35,73	2,30	4 314	1 852	4 314	0,00	2461,82
3-1990	173	198	173	0,00	-24,97	126	168	146	-17,42	-22,50	2 077	1 958	2 077	0,00	120,46
4-1990	489	454	489	0,00	35,20	366	330	356	31,67	25,91	3 275	2 078	3 275	0,00	1197,00
1-1991	603	632	603	0,00	-28,97	453	454	437	15,92	-16,60	2 893	2 287	2 893	0,00	406,13
2-1991	659	643	659	0,00	15,85	550	570	580	-30,69	10,21	3 093	2 485	3 093	0,00	607,90
3-1991	1 078	1 088	1 078	0,00	-9,92	666	672	673	-7,11	0,99	3 073	2 693	3 073	0,00	379,47
4-1991	1 345	1 343	1 345	0,00	1,80	767	749	746	21,31	-3,54	3 349	3 042	3 349	0,00	307,02
1-1992	1 594	1 585	1 594	0,00	9,23	864	855	852	11,79	-3,00	3 493	3 265	3 493	0,00	227,80
2-1992	1 760	1 794	1 760	0,00	-13,49	952	977	982	-29,71	4,73	3 433	3 323	3 433	0,00	109,47
3-1992	2 013	1 993	2 013	0,00	-19,95	1 086	1 082	1 082	4,10	0,07	3 525	3 389	3 525	0,00	136,45
4-1992	2 193	2 226	2 193	0,00	-33,73	1 212	1 211	1 199	12,88	-12,38	3 481	3 454	3 481	0,00	27,16
1-1993	2 542	2 504	2 542	0,00	38,22	1 410	1 393	1 401	9,19	7,74	3 590	3 487	3 590	0,00	102,90
2-1993	2 688	2 717	2 688	0,00	-29,16	1 499	1 515	1 532	-33,49	17,66	3 413	3 424	3 413	0,00	-11,07
3-1993	2 962	2 945	2 962	0,00	16,97	1 570	1 568	1 549	21,30	-19,60	3 504	3 466	3 504	0,00	36,04
4-1993	3 294	3 332	3 294	0,00	-38,13	1 691	1 676	1 680	10,95	4,52	3 695	3 699	3 695	0,00	-4,59
1-1994	3 874	3 841	3 874	0,00	33,43	1 818	1 821	1 820	-1,62	-0,96	4 094	4 087	4 094	0,00	7,32
2-1994	4 519	4 600	4 519	0,00	-81,49	1 952	2 019	2 000	-47,92	-19,56	4 564	4 541	4 564	0,00	23,16
3-1994	5 562	5 452	5 562	0,00	110,16	2 342	2 282	2 302	40,62	19,32	5 448	5 431	5 448	0,00	17,03
4-1994	5 918	5 991	5 918	0,00	-73,14	2 515	2 505	2 500	15,61	-5,24	5 674	5 705	5 674	0,00	-30,28
1-1995	6 480	6 420	6 480	0,00	59,28	2 707	2 721	2 714	-6,56	-7,06	6 067	6 016	6 067	0,00	51,72
2-1995	6 958	7 044	6 958	0,00	-86,34	2 914	2 965	2 974	-60,40	9,15	6 317	6 394	6 317	0,00	-76,52
3-1995	7 796	7 687	7 796	0,00	109,41	3 217	3 159	3 163	53,79	4,40	6 924	6 827	6 924	0,00	87,06
4-1995	7 986	8 062	7 986	0,00	-76,04	3 304	3 279	3 284	19,86	5,19	6 944	6 996	6 944	0,00	-53,44
1-1996	8 526	8 495	8 526	0,00	30,36	3 356	3 368	3 361	-5,19	-5,13	7 161	7 141	7 161	0,00	19,91
2-1996	9 003	9 004	9 003	0,00	-0,47	3 392	3 487	3 466	-74,35	-0,73	7 344	7 341	7 344	0,00	3,88
3-1996	9 324	9 311	9 324	0,00	12,86	3 616	3 547	3 559	56,97	12,31	7 408	7 408	7 408	0,00	4,55
4-1996	9 585	9 608	9 585	0,00	-22,80	3 632	3 634	3 607	24,74	-27,15	7 467	7 467	7 467	0,00	-14,94
1-1997	9 944	9 913	9 944	0,00	30,81	3 787	3 760	3 788	-1,81	28,23	7 600	7 577	7 600	0,00	22,50
2-1997	10 283	10 349	10 283	0,00	-66,42	3 763	3 877	3 850	-86,63	-26,75	7 694	7 738	7 694	0,00	-43,92
3-1997	11 181	11 157	11 181	0,00	23,65	4 104	4 036	4 046	57,84	10,09	8 197	8 198	8 197	0,00	-0,78
4-1997	12 005	11 991	12 005	0,00	13,88	4 253	4 223	4 219	33,59	-3,59	8 740	8 705	8 740	0,00	35,23
1-1998	12 576	12 575	12 576	0,00	0,94	4 393	4 394	4 395	-1,93	0,98	8 921	8 927	8 921	0,00	-5,82
2-1998	12 889	12 837	12 889	0,00	52,41	4 424	4 494	4 518	-94,05	23,74	8 920	8 886	8 920	0,00	34,86
3-1998	12 534	12 518	12 534	0,00	16,43	4 535	4 485	4 471	64,15	-13,38	8 574	8 579	8 574	0,00	-4,63
4-1998	12 070	12 143	12 070	0,00	-73,50	4 536	4 498	4 492	46,02	-5,79	8 288	8 325	8 288	0,00	-37,45
1-1999	12 158	12 096	12 158	0,00	61,66	4 546	4 550	4 561	-15,02	11,56	8 277	8 234	8 277	0,00	43,58
2-1999	12 212	12 318	12 212	0,00	-106,67	4 499	4 640	4 609	-110,13	-30,72	8 193	6 271	8 193	0,00	-78,26
3-1999	13 057	13 002	13 057	0,00	54,42	4 930	4 851	4 860	70,41	8,58	8 689	8 653	8 689	0,00	36,27
4-1999	13 503	13 457	13 503	0,00	48,11	5 112	5 024	5 050	62,38	25,49	8 935	8 899	8 935	0,00	35,87
1-2000	13 293	13 314	13 293	0,00	-20,56	5 021	5 051	5 039	-16,61	-12,12	8 713	8 728	8 713	0,00	-15,12
2-2000	13 260	13 291	13 260	0,00	-30,32	4 948	5 055	5 061	-112,46	5,25	8 600	8 619	8 600	0,00	-19,45
3-2000	13 603	13 590	13 603	0,00	13,14	5 135	5 083	5 062	72,31	-0,30	8 729	8 722	8 729	0,00	6,82
4-2000	13 810	13 784	13 810	0,00	26,40	5 122	5 065	5 062	60,34	-3,43	8 787	8 768	8 787	0,00	18,57
1-2001	13 824	13 866	13 824	0,00	-42,44	5 079	5 113	5 105	-25,90	-8,15	8 739	8 774	8 739	0,00	-34,96
2-2001	14 177	14 184	14 177	0,00	12,98	5 101	5 206	5 211	-109,88	4,70	8 962	8 949	8 962	0,00	13,67
3-2001	14 540	14 524	14 540	0,00	0,00	5 372	5 296	5 296	75,92	0,00	9 158	9 151	9 158	0,00	0,00
4-2001	14 655	14 833	14 655	0,00	0,00	5 432	5 371	5 371	61,01	0,00	9 306	9 298	9 306	0,00	0,00
1-2002	15 169	15 147	15 169	0,00	0,00	5 420	5 447	5 447	-27,13	0,00	9 453	9 448	9 453	0,00	0,00
2-2002	15 484	15 464	15 484	0,00	0,00	5 413	5 523	5 523	-109,80	0,00	9 601	9 599	9 601	0,00	0,00
3-2002	15 799	15 780	15 799	0,00	0,00	5 674	5 598	5 598	75,92	0,00	9 749	9 748	9 749	0,00	0,00
4-2002	16 113	16 095	16 113	0,00	0,00	5 736	5 674	5 674	61,01	0,00	9 897	9 896	9 897	0,00	0,00
1-2003	16 428	16 410	16 428	0,00	0,00	5 722	5 750	5 750	-27,13	0,00	10 044	10 044	10 044	0,00	0,00
2-2003	16 742	16 724	16 742	0,00	0,00	5 715	5 825	5 825	-109,80	0,00	10 182	10 192	10 182	0,00	0,00

## Sector Monetario: Series Observadas y Componentes Estimados por TRAMO-SEATS

EPRIM\_R: Emisión Primaria Real, Promedio, \$/ MM de 1994

DATE	Serie Original	Tendencia corto plazo	Desestacionalizada	Componente Estacional	Transitorio e irregular
1-1990	2 715	2 671	2 680	34,46	9,71
2-1990	2 473	2 543	2 531	-57,87	-11,40
3-1990	1 544	2 517	1 550	-6,07	-966,73
4-1990	2 596	2 567	2 568	27,53	1,69
1-1991	2 025	1 999	1 992	32,44	-6,65
2-1991	1 980	2 014	2 034	-53,66	19,63
3-1991	1 899	1 919	1 901	-1,50	-18,22
4-1991	1 910	1 875	1 866	24,68	10,26
1-1992	1 894	1 874	1 867	20,88	-7,56
2-1992	1 836	1 886	1 889	-53,30	3,38
3-1992	1 902	1 896	1 898	4,72	1,20
4-1992	1 924	1 905	1 900	24,23	-5,29
1-1993	1 991	1 966	1 969	21,87	2,71
2-1993	1 903	1 947	1 958	-54,59	10,57
3-1993	1 857	1 859	1 844	12,75	-14,67
4-1993	1 897	1 866	1 873	24,39	6,74
1-1994	1 921	1 910	1 907	14,20	-3,33
2-1994	1 972	2 041	2 030	-58,74	-11,00
3-1994	2 295	2 258	2 273	21,82	14,49
4-1994	2 412	2 392	2 385	28,90	-7,08
1-1995	2 535	2 526	2 526	9,09	-0,31
2-1995	2 646	2 706	2 708	-62,27	1,78
3-1995	2 857	2 825	2 829	28,14	4,61
4-1995	2 874	2 843	2 844	29,08	1,91
1-1996	2 819	2 815	2 812	6,49	-2,70
2-1996	2 767	2 836	2 833	-66,32	-2,88
3-1996	2 873	2 831	2 843	30,36	11,72
4-1996	2 829	2 817	2 798	31,43	-19,49
1-1997	2 894	2 870	2 889	5,30	18,63
2-1997	2 816	2 901	2 886	-69,87	-14,92
3-1997	3 009	2 971	2 977	31,71	6,00
4-1997	3 096	3 061	3 061	35,01	0,30
1-1998	3 116	3 114	3 112	3,88	-1,84
2-1998	3 062	3 125	3 134	-72,36	8,65
3-1998	3 102	3 076	3 069	33,82	-7,73
4-1998	3 116	3 078	3 078	38,27	0,23
1-1999	3 095	3 090	3 096	-0,34	5,90
2-1999	3 015	3 106	3 094	-75,45	-12,68
3-1999	3 281	3 240	3 244	38,66	4,28
4-1999	3 383	3 332	3 341	41,58	9,52
1-2000	3 291	3 301	3 294	-2,87	-7,69
2-2000	3 209	3 280	3 265	-75,45	4,68
3-2000	3 295	3 258	3 256	38,54	-1,69
4-2000	3 259	3 217	3 218	40,84	1,20
1-2001	3 211	3 224	3 217	-5,93	-6,88
2-2001	3 225	3 295	3 299	-74,80	4,18
3-2001	3 396	3 366	3 356	40,13	0,00
4-2001	3 425	3 384	3 384	41,24	0,00
1-2002	3 405	3 412	3 412	-8,50	0,00
2-2002	3 385	3 440	3 440	-74,87	0,00
3-2002	3 508	3 468	3 468	40,13	0,00
4-2002	3 537	3 498	3 496	41,24	0,00
1-2003	3 518	3 524	3 524	-8,50	0,00
2-2003	3 477	3 552	3 552	-74,87	0,00

## Sector Fiscal: Series Observadas y Componentes Estimados por TRAMO-SEATS

ITRIB_R: Ingresos Tributarios, \$/ MM de 1994						IMP_ING_R: Impuestos a los Ingresos, \$/ MM de 1994					IMP_IMP_R: Impuestos a las Importaciones, \$/ MM de 1994				
DATE	Serie Original	Tendencia corto plazo	Desestaciona nalizada	Componente Estacional	Transitorio e Irregular	Serie Original	Tendencia corto plazo	Desestaciona nalizada	Componente Estacional	Transitorio e Irregular	Serie Original	Tendencia corto plazo	Desestaciona nalizada	Componente Estacional	Transitorio e Irregular
1-1990	1 833	1 813	1 818	15,19	5,03	256	212	218	117,35	102,86	389	394	408	-18,11	13,09
2-1990	1 952	1 886	1 886	66,78	-0,48	230	202	196	116,90	97,25	351	373	360	-8,87	-13,09
3-1990	1 847	1 973	1 943	-100,50	-25,67	97	197	121	80,24	61,21	210	215	202	7,37	-12,65
4-1990	2 734	2 084	2 729	5,07	645,11	173	197	199	86,90	100,91	277	237	258	19,60	20,59
1-1991	2 217	2 203	2 203	9,54	4,86	224	199	194	115,66	97,23	213	248	231	-18,13	-16,60
2-1991	2 360	2 309	2 319	40,76	10,34	252	204	212	118,95	103,69	262	266	271	-8,83	5,06
3-1991	2 410	2 385	2 409	1,25	23,73	165	205	203	81,22	96,50	298	277	290	7,40	13,43
4-1991	2 392	2 428	2 425	-32,86	-3,15	178	213	206	86,49	96,66	276	277	258	19,55	-20,84
1-1992	2 448	2 454	2 450	-2,05	-3,41	271	233	240	112,94	103,05	286	281	304	-18,16	23,89
2-1992	2 504	2 474	2 475	29,07	1,56	428	363	360	119,13	98,94	249	279	258	-8,77	-21,04
3-1992	2 452	2 490	2 495	-43,07	5,04	324	383	391	82,77	102,18	303	294	296	7,41	2,00
4-1992	2 540	2 504	2 510	30,34	6,03	348	394	392	88,29	99,49	345	328	325	19,51	-0,29
1-1993	2 527	2 527	2 519	8,16	-6,04	442	402	403	109,75	100,11	338	353	353	-18,20	3,58
2-1993	2 615	2 576	2 565	49,90	-11,01	488	414	413	117,78	99,58	364	374	373	-8,68	-0,83
3-1993	2 516	2 668	2 633	-121,85	-29,89	360	443	430	83,75	96,98	400	387	393	7,42	6,28
4-1993	2 807	2 806	2 799	7,60	-8,63	455	493	505	90,08	102,29	407	393	386	19,48	-5,56
1-1994	3 061	2 974	2 990	70,82	15,98	578	546	544	106,32	99,42	387	404	405	-18,28	0,90
2-1994	3 187	3 136	3 141	46,77	4,75	708	804	599	118,15	99,05	410	417	418	-8,59	1,78
3-1994	3 194	3 284	3 287	-93,45	2,92	584	689	683	85,49	102,00	432	429	425	7,43	-4,06
4-1994	3 408	3 416	3 424	-16,17	6,49	654	716	719	80,88	100,27	467	450	447	19,46	-2,65
1-1995	3 559	3 520	3 539	20,50	19,04	770	749	747	103,01	99,68	462	475	481	-18,36	5,88
2-1995	3 716	3 600	3 583	133,15	-16,90	931	774	783	118,98	101,01	482	489	490	-8,50	1,13
3-1995	3 537	3 671	3 679	-141,45	7,65	684	790	785	87,04	99,31	503	486	495	7,43	9,56
4-1995	3 770	3 731	3 739	30,90	7,35	734	806	807	90,95	100,07	482	467	462	19,46	-5,28
1-1996	3 582	3 789	3 756	-174,16	-33,32	826	838	823	100,40	98,10	432	459	450	-16,45	-9,11
2-1996	4 297	3 850	3 893	404,77	42,30	1 425	899	1 193	119,38	132,59	466	466	474	-8,44	6,43
3-1996	3 657	3 897	3 882	-224,64	-15,78	864	961	981	88,07	101,93	472	469	465	7,43	-3,59
4-1996	3 818	3 954	3 909	-90,79	-45,44	906	995	988	91,70	99,23	490	465	470	19,48	4,78
1-1997	3 995	4 036	4 055	-59,88	18,48	1 016	1 033	1 020	99,61	98,58	437	456	456	-18,51	-0,13
2-1997	4 461	4 099	4 129	331,63	29,78	1 310	1 070	1 107	118,41	103,24	434	448	442	-8,38	-5,73
3-1997	3 946	4 124	4 111	-164,53	-12,99	929	1 071	1 053	88,21	98,27	459	458	452	7,41	-5,93
4-1997	4 042	4 123	4 131	-89,61	8,27	992	1 056	1 069	92,77	101,08	504	481	485	19,48	4,03
1-1998	4 099	4 096	4 100	-0,91	3,65	1 035	1 037	1 034	100,18	99,49	483	505	502	-18,57	-3,19
2-1998	4 174	4 038	4 050	124,15	12,07	1 174	1 025	1 013	115,94	98,64	523	519	531	-8,31	12,80
3-1998	3 980	3 943	3 975	4,48	32,13	915	1 023	1 042	87,89	101,69	518	503	511	7,42	7,69
4-1998	3 686	3 824	3 799	-113,01	-25,37	938	996	1 000	93,89	100,23	478	472	459	19,49	-12,69
1-1999	3 783	3 718	3 715	67,97	-2,21	968	927	952	101,69	102,49	440	461	458	-18,63	-2,94
2-1999	3 658	3 646	3 618	41,86	-30,23	946	851	822	115,08	98,37	461	469	469	-8,28	0,58
3-1999	3 444	3 627	3 594	-149,50	-33,35	711	822	818	86,91	99,35	485	481	478	7,40	-3,65
4-1999	3 764	3 648	3 677	87,41	28,53	776	823	835	92,96	101,21	521	487	501	19,53	14,04
1-2000	3 671	3 667	3 677	-6,50	10,32	832	829	813	102,38	97,94	449	481	468	-18,66	-12,58
2-2000	3 803	3 668	3 685	118,68	16,87	1 007	840	861	116,99	102,33	477	474	485	-8,27	11,12
3-2000	3 492	3 656	3 650	-157,86	-6,07	724	835	835	86,79	99,79	466	467	458	7,39	-9,08
4-2000	3 662	3 649	3 637	25,74	-12,58	749	828	817	91,73	98,48	487	464	468	19,54	3,67
1-2001	3 667	3 656	3 657	9,74	1,90	868	838	848	102,41	101,06	443	465	462	-18,67	-2,56
2-2001	3 741	3 670	3 670	70,86	0,37	995	844	844	117,90	100,00	459	467	467	-8,26	0,00
3-2001	3 612	3 687	3 687	-75,30	-0,17	730	841	841	86,81	100,00	479	472	472	7,38	0,00
4-2001	3 715	3 709	3 709	6,13	0,07	786	839	839	91,34	100,00	498	478	476	19,55	0,00
1-2002	3 740	3 734	3 734	5,95	-0,03	857	836	836	102,54	100,00	462	481	481	-18,67	0,00
2-2002	3 797	3 781	3 782	35,53	0,01	983	833	833	117,90	100,00	478	486	486	-8,26	0,00
3-2002	3 754	3 791	3 791	-37,76	-0,01	721	831	831	86,81	100,00	498	491	491	7,38	0,00
4-2002	3 826	3 823	3 823	3,07	0,00	756	828	828	91,34	100,00	515	495	495	19,55	0,00
1-2003	3 859	3 856	3 856	2,98	0,00	847	826	826	102,54	100,00	481	500	500	-18,67	0,00

## Sector Fiscal: Series Observadas y Componentes Estimados por TRAMO-SEATS

DATE	IGV_R: Recaudación de IGV, S/. MM de 1994					ISC_R: Recaudación por ISC, S/. MM de 1994					
	Serie Original	Tendencia corto plazo	Desestacionalizada	Componente Estacional	Transitorio e Irregular	Serie Original	Tendencia corto plazo	Desestacionalizada	Componente Estacional	Transitorio e Irregular	
1-1990	597		596	597	0,00	1,23	341	1	341	100,00	55,66
2-1990	618		620	618	0,00	-1,88	471	1	471	100,00	76,91
3-1990	311		670	311	0,00	-359,32	781	1	781	100,00	124,18
4-1990	502		716	502	0,00	-214,28	1 067	1	1 067	100,00	174,04
1-1991	518		695	518	0,00	-176,83	961	1	961	100,00	156,83
2-1991	536		665	536	0,00	-129,00	948	1	948	100,00	154,58
3-1991	606		699	606	0,00	-93,45	973	1	973	100,00	158,81
4-1991	717		760	717	0,00	-43,83	937	1	937	100,00	152,89
1-1992	746		785	746	0,00	-38,49	839	1	839	100,00	138,85
2-1992	751		785	751	0,00	-33,74	784	1	784	100,00	127,98
3-1992	780		803	780	0,00	-23,01	781	1	781	100,00	127,46
4-1992	835		860	835	0,00	-24,23	806	1	806	100,00	131,42
1-1993	952		968	952	0,00	-16,16	543	1	543	100,00	88,51
2-1993	1 088		1 067	1 088	0,00	21,45	455	1	455	100,00	74,23
3-1993	1 091		1 120	1 091	0,00	-29,05	456	1	456	100,00	74,41
4-1993	1 212		1 224	1 212	0,00	-11,85	542	1	542	100,00	88,38
1-1994	1 375		1 349	1 375	0,00	26,66	577	1	577	100,00	94,09
2-1994	1 403		1 426	1 403	0,00	-25,17	528	1	526	100,00	85,89
3-1994	1 531		1 523	1 531	0,00	7,85	554	1	554	100,00	90,36
4-1994	1 631		1 636	1 631	0,00	-5,24	609	1	609	100,00	99,29
1-1995	1 730		1 706	1 730	0,00	23,44	562	1	562	100,00	91,70
2-1995	1 707		1 717	1 707	0,00	-10,00	539	1	539	100,00	88,01
3-1995	1 719		1 718	1 719	0,00	0,57	554	1	554	100,00	90,35
4-1995	1 724		1 712	1 724	0,00	12,06	581	1	581	100,00	94,72
1-1996	1 680		1 705	1 680	0,00	-25,38	560	1	560	100,00	91,32
2-1996	1 748		1 724	1 748	0,00	23,76	558	1	558	100,00	91,07
3-1996	1 718		1 739	1 718	0,00	-20,30	545	1	545	100,00	88,92
4-1996	1 771		1 756	1 771	0,00	14,72	564	1	564	100,00	92,08
1-1997	1 784		1 820	1 784	0,00	-35,35	593	1	593	100,00	96,78
2-1997	1 950		1 909	1 950	0,00	40,81	698	1	696	100,00	113,46
3-1997	1 936		1 962	1 936	0,00	-25,30	604	1	604	100,00	98,47
4-1997	2 012		1 985	2 012	0,00	26,43	609	1	609	100,00	99,34
1-1998	1 961		1 962	1 961	0,00	-0,97	614	1	614	100,00	100,16
2-1998	1 908		1 923	1 908	0,00	-15,32	574	1	574	100,00	93,64
3-1998	1 926		1 906	1 926	0,00	17,80	612	1	612	100,00	99,80
4-1998	1 856		1 855	1 856	0,00	1,02	575	1	575	100,00	93,84
1-1999	1 775		1 786	1 775	0,00	-10,39	588	1	588	100,00	95,91
2-1999	1 760		1 772	1 760	0,00	-12,38	567	1	567	100,00	92,42
3-1999	1 813		1 804	1 813	0,00	9,29	572	1	572	100,00	93,35
4-1999	2 034		1 816	2 034	0,00	217,75	581	1	581	100,00	94,82
1-2000	1 952		1 815	1 952	0,00	137,08	589	1	589	100,00	96,03
2-2000	1 945		1 834	1 945	0,00	111,22	530	1	530	100,00	86,42
3-2000	1 925		1 857	1 925	0,00	66,66	548	1	548	100,00	89,32
4-2000	1 921		1 853	1 921	0,00	67,88	543	1	543	100,00	88,55
1-2001	1 845		1 826	1 845	0,00	19,70	535	1	535	100,00	87,25
2-2001	1 850		1 821	1 850	0,00	25,02	544	609	544	100,00	89,43
3-2001	1 870		1 848	1 870	0,00	17,52	561	603	561	100,00	93,10
4-2001	1 892		1 872	1 892	0,00	12,28	579	598	579	100,00	96,83
1-2002	1 816		1 899	1 816	0,00	8,58	593	594	593	100,00	99,72
2-2002	1 941		1 926	1 941	0,00	6,01	601	592	601	100,00	101,40
3-2002	1 867		1 954	1 867	0,00	4,21	604	592	604	100,00	102,00
4-2002	1 993		1 981	1 993	0,00	2,94	603	592	603	100,00	101,85
1-2003	2 020		2 009	2 020	0,00	2,06	601	593	601	100,00	101,32

## Sector Externo: Series Observadas y Componentes Estimados por TRAMO-SEATS

EXP_BS: Exportaciones de Bienes, US\$ MM						IMP_BS: Importaciones de Bienes, US\$ MM					EXP_SS: Exportaciones de Servicios, US\$ MM				
DATI	Serie Original	Tendencia corto plazo	Desestacionalizada	Componente Estacional	Transitorio e Irregular	Serie Original	Tendencia corto plazo	Desestacionalizada	Componente Estacional	Transitorio e Irregular	Serie Original	Tendencia corto plazo	Desestacionalizada	Componente Estacional	Transitorio e Irregular
1-19:	784	761	784	100,00	100,96	932	857	886	45,65	28,87	200	205	204	98,11	100,18
2-19:	766	790	766	100,00	95,00	702	754	718	-15,52	-36,15	189	203	205	91,86	101,85
3-19:	917	844	917	100,00	106,40	708	684	711	-2,78	26,43	194	199	195	99,47	98,18
4-19:	854	842	854	100,00	99,39	580	665	632	-52,21	-32,51	216	199	194	111,51	97,76
1-19:	814	838	814	100,00	95,19	711	730	714	-3,69	-15,59	204	202	209	97,68	103,74
2-19:	943	875	943	100,00	105,66	851	847	879	2,12	32,06	179	204	196	91,18	96,60
3-19:	875	848	875	100,00	101,12	957	940	924	33,79	-16,58	213	206	212	100,45	103,35
4-19:	774	800	774	100,00	94,92	1 046	1 006	1 020	26,81	13,47	230	205	204	112,88	100,05
1-19:	843	814	843	100,00	101,50	1 033	1 022	1 043	-9,97	21,78	190	202	199	95,78	98,79
2-19:	863	860	863	100,00	98,30	934	995	967	-32,34	-28,70	182	204	199	91,80	98,09
3-19:	944	921	944	100,00	100,45	999	985	993	6,06	7,32	209	210	209	99,77	100,26
4-19:	1 012	929	1 012	100,00	106,76	1 035	976	993	42,61	16,14	255	212	224	114,06	105,83
1-19:	833	864	833	100,00	94,53	907	969	940	-33,22	-28,98	188	209	198	94,82	95,01
2-19:	858	837	858	100,00	100,49	989	1 001	1 015	-26,42	14,22	199	208	213	93,55	102,79
3-19:	864	869	864	100,00	97,50	1 062	1 055	1 052	10,29	-2,83	200	213	202	98,95	95,38
4-19:	961	917	961	100,00	102,74	1 165	1 119	1 120	45,42	0,07	251	225	224	111,83	100,17
1-19:	957	968	957	100,00	96,89	1 180	1 208	1 205	-24,84	-2,44	232	243	242	95,82	99,98
2-19:	1 080	1 080	1 080	100,00	97,98	1 293	1 321	1 320	-27,74	-0,99	249	261	264	94,24	101,71
3-19:	1 320	1 212	1 320	100,00	106,70	1 443	1 468	1 455	-11,81	-13,28	277	273	277	100,09	101,59
4-19:	1 241	1 249	1 241	100,00	97,44	1 680	1 644	1 644	35,95	-0,21	306	278	281	109,03	101,46
1-19:	1 293	1 271	1 293	100,00	99,73	1 796	1 801	1 825	-28,58	23,58	264	279	271	97,21	97,75
2-19:	1 359	1 349	1 359	100,00	98,76	1 906	1 905	1 890	15,23	-14,73	266	282	283	94,02	100,76
3-19:	1 498	1 419	1 498	100,00	103,45	2 025	1 968	1 983	42,26	14,39	288	291	285	101,03	98,45
4-19:	1 439	1 422	1 439	100,00	99,17	2 027	1 972	1 994	32,96	22,99	313	308	295	108,00	96,48
1-19:	1 427	1 410	1 427	100,00	99,18	1 792	1 950	1 902	-109,87	-48,37	343	330	346	99,27	105,17
2-19:	1 459	1 431	1 459	100,00	99,90	2 005	1 965	1 995	10,78	30,20	319	347	341	93,49	98,85
3-19:	1 494	1 462	1 494	100,00	100,14	2 038	1 989	1 973	64,25	-15,73	366	358	357	102,55	100,26
4-19:	1 519	1 506	1 519	100,00	98,83	2 051	2 015	2 024	26,76	9,09	385	367	369	104,43	100,92
1-19:	1 615	1 615	1 615	100,00	97,99	1 923	2 056	2 044	-121,01	-11,92	367	374	370	99,17	99,44
2-19:	1 859	1 739	1 859	100,00	104,75	2 131	2 123	2 111	19,69	-11,65	351	381	376	93,38	99,15
3-19:	1 773	1 711	1 773	100,00	101,58	2 281	2 186	2 214	67,02	28,51	407	392	390	104,21	99,98
4-19:	1 585	1 605	1 585	100,00	96,84	2 217	2 199	2 187	30,25	-12,46	413	405	402	102,87	99,53
1-19:	1 198	1 581	1 198	100,00	74,26	2 076	2 179	2 178	-101,60	-0,93	417	415	422	98,89	102,07
2-19:	1 339	1 643	1 339	100,00	79,89	2 172	2 116	2 142	30,32	25,28	470	418	501	93,73	120,37
3-19:	1 564	1 737	1 564	100,00	88,25	2 046	1 995	1 982	63,61	-13,01	439	418	415	106,01	99,99
4-19:	1 655	1 708	1 655	100,00	95,02	1 928	1 844	1 868	59,90	24,64	422	411	416	101,39	101,79
1-19:	1 412	1 549	1 412	100,00	89,35	1 549	1 710	1 672	-122,87	-37,88	384	404	391	97,98	97,44
2-19:	1 409	1 499	1 409	100,00	92,15	1 614	1 662	1 656	-41,78	-6,20	377	401	399	94,31	100,00
3-19:	1 585	1 595	1 585	100,00	97,42	1 694	1 702	1 696	-2,46	-5,17	439	399	407	107,78	102,54
4-19:	1 712	1 673	1 712	100,00	100,28	1 893	1 767	1 783	110,18	15,23	379	394	381	99,52	97,22
1-20:	1 651	1 670	1 651	100,00	96,87	1 786	1 818	1 816	-29,71	-1,73	384	393	391	98,12	100,01
2-20:	1 681	1 701	1 681	100,00	98,88	1 836	1 838	1 853	-17,28	15,04	377	396	398	94,73	100,84
3-20:	1 847	1 785	1 847	100,00	101,42	1 781	1 847	1 822	-41,53	-24,20	426	397	395	108,23	100,11
4-20:	1 849	1 772	1 849	100,00	102,28	1 946	1 856	1 879	67,39	22,45	386	397	391	98,79	99,01
1-20:	1 648	1 678	1 648	100,00	96,27	1 828	1 851	1 841	-13,05	-9,60	393	399	400	98,38	100,72
2-20:	1 678	1 683	1 678	100,00	99,71	1 831	1 839	1 839	-8,72	-0,02	377	399	398	94,74	99,80
3-20:	1 708	1 712	1 708	100,00	99,80	1 806	1 835	1 835	-29,11	-0,01	433	400	400	108,30	100,06
4-20:	1 739	1 741	1 739	100,00	99,88	1 868	1 832	1 832	36,09	0,00	396	401	401	98,69	99,97
1-20:	1 769	1 771	1 769	100,00	99,90	1 823	1 829	1 829	-6,19	0,00	396	402	402	98,42	100,01
2-20:	1 800	1 801	1 800	100,00	99,99	1 824	1 827	1 827	-3,31	0,00	382	403	403	94,74	99,99
3-20:	1 831	1 832	1 831	100,00	99,95	1 815	1 826	1 826	-11,04	0,00	438	405	405	108,30	100,00
4-20:	1 863	1 884	1 863	100,00	99,87	1 838	1 825	1 825	13,69	0,00	400	406	406	98,69	100,00
1-20:	1 895	1 896	1 895	100,00	99,98	1 821	1 824	1 824	-2,35	0,00	400	407	407	98,42	100,00

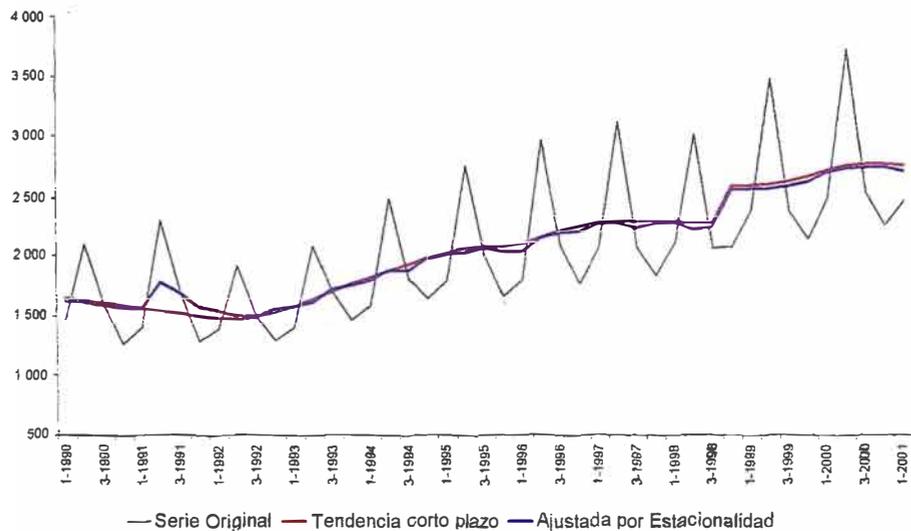
## Sector Externo: Series Observadas y Componentes Estimados por TRAMO-SEATS

IMP_SS: Importaciones de Servicios, US\$ MM					
DATI	Serie Original	Tendencia corto plazo	Desestacion nalizada	Componente Estacional	Transitorio e Irregular
1-19:	314	303	324	-10,00	20,45
2-19:	267	291	279	-12,62	-11,84
3-19:	275	283	275	0,15	-8,72
4-19:	309	286	286	22,82	-0,56
1-19:	279	294	290	-11,62	-3,95
2-19:	292	306	303	-11,46	-3,42
3-19:	331	319	330	0,98	11,31
4-19:	337	330	314	22,92	-15,55
1-19:	345	342	359	-13,82	16,52
2-19:	343	346	353	-10,19	7,42
3-19:	327	346	325	1,70	-20,63
4-19:	396	350	373	23,60	22,56
1-19:	321	351	337	-16,72	-13,15
2-19:	344	352	353	-9,23	0,84
3-19:	362	357	359	3,55	1,53
4-19:	385	361	362	23,31	1,16
1-19:	339	367	358	-19,02	-9,18
2-19:	365	382	373	-8,35	-8,72
3-19:	416	404	411	5,26	6,62
4-19:	446	426	423	22,40	-2,60
1-19:	426	448	447	-20,57	-1,18
2-19:	470	468	477	-7,16	9,21
3-19:	490	482	483	6,42	1,44
4-19:	508	493	487	21,66	-6,59
1-19:	489	508	511	-21,97	2,60
2-19:	521	520	526	-6,51	7,26
3-19:	531	528	524	7,58	-4,46
4-19:	558	537	536	21,59	-0,36
1-19:	517	550	540	-23,30	-10,49
2-19:	569	569	576	-6,73	7,20
3-19:	596	585	587	8,87	2,43
4-19:	623	593	601	21,72	6,02
1-19:	567	597	581	-23,78	-5,62
2-19:	603	596	611	-7,68	14,73
3-19:	602	584	592	9,99	8,41
4-19:	568	568	546	22,04	-21,88
1-19:	546	562	569	-23,70	6,88
2-19:	542	564	551	-9,50	-12,35
3-19:	582	571	572	10,50	1,14
4-19:	609	579	585	23,51	6,59
1-20:	560	581	584	-23,80	2,41
2-20:	562	583	573	-10,77	-10,32
3-20:	803	591	592	10,53	0,92
4-20:	633	599	608	24,49	9,21
1-20:	573	602	597	-24,09	-5,28
2-20:	594	606	605	-11,03	0,00
3-20:	621	610	610	10,52	0,00
4-20:	640	616	616	24,67	0,00
1-20:	597	621	621	-24,16	0,00
2-20:	615	626	626	-11,03	0,00
3-20:	642	631	631	10,52	0,00
4-20:	661	636	636	24,67	0,00
1-20:	617	641	641	-24,16	0,00

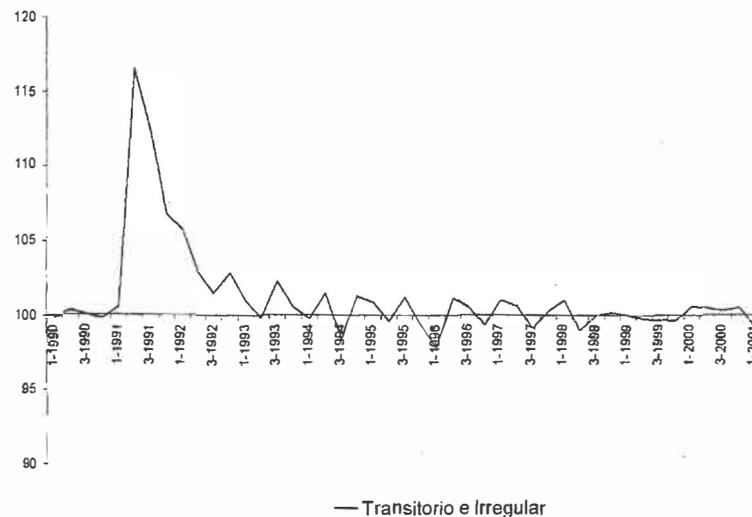
## **Anexo 2**

# **Gráficos de los Componentes No Observados Estimados por TRAMO- SEATS**

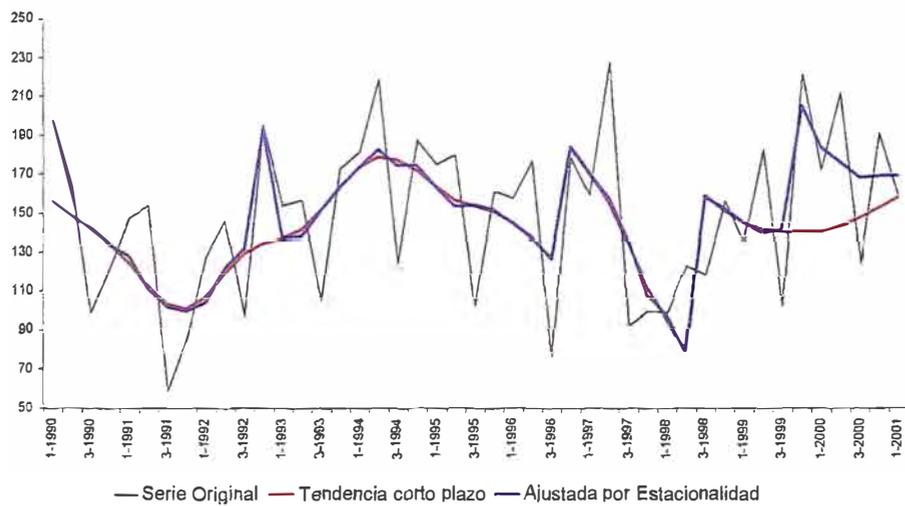
PBI Agropecuario, S/. 94 MM



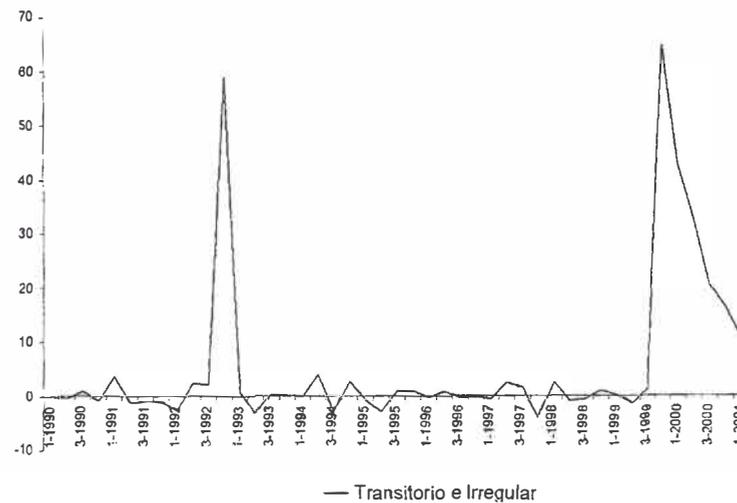
PBI Agropecuario, S/. 94 MM



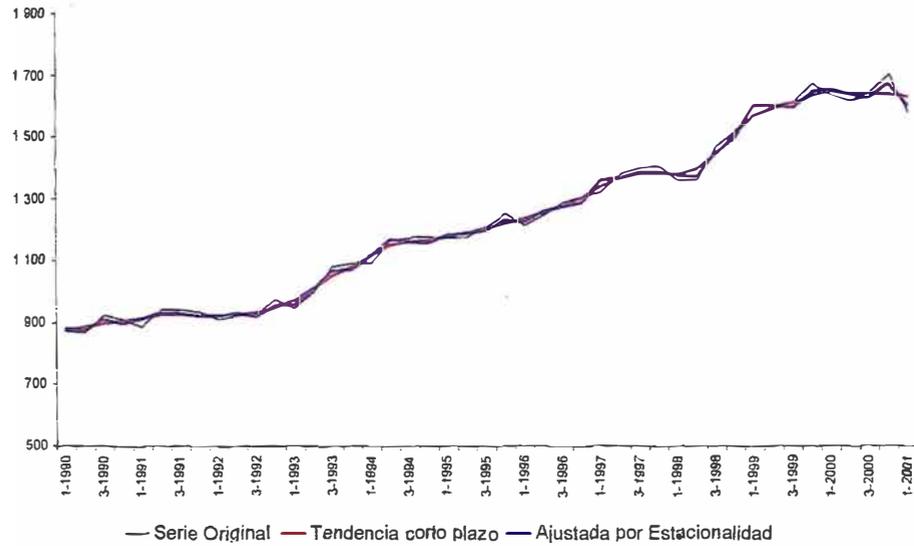
PBI Pesca, S/. 94 MM



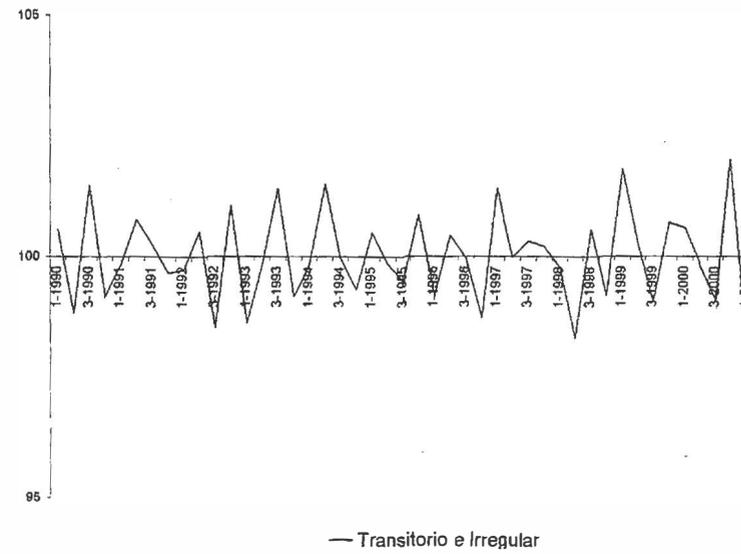
PBI Pesca, S/. 94 MM



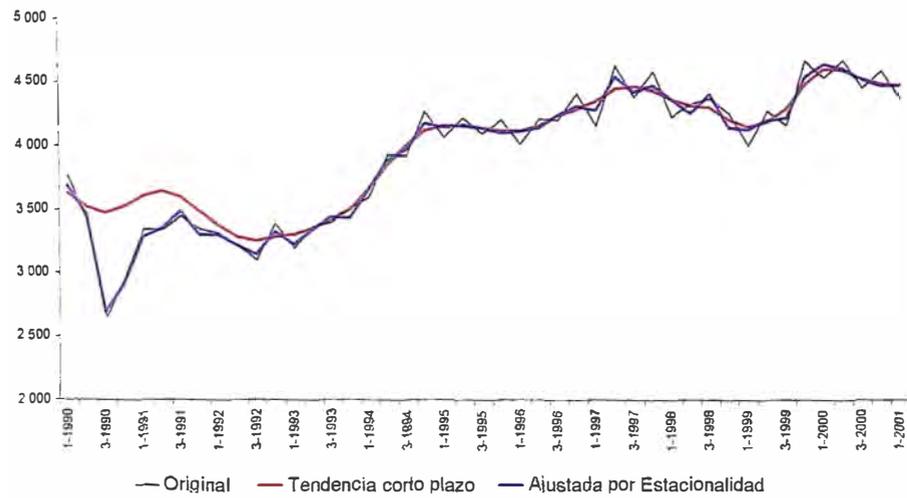
PBI Minería, S/. 94 MM



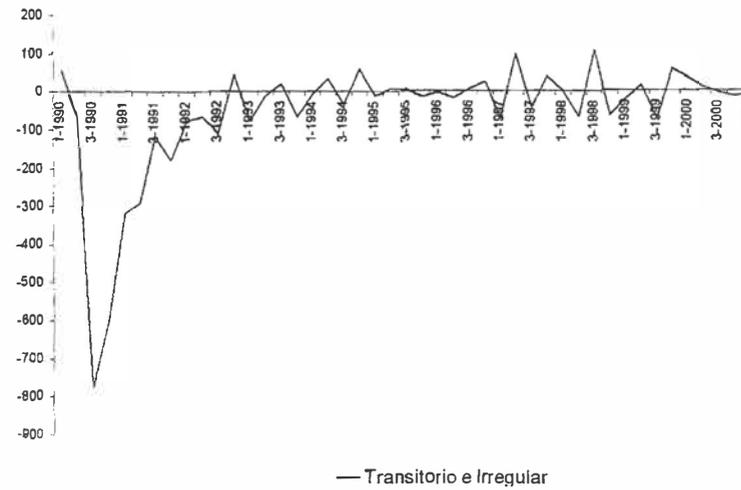
PBI Minería, S/. 94 MM



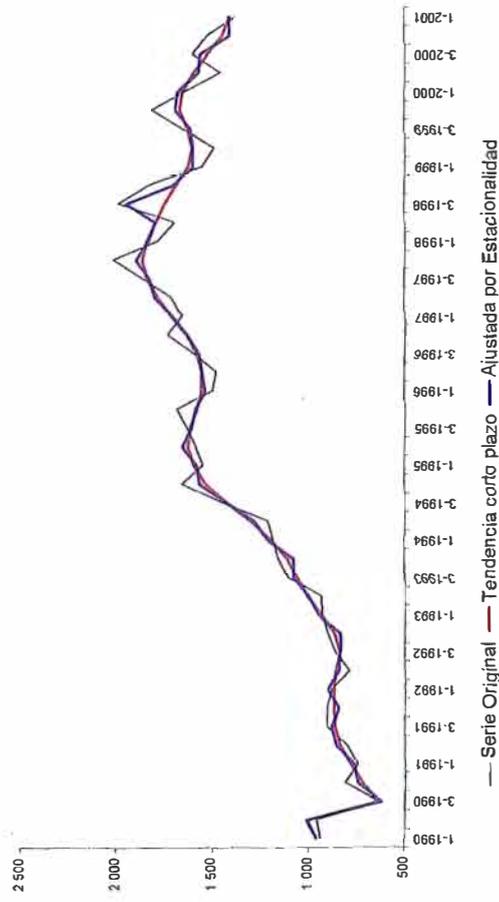
PBI Manufactura, S/. 94 MM



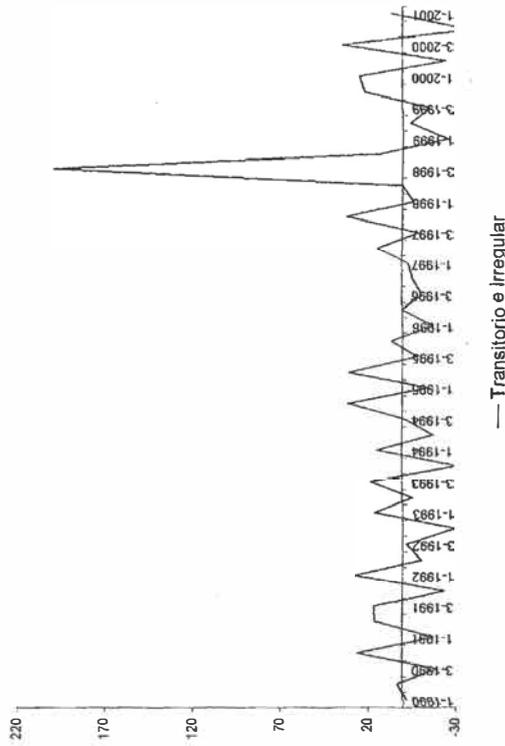
PBI Manufactura, S/. 94 MM



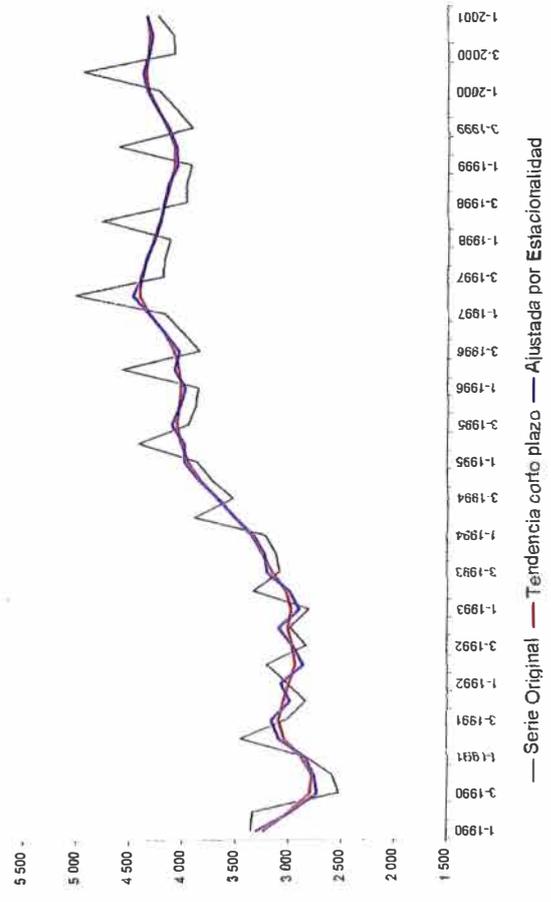
PBI Construcción, S/. 94 MM



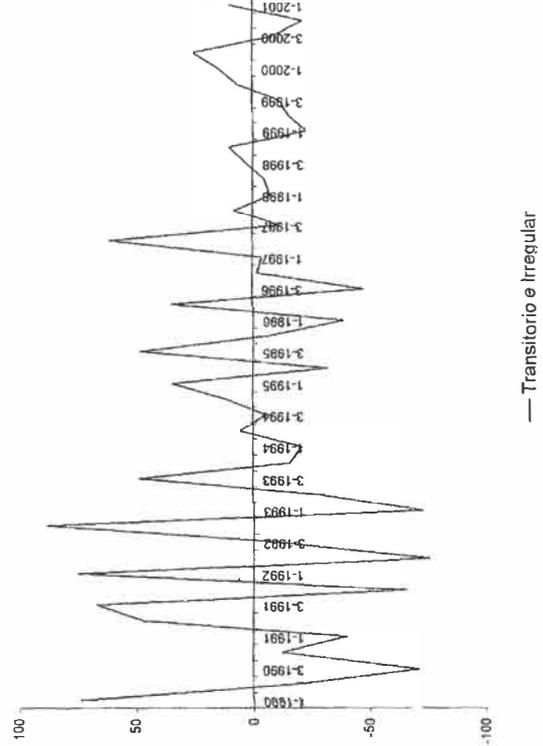
PBI Construcción, S/. 94 MM



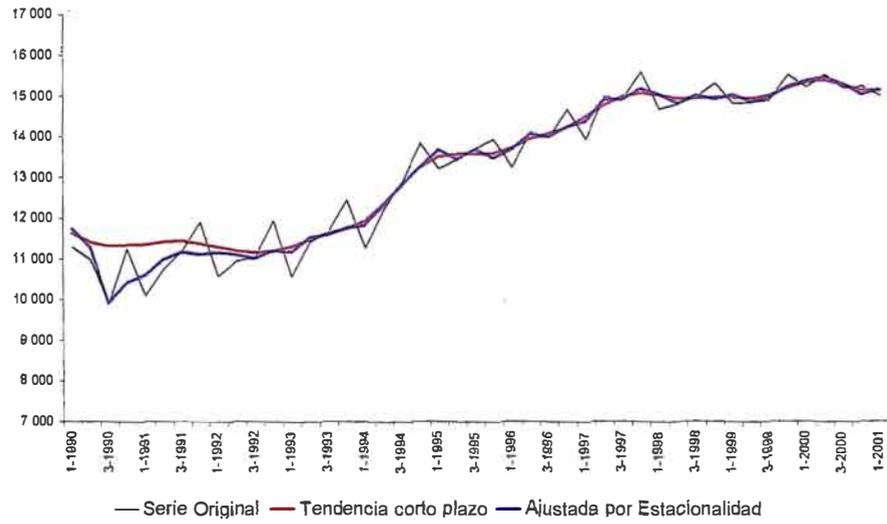
PBI Comercio, S/. 94 MM



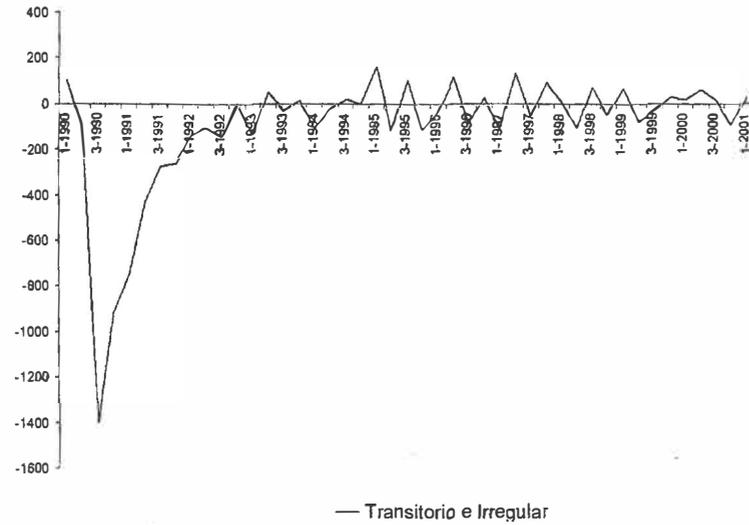
PBI Comercio, S/. 94 MM



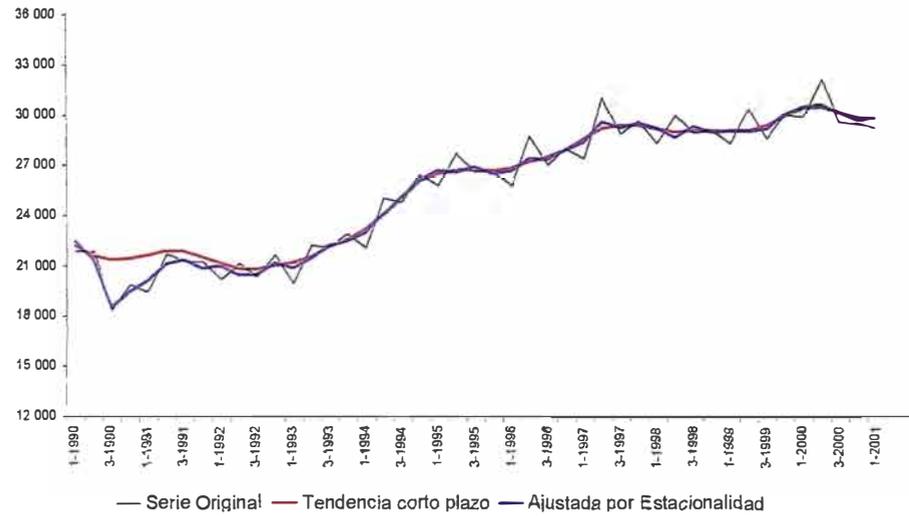
PBI Otros, S/. 94 MM



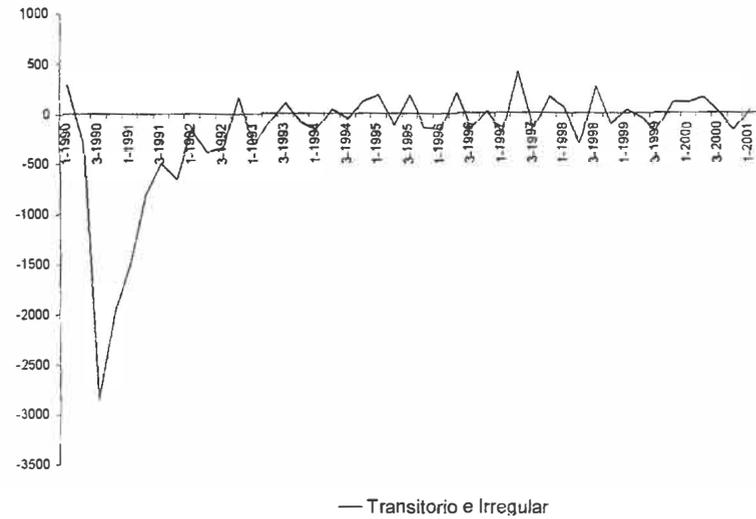
PBI Otros, S/. 94 MM



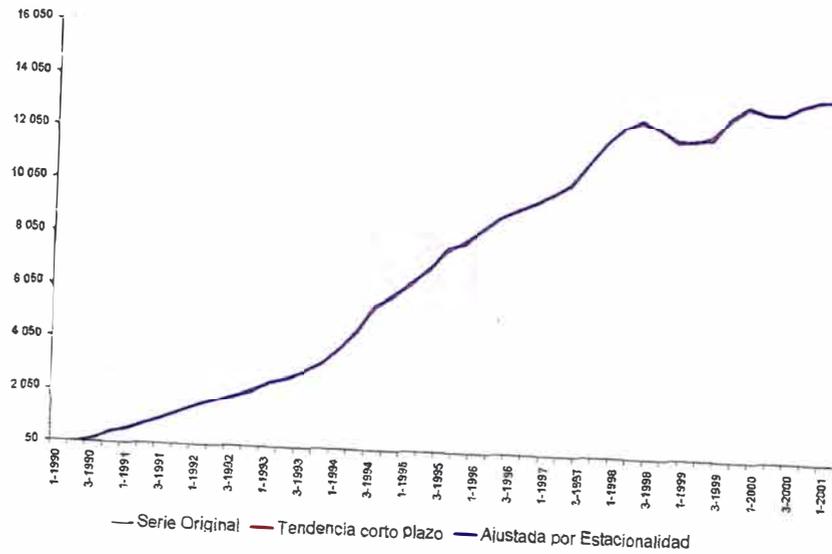
PBI Global, S/. 94 MM



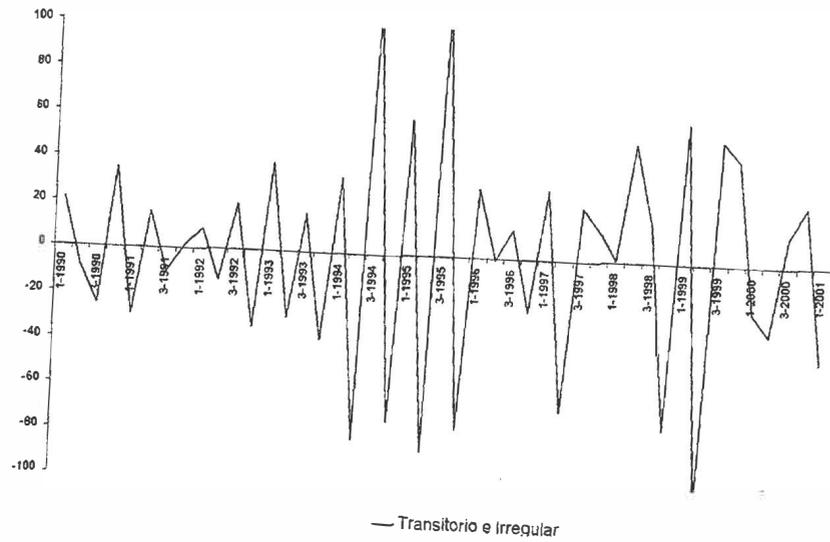
PBI Global, S/. 94 MM



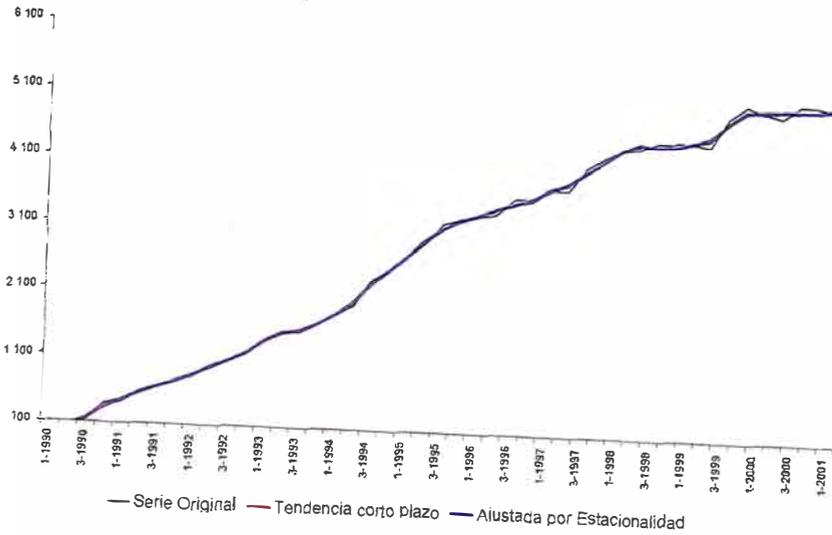
Liquidez en M/N, Nominal S/. MM



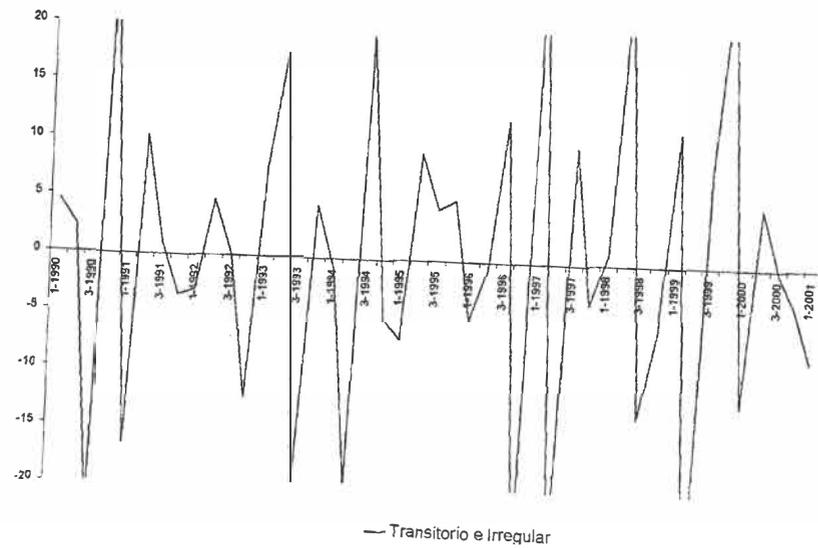
Liquidez en M/N, Nominal S/. MM



Emisión Primaria, Nominal S/. MM

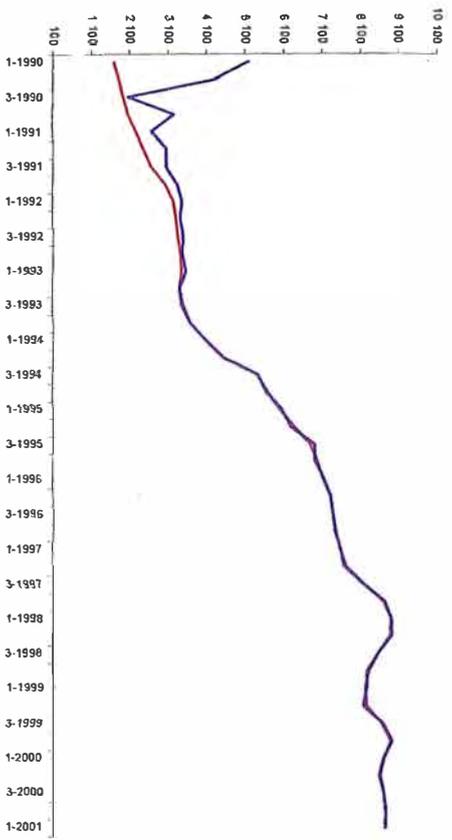


Emisión Primaria, Nominal, S/. MM

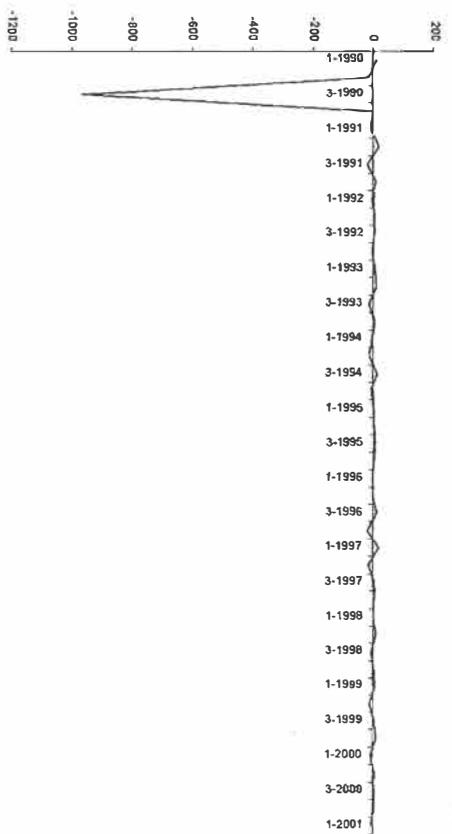


color one año. Se es O se a mp ent im os po TS

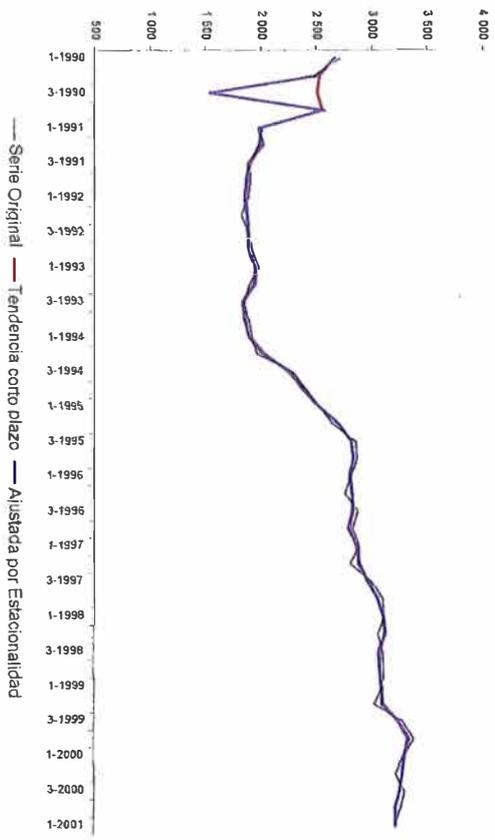
Liquidez en M/N, Real, S/ 94 MM



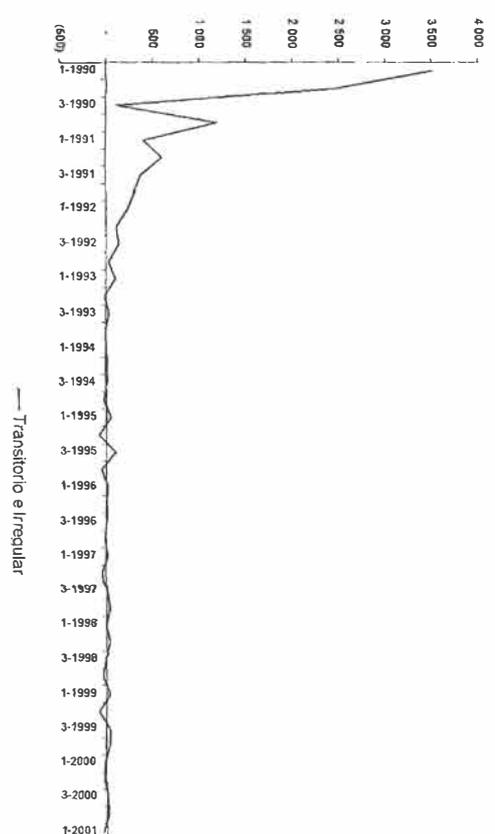
Liquidez en M/N, Real, S/ 94 MM



Emisión Primaria, Real, S/ 94 MM

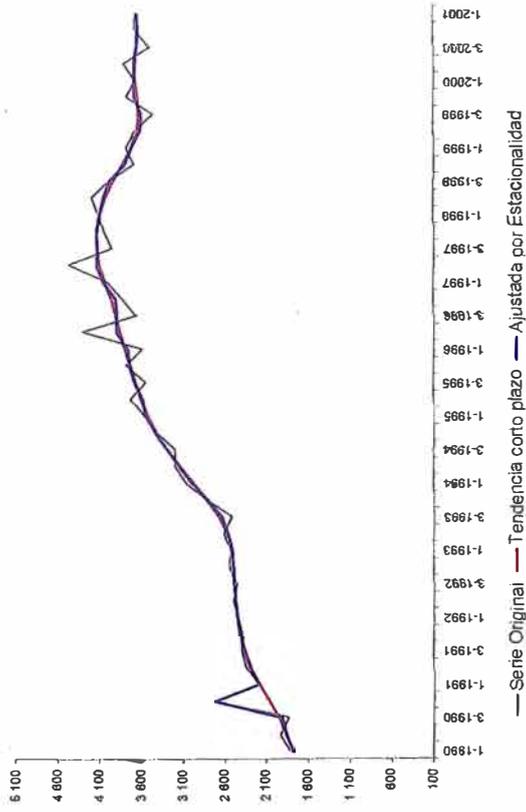


Emisión Primaria, Real, S/ 94 MM

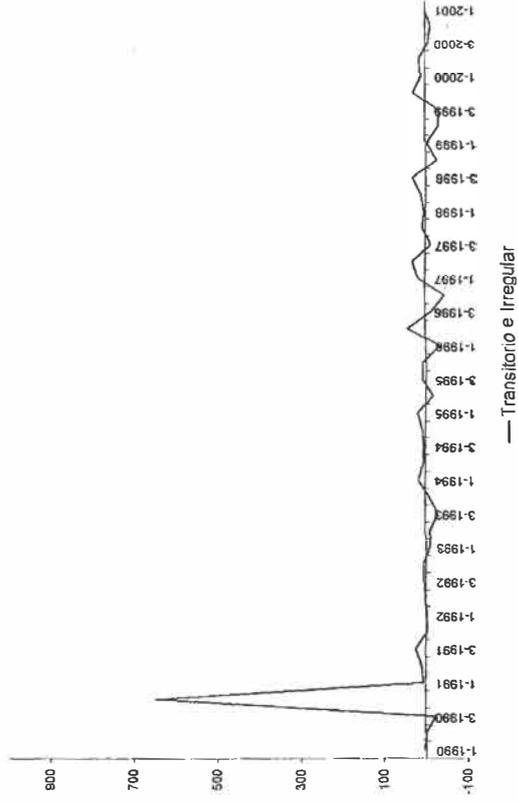


Sector Fiscal: Series Observada Componentes Estimados por TRAMO-SEATS

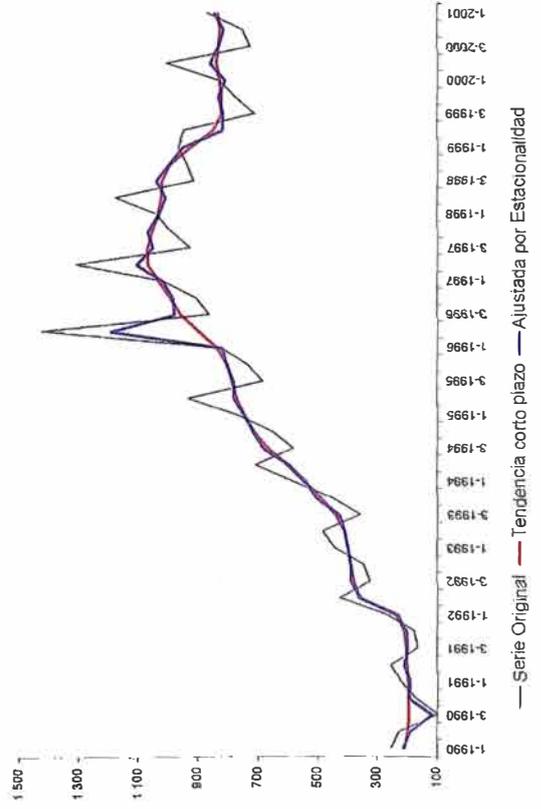
Ingresos Tributarios, S/. 94 MM



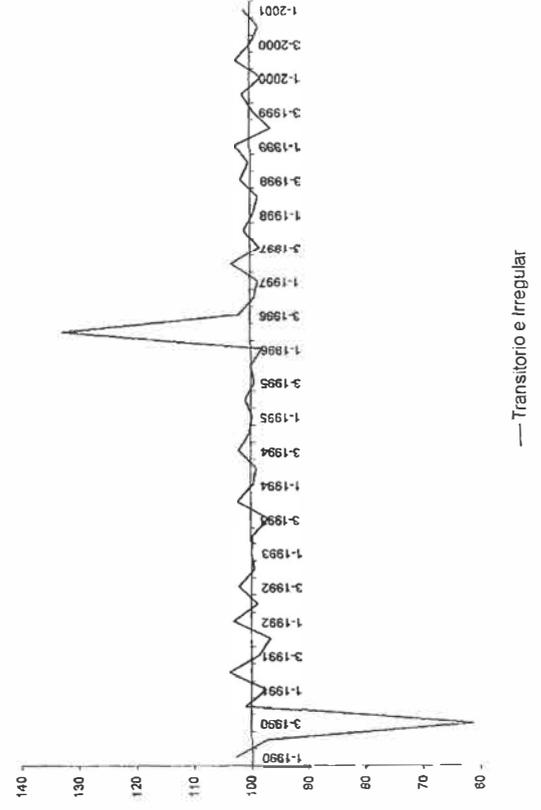
Ingresos Tributarios, S/. 94 MM



Impuestos a los Ingresos, S/. 94 MM

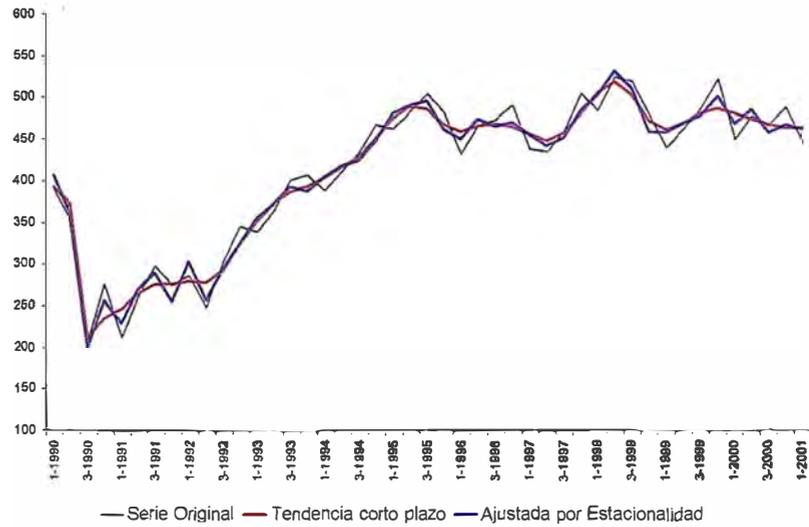


Impuestos a los Ingresos, S/. 94 MM

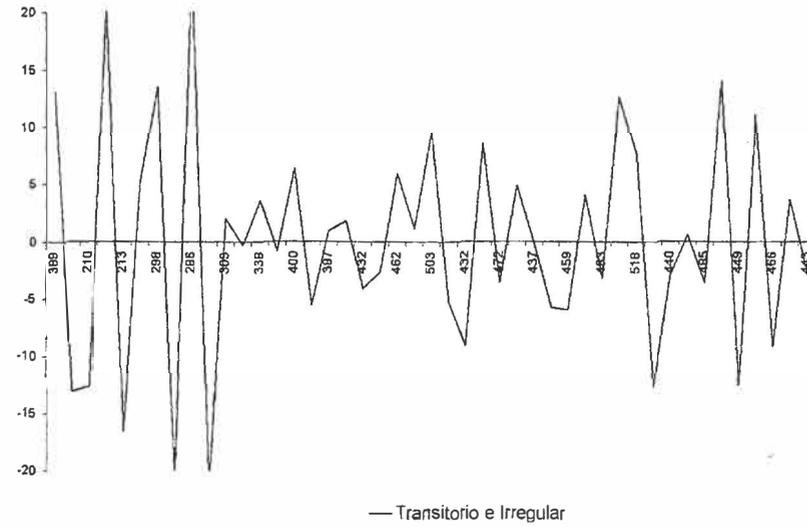


Sector Fiscal: Series Observadas y Componentes Estimados por TRAMO-SEATS

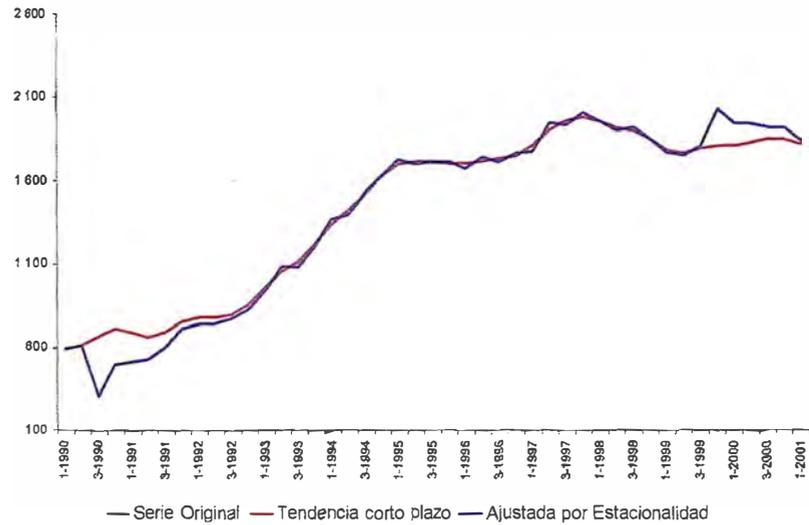
Impuestos a las Importaciones, S/. 94 MM



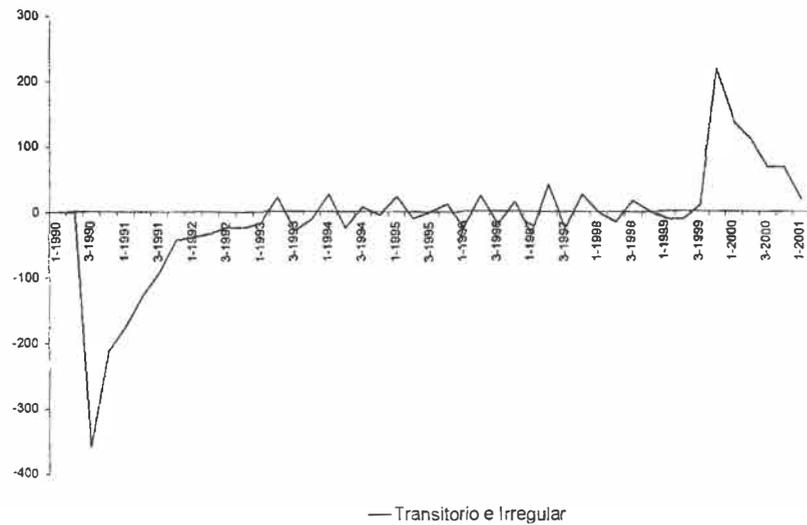
Impuestos a las Importaciones, S/. 94 MM



IGV, S/. 94 MM

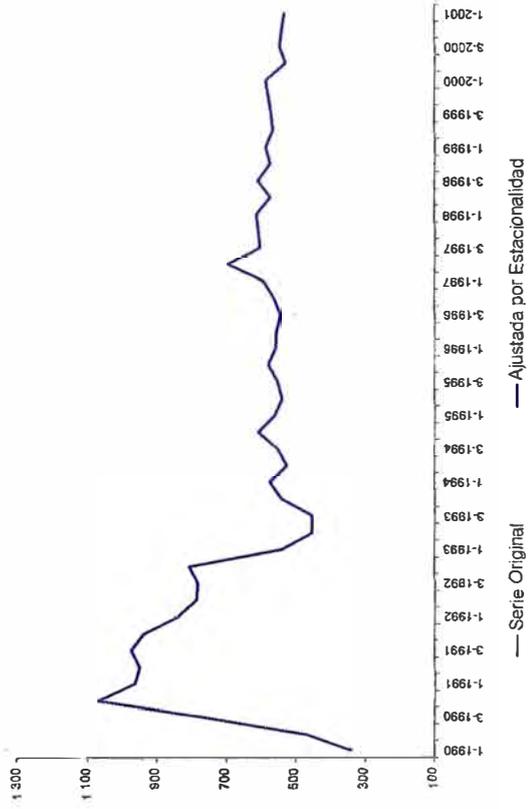


IGV, S/. 94 MM

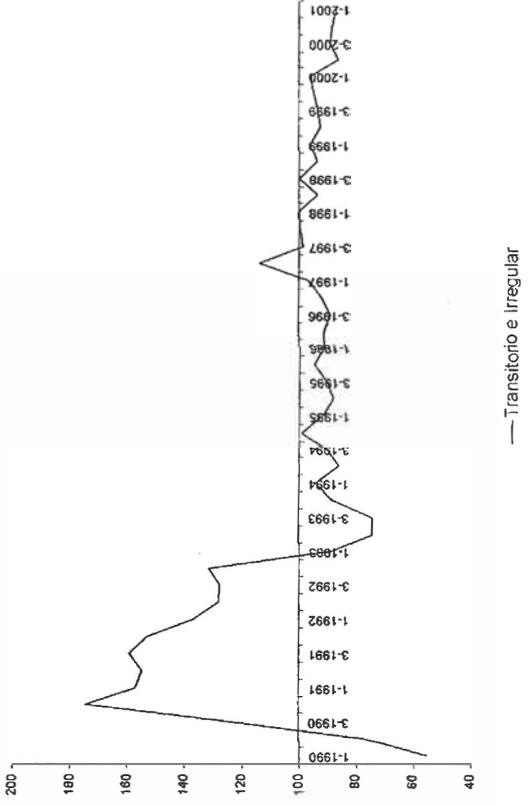


Sector Fiscal Series Observadas y Componentes Estimados por TRAMO-SEATS

ISC, \$/ 94 MM

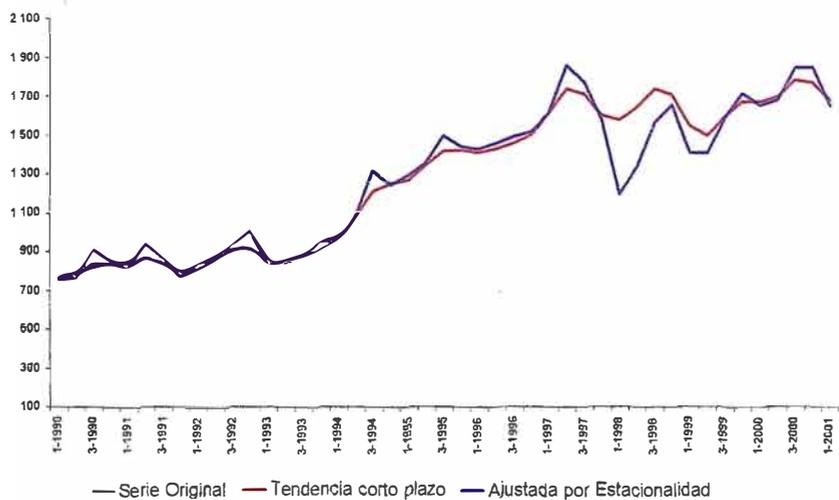


ISC, \$/ 94 MM

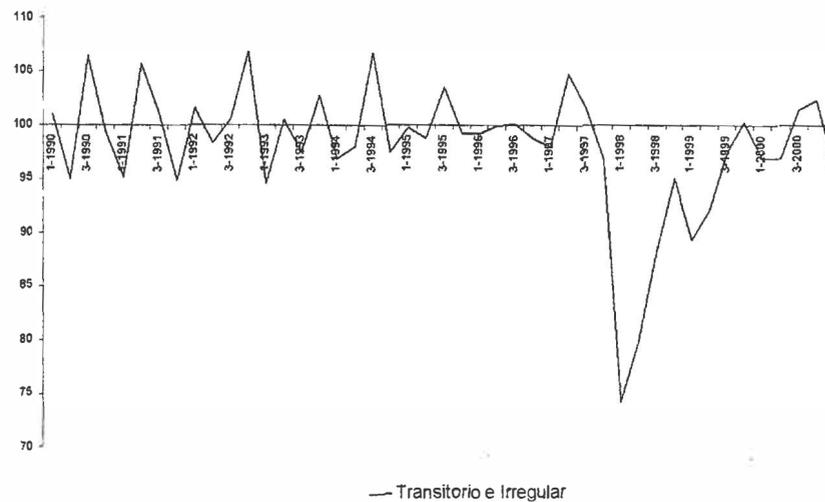


Sector Externo: Series Observadas y Componentes Estimados por TRAMO-SEATS

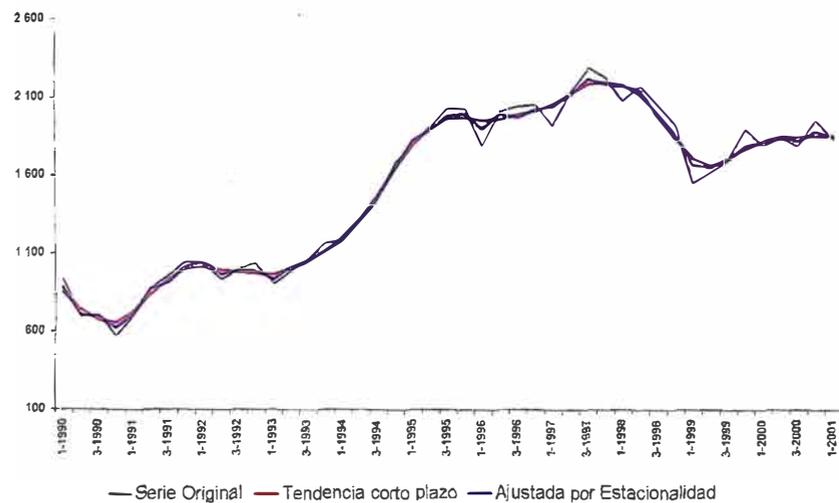
Exportaciones de Bienes, US\$ MM



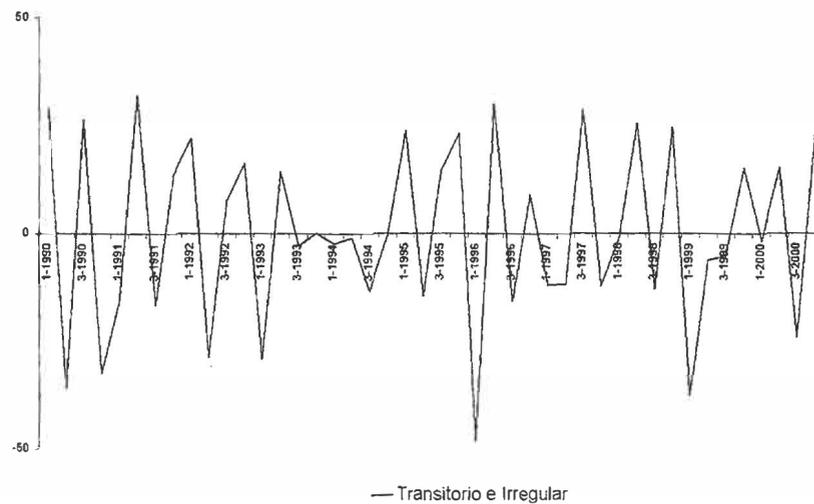
Exportaciones de Bienes, US\$ MM



Importaciones de Bienes, US\$ MM

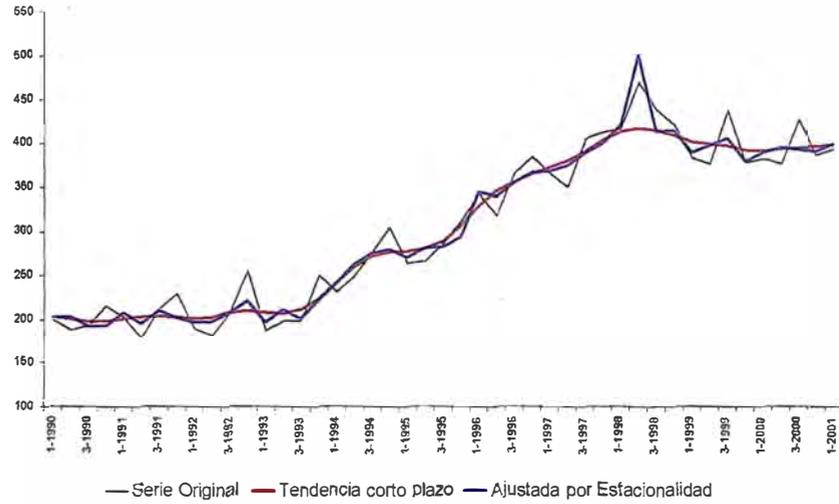


Exportaciones de Bienes, US\$ MM

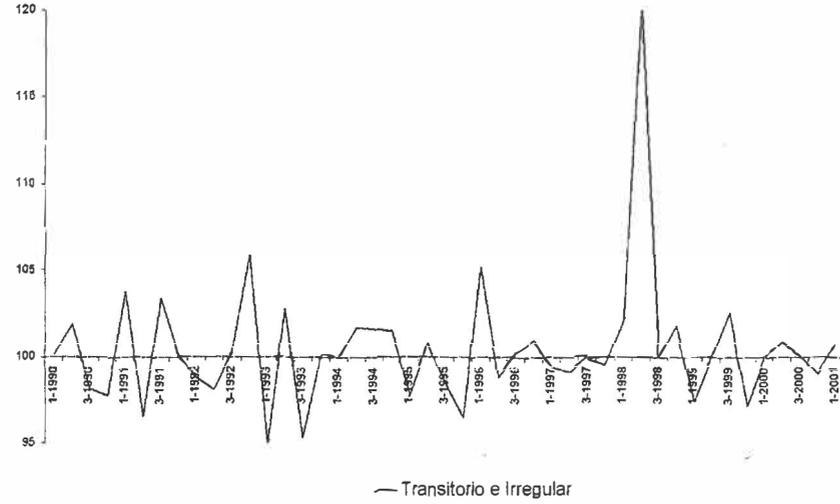


ector Externo: Series Observadas y Componentes Estimados por TRAMO-SEATS

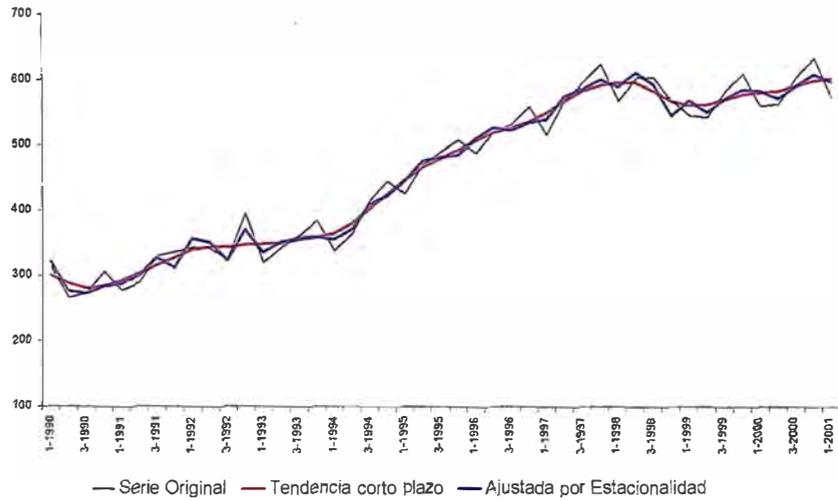
Exportaciones de Servicios, US\$ MM



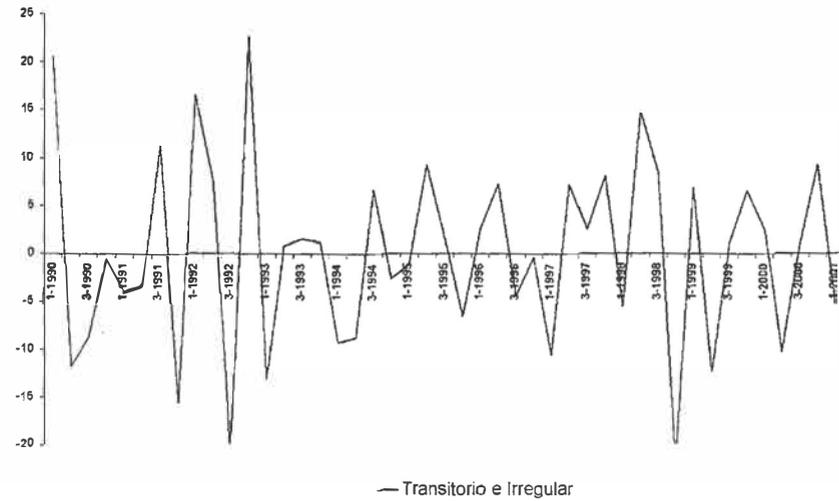
Exportaciones de Servicios, US\$ MM



Importaciones de Servicios, US\$ MM



Importaciones de Servicios, US\$ MM



## **Anexo 3**

### **Glosario de Términos**

**ACF** (autocorrelation generating function).- Función generadora de autocorrelaciones.

**ACGF** (autocovariance generating function).- Función generadora de autocovarianzas.

También se usa la nomenclatura AGF.

**Amplitud** (amplitud).- Es la distancia del valor medio al valor máximos de una onda.

**Análisis Espectral de Series de Tiempo.**- Una forma alternativa para el análisis de las series de tiempo es llevado a cabo en el dominio de las frecuencias, al cual también se le conoce como análisis espectral. La idea es identificar las características dominantes de una serie de tiempo. Es decir, conocer sus componentes no observados (tendencia, estacionalidad, ciclos de negocios, etc).

Cualquier serie de tiempo puede ser representado en términos de sumas infinitas de funciones

trigonométricas del tipo  $y_t = \int_0^{\pi} \alpha(\lambda) \cos(\lambda t) d\lambda + \int_0^{\pi} \delta(\lambda) \text{sen}(\lambda t) d\lambda$ , donde  $\lambda$  se conoce como la

frecuencia. Nótese que  $y_t$  depende de los componentes asociados con el rango de frecuencias

$\lambda$ . La idea es extraer o identificar aquellas frecuencias que dominan la variación estadística

de  $y_t$ . Al ver un círculo unitario, estamos interesado en la velocidad los diferentes

componentes de la serie complementan un ciclo. Es decir, antes de que empiece a repetirse así

mismo (correspondiente a distintas frecuencias).

**CCGF** (crosscovariance generating function).- Función generadora de covarianzas cruzadas.

También se usa la nomenclatura CGF.

**Componente canónico.**- Un componente que está libre de ruido blanco. Es decir, para un componente dado, excepto para el irregular, ningún ruido blanco aditivo puede ser extraído de dicho componente.

**Método AMB o Método Basado en Modelos ARIMA** (ARIMA model based approach).- En el contexto del ajuste estacional consiste de dos pasos: i) un modelo ARIMA se obtiene para la serie observada y ii) técnicas de extracción de señales son usadas para estimar los componentes no observados de una serie con filtros que son óptimos (en alguna manera bien definidos).

**Espectro** (spectrum).-Es la transformación de Fourier de la AGF de un proceso estacionario.

Para una serie no estacionaria se le suele denominar pseudo-espectro.

Es una función de frecuencias definida en  $[0; \pi]$ , el cual indica cómo cada frecuencia contribuye a la variación total de una serie de tiempo. El Espectro puede ser representado de varias formas, una representación es:

$$f_y(\lambda) = \frac{1}{2\pi} \left[ \sigma_y^2 + 2 \sum_{\tau=1}^{\infty} \sigma(\tau) \cos(\lambda\tau) \right], \text{ donde } \lambda \in [-\pi; \pi]$$

Esto es, el espectro está en términos de la varianza y autocovarianzas de  $y_t$ . Observese que el espectro es una función simétrica alrededor de cero debido a que la función coseno es par, por lo que suele realizar el análisis en el intervalo cerrado  $\lambda \in [0; \pi]$

**Estimador concurrente o actual** (concurrent estimator).- Aquel utilizado para la estimación de  $y_t$  cuando  $t = T$  (T es la última observación).

**Filtro fijo ad hoc** (ad hoc fixed filter).- Es un filtro en el que las ponderaciones son elegidas a priori, independientemente de la serie en particular. Ejemplos son los filtros HP y X11, aunque en estos casos los coeficientes no serán constantes.

**Filtro lineal** (linear filter).- Es una combinación lineal de una serie ( $x_t$ ) de acuerdo a la expresión  $y_t = c_{k_1} x_{t-k_1} + \dots + c_{-1} x_{t-1} + c_0 x_t + c_1 x_{t+1} + \dots + c_{k_2} x_{t+k_2}$ . También se le conoce como filtro de media móvil. Las ponderaciones  $c_j$  pueden ser determinados de tal forma que se capture la variación relevante asociada con el componente de interés. Por ejemplo un filtro estimar la tendencia capturaría la variación asociada con el movimiento de largo plazo de la serie y un filtro para el componente estacional capturaría la variación de naturales estacional.

**Frecuencia** ( $\lambda$ ).- Es la velocidad al cual recorre una onda igual al número de longitudes de onda por unidad de tiempo. También, en un círculo trigonométrico, es igual al número de vueltas por unidad de tiempo.

**Frecuencia (Fundamental).**- Está dado por la relación  $\lambda = \frac{2\pi}{T}$ ; con el término frecuencia se quiere decir cuán frecuentemente están juntas los datos. Por ejemplo, datos de alta frecuencia como son las estadísticas que tienen observaciones minuto a minuto, hora a hora y día a día.

**Frecuencias Armónicas.**- Para una serie trimestral están dadas por la fórmula  $\lambda_j = j \frac{\pi}{2}$ ;  
 $j=1,2, 3$  y  $4$

**Función de transferencia ()**.- En el dominio de las frecuencias esta función representa, para cada frecuencia, la proporción de la variabilidad de  $x_t$  que es usada para estimar la serie ajustada estacionalmente.

**Kurtosis.**- Mide la elevación o achatamiento de la distribución de una serie. Tiene la siguiente fórmula:

$$K = \frac{1}{N} \sum_{i=1}^N \left( \frac{y_i - \bar{y}}{\hat{\sigma}} \right)^4$$

donde  $\hat{\sigma}$  es un estimado insesgado de la varianza (Bickel and Doksum 1977, p.388). La Kurtosis de la distribución normal es 3. Si la Kurtosis excede a 3, la distribución es elevada (leptokurtic) relativa a la normal; si la Kurtosis es menor a 3, la distribución es achatada (platykurtic) relativa a la normal.

**Modelo determinístico** (deterministic model).- Un modelo que produce pronósticos con error cero cuando los parámetros del modelo son conocidos.

**Modelo estocástico** (stochastic model).- Un modelo cuyos pronósticos tienen errores aleatorios distintos de cero, incluso si los parámetros del modelo son conocidos.

**Periodo** ( $\tau$ ).- Es el número de unidades de tiempo en el que se completa un círculo unitario. Longitud de tiempo  $\tau$  que toma una serie para completar un ciclo completo. Por ejemplo una serie trimestral toma 4 periodos en completar un ciclo de  $2\pi$

**Poder de un test**.- Poder de un test =  $(1 - \beta)$ , donde  $\beta$  es la probabilidad de cometer el Error Tipo II (aceptar una hipótesis nula siendo ésta falsa). El poder de un test es la probabilidad de rechazar correctamente una hipótesis nula falsa.

**SACF** (sample autocorrelation generating function).- Función muestral generadora de autocorrelaciones.

**Serie linealizada**.- Se suele llamar así a la serie observada corregida por outliers y variables de tipo regresión. Esta corrección consiste en removerle los efectos de los outliers, efectos calendario, y variables de intervención. Se le denomina linealizada dado que puede asumirse que es la salida de un proceso estocástico lineal modelado en el formato ARIMA.

**Skewness** (S=coeficiente de asimetría).- Es una medida de asimetría de la distribución de la serie alrededor de su media. Tiene la siguiente fórmula:

$$S = \frac{1}{N} \sum_{i=1}^N \left( \frac{y_i - \bar{y}}{\hat{\sigma}} \right)^3$$

donde  $\hat{\sigma}$  es un estimador insesgado de la varianza (Bickel and Doksum 1977, p.388). El

Skewness de una distribución simétrica, como el de una distribución normal, es cero. Un valor positivo del Skewness significa que la distribución tiene una larga cola derecha, en tanto que un valor negativo de este estadístico implica que la distribución tiene una larga cola izquierda.

**UCARIMA** (unobserved component ARIMA model).- Modelo ARIMA de componentes no

observados. Esta constituido por las ecuaciones  $x_t = \sum_{i=1}^k x_{it}$  y  $\phi_i(B)x_{it} = \theta_i(B)a_{it}$

conjuntamente con los supuestos 1-5.  $x_t$  es la serie linealizada a ser descompuesta y  $x_{it}$  es su i-ésimo componente.

**Variables de intervención.**- Son variables de regresión que se usan para modelar ciertos efectos anormales tales como huelgas, cambios significativos en la política económica, desastres naturales, etc.