



Regresión Lineal con Errores Localmente Estacionarios LSMA

Por

Carlos Alberto Piutrin Pizarro

Tesis sometida como requisito para optar al grado de

Doctor en Estadística

Pontificia Universidad Católica de Chile,

Santiago, Chile

2020

Director de Tesis: Wilfredo Palma

PONTIFICIA UNIVERSIDAD CATÓLICA DE CHILE

DEPARTAMENTO DE ESTADÍSTICA

Los que abajo firman certifican haber leído y recomiendan a la Facultad de Matemáticas la aceptación de la Tesis titulada “**Regresión Lineal con Errores Localmente Estacionarios LSMA**” de **Carlos Alberto Piutrin Pizarro** como requerimiento para optar al grado de **Doctor en Estadística**.

2020.

Supervisor de Tesis:

Wilfredo Palma

Pontificia Universidad Católica de Chile

Comité Examinador:

Reinaldo Arellano

Pontificia Universidad Católica de Chile

Manuel Galea

Pontificia Universidad Católica de Chile

Felipe Osorio

Universidad Técnica Federico Santa María

PONTIFICIA UNIVERSIDAD CATÓLICA DE CHILE

Fecha: **2020**

Autor: **Carlos Alberto Piutrin Pizarro**

Título: **Regresión Lineal con Errores Localmente Estacionarios
LSMA**

Departamento de: **Estadística**

Grado: **Doctor** Convocación: Año: **2020**

Se le concede permiso para hacer circular y copiar, con propósitos no comerciales, el título ante dicho para los requerimientos de individuos y/o instituciones.

Firma del Autor

EL AUTOR SE RESERVA LOS DERECHOS DE OTRAS PUBLICACIONES, Y NI LA TESIS NI EXTRACTOS EXTENSOS DE ELLA, PUEDEN SER IMPRESOS O REPRODUCIDOS SIN EL PERMISO ESCRITO DEL AUTOR.

EL AUTOR ATESTIGUA QUE EL PERMISO SE HA OBTENIDO PARA EL USO DE CUALQUIER MATERIAL COPYRIGHTED QUE APAREZCA EN ESTA TESIS (CON EXCEPCIÓN DE LOS BREVES EXTRACTOS QUE REQUIEREN SOLAMENTE EL RECONOCIMIENTO APROPIADO EN LA ESCRITURA DEL ESTUDIANTE) Y QUE TODO USO ESTÉ RECONOCIDO CLARAMENTE.

Dedicado a mi familia.

Agradecimientos

Agradecer a mi tutor de tesis, Wilfredo Palma, por todos sus conocimientos y ayuda en este trabajo. También agradezco a CONICYT por el apoyo económico sustentado a lo largo de mis estudios de Doctorado.

Índice General

1. Introducción	2
2. Procesos Localmente Estacionarios	6
2.1. Definición	6
2.2. Procesos Localmente Estacionarios de Corta Memoria	10
2.2.1. Procesos Localmente Estacionarios de Medias Móviles de Orden q	12
2.3. Procesos Localmente Estacionarios de Larga Memoria	14
2.4. Covarianza Local	16
3. Regresión Lineal con Errores LSMA(q)	18
3.1. Definición	19
3.2. Estimación	21
3.3. Teoría Asintótica	22
3.4. Estudio de Simulación	28

4. Extensiones	48
4.1. Extensión a un Proceso LSARMA(p, q)	49
4.2. Estudio de Simulación	52
5. Eficiencia Relativa	66
5.1. Proceso LSMA con Media μ Constante	67
5.1.1. Caso θ Constante	68
5.1.2. Caso θ Función Lineal	69
5.1.3. Caso θ Función Trigonométrica	74
5.2. Regresión Lineal con Errores LSMA	77
6. Estimador de Whittle	91
6.1. Estimación	91
6.2. Teoría Asintótica	93
6.3. Simulaciones	95
7. Aplicaciones	128
7.1. Anillos de Árbol	129
8. Conclusiones y Trabajos Futuros	136
A. Apéndice	138

Índice de Tablas

3.1. Comparación varianza teórica del BLUE de la media constante μ de un proceso LSMA(1) con parámetro $\theta(u) = 3.5(u - 0.5)^2$	31
3.2. Comparación varianza teórica del BLUE del parámetro de tendencia β de un proceso LSMA(1) con parámetro $\theta(u) = 0.2 - u$	35
3.3. Comparación matriz de covarianza teórica del BLUE de β de una regresión lineal con errores LSMA(1) con parámetro $\theta(u) = \log(0.5 + u)$	39
3.4. Comparación matriz de covarianza teórica del BLUE de β de una regresión lineal con errores LSMA(2) de parámetros $\theta_1(u) = u - 0.5$, $\theta_2(u) = 0.5\sqrt{u} - 0.5$ y $\sigma(u) = \sqrt{0.5 + u}$	45
4.1. Comparación varianza teórica del BLUE de la media constante μ del proceso LSAR(3) con parámetros $\phi_1(u) = \frac{7}{6}(u - 0.5)^2$, $\phi_2(u) = \frac{1}{12}(12u^2 - 4u + 3)$ y $\phi_3(u) = \frac{1}{15}(-4u^2 + 2u + 4)$	55

4.2.	Comparación varianza teórica del BLUE de la media constante μ de un proceso LSARMA(1,1) con parámetros $\phi(u) = \frac{7}{6}(u - 0.5)^2$ y $\theta(u) = \frac{1}{6}(-6u^2 + 2u + 5)$	59
4.3.	Comparación varianza teórica del BLUE de β del proceso LSAR(1) con parámetro $\phi(u) = u - 0.2$	63
5.1.	Radio de Eficiencia: Varianza LSE v/s varianza BLUE de la media constante μ de un proceso LSMA(1) con parámetro $\theta(u) = u - 0.8$. .	72
5.2.	Radio de Eficiencia: Varianza LSE v/s varianza BLUE de la media constante μ de un proceso LSMA(1) con parámetro $\theta(u) = 0.2 + 0.5u$. .	73
5.3.	Radio de Eficiencia: Varianza LSE v/s varianza BLUE de la media constante μ de un proceso LSMA(1) con parámetro $\theta(u) = \sin(-0.2 - 1.1u)$	75
5.4.	Radio de Eficiencia: Varianza LSE v/s varianza BLUE para la media constante μ de un proceso LSMA(1) con parámetro $\theta(u) = \sin(0.5u + 0.2)$. .	76
5.5.	Matriz de covarianza teórica del LSE de β de una regresión lineal con errores LSMA(1) de parámetro $\theta(u) = 0.5 - u^2$	80
5.6.	Matriz de covarianza teórica del BLUE de β de una regresión lineal con errores LSMA(1) de parámetro $\theta(u) = 0.5 - u^2$	82

5.7.	Radio de Eficiencia: Determinante varianza LSE v/s determinante varianza BLUE de β para una regresión lineal con errores LSMA(1) de parámetro $\theta(u) = 0.5 - u^2$	84
5.8.	Radio de Eficiencia: Varianza LSE v/s varianza BLUE para β_1 de una regresión lineal con errores LSMA(1) de parámetro $\theta(u) = 0.5 - u^2$. .	84
5.9.	Comparación matriz de covarianza teórica del LSE de β de una regresión lineal con errores LSMA(2) de parámetros $\theta_1(u) = u - 0.5$, $\theta_2(u) = 0.5\sqrt{u} - 0.5$ y $\sigma(u) = \sqrt{0.5 + u}$	86
5.10.	Comparación matriz de covarianza teórica del BLUE de β de una regresión lineal con errores LSMA(2) de parámetros $\theta_1(u) = u - 0.5$, $\theta_2(u) = 0.5\sqrt{u} - 0.5$ y $\sigma(u) = \sqrt{0.5 + u}$	88
5.11.	Radio de Eficiencia: Determinante varianza LSE v/s determinante varianza BLUE de β de una regresión lineal con errores LSMA(2) de parámetros $\theta_1(u) = u - 0.5$, $\theta_2(u) = 0.5\sqrt{u} - 0.5$ y $\sigma(u) = \sqrt{0.5 + u}$	90
6.1.	Estimaciones del LSE y BLUE de la media constante μ , y estimadores de Whittle de los parámetros $\theta(u) = a_0 + a_1 u$ y $\sigma(u) = b_0$ de un proceso LSMA(1). Tamaño muestral $T = 1000$	98
6.2.	<i>Comparación de la varianza del LSE y BLUE de la media constante μ de un proceso LSMA(1) con parámetro $\theta(u) = u - 0.8$ usando el estimador de Whittle. Tamaño muestral $T = 1000$.</i>	99

6.3.	Estimaciones del LSE y BLUE de la media constante μ , y estimadores de Whittle de los parámetros $\theta(u) = a_0 + a_1u$ y $\sigma(u) = b_0 + b_1u$ de un proceso LSMA(1). Tamaño muestral $T = 1000$	104
6.4.	<i>Comparación de la varianza del LSE y BLUE de la media constante μ de un proceso LSMA(1) con parámetros $\theta(u) = 0.8 - 1.5u$ y $\sigma(u) = 1.5 - 0.5u$ usando el estimador de Whittle. Tamaño muestral $T = 1000$.</i>	105
6.5.	Estimaciones del LSE y BLUE de β , y estimadores de Whittle de los parámetros $\theta_1(u) = a_0 + a_1u$ y $\sigma(u) = b_0 + c_bu$ de un proceso LSMA(1). Tamaño muestral $T = 1000$	111
6.6.	<i>Comparación de la varianza del LSE y BLUE de β de una regresión lineal con errores LSMA(1) de parámetros $\theta(u) = 0.8u - 0.8$ y $\sigma(u) = 1 + 0.25u$ usando el estimador de Whittle. Tamaño muestral $T = 1000$.</i>	112
6.7.	Estimaciones del LSE y BLUE de β , y estimadores de Whittle de los parámetros $\theta_1(u) = a_0 + a_1u$ $\theta_2(u) = b_0 + b_1u$ y $\sigma(u) = c_0 + c_1u + c_2u^2$ de un proceso LSMA(2). Tamaño muestral $T = 1000$	118
6.8.	<i>Comparación de la varianza del LSE y BLUE de β de una regresión lineal con errores LSMA(2) de parámetros $\theta_1(u) = u - 0.7$, $\theta_2(u) = 0.5u$ y $\sigma(u) = 1.025 - 0.5u + 0.5u^2$ usando el estimador de Whittle. Tamaño muestral $T = 1000$.</i>	119

6.9.	Estimaciones del LSE y BLUE de β , y estimadores de Whittle de los parámetros $\theta_1(u) = a_0 + a_1u$ $\theta_2(u) = b_0 + b_1u$ y $\sigma(u) = c_0 + c_1u + c_2u^2$ de un proceso LSMA(2). Tamaño muestral $T = 1000$	125
6.10.	<i>Comparación de la varianza del LSE y BLUE de β de una regresión lineal con errores LSMA(2) de parámetros $\theta_1(u) = u - 0.5$, $\theta_2(u) = 0.5 - 0.5u$ y $\sigma(u) = 1.25 - u + u^2$ usando el estimador de Whittle. Tamaño muestral $T = 1000$.</i>	126
7.1.	Tabla resumen ajuste.	132
7.2.	Radio de Eficiencia: Varianza LSE v/s varianza BLUE Plug-in de μ de un proceso LSMA(2)	135

Índice de Figuras

3.1. Función de variación en el tiempo $\theta(u) = 3.5(u - 0.5)^2$	29
3.2. Simulación de un proceso LSMA(1) con parámetro $\theta(u) = 3.5(u - 0.5)^2$	29
3.3. ACF de un proceso LSMA(1) con parámetro $\theta(u) = 3.5(u - 0.5)^2$	30
3.4. PACF de un proceso LSMA(1) con parámetro $\theta(u) = 3.5(u - 0.5)^2$	30
3.5. Función de variación en el tiempo $\theta(u) = 0.2 - u$	33
3.6. Simulación de un proceso LSMA(1) con parámetro $\theta(u) = 0.2 - u$	33
3.7. ACF de un proceso LSMA(1) con parámetro $\theta(u) = 0.2 - u$	34
3.8. PACF de un proceso LSMA(1) con parámetro $\theta(u) = 0.2 - u$	34
3.9. Función de variación en el tiempo $\theta(u) = \log(0.5 + u)$	37
3.10. Simulación de un proceso LSMA(1) con parámetro $\theta(u) = \log(0.5 + u)$	37
3.11. ACF de un proceso LSMA(1) con parámetro $\theta(u) = \log(0.5 + u)$	38
3.12. PACF de un proceso LSMA(1) con parámetro $\theta(u) = \log(0.5 + u)$	38
3.13. Función de variación en el tiempo $x_1(u) = u$, $x_2(u) = e^{-u}$	42

3.14. Funciones de variación en el tiempo $\theta_1(u) = u - 0.5$, $\theta_2(u) = 0.5\sqrt{u} -$	
0.5.	42
3.15. Función de variación en el tiempo $\sigma(u) = \sqrt{0.5 + u}$	43
3.16. Simulación de un proceso LSMA(2) con parámetros $\theta_1(u) = u - 0.5$, $\theta_2(u) =$	
$0.5\sqrt{u} - 0.5$ y $\sigma(u) = \sqrt{0.5 + u}$	43
3.17. ACF de un proceso LSMA(2) con parámetros $\theta_1(u) = u - 0.5$, $\theta_2(u) =$	
$0.5\sqrt{u} - 0.5$ y $\sigma(u) = \sqrt{0.5 + u}$	44
3.18. PACF de un proceso LSMA(2) con parámetros $\theta_1(u) = u - 0.5$, $\theta_2(u) =$	
$0.5\sqrt{u} - 0.5$ y $\sigma(u) = \sqrt{0.5 + u}$	44
4.1. Funciones de variación en el tiempo $\phi_1(u) = \frac{7}{6}(u - 0.5)^2$, $\phi_2(u) =$	
$\frac{1}{12}(12u^2 - 4u + 3)$ y $\phi_3(u) = \frac{1}{15}(-4u^2 + 2u + 4)$	53
4.2. Simulación de un proceso LSAR(3) con parámetros $\phi_1(u) = \frac{7}{6}(u -$	
$0.5)^2$, $\phi_2(u) = \frac{1}{12}(12u^2 - 4u + 3)$ y $\phi_3(u) = \frac{1}{15}(-4u^2 + 2u + 4)$	53
4.3. ACF de un proceso LSAR(3) con parámetros $\phi_1(u) = \frac{7}{6}(u - 0.5)^2$, $\phi_2(u) =$	
$\frac{1}{12}(12u^2 - 4u + 3)$ y $\phi_3(u) = \frac{1}{15}(-4u^2 + 2u + 4)$	54
4.4. PACF de un proceso LSAR(3) con parámetros $\phi_1(u) = \frac{7}{6}(u - 0.5)^2$, $\phi_2(u) =$	
$\frac{1}{12}(12u^2 - 4u + 3)$ y $\phi_3(u) = \frac{1}{15}(-4u^2 + 2u + 4)$	54
4.5. Funciones de variación en el tiempo $\phi(u) = \frac{7}{6}(u - 0.5)^2$ y $\theta(u) =$	
$\frac{1}{6}(-6u^2 + 2u + 5)$	57

4.6. Simulación de un proceso LSARMA(1,1) con parámetros $\phi(u) = \frac{7}{6}(u - 0.5)^2$ y $\theta(u) = \frac{1}{6}(-6u^2 + 2u + 5)$	57
4.7. ACF de un proceso LSARMA(1,1) con parámetros $\phi(u) = \frac{7}{6}(u - 0.5)^2$ y $\theta(u) = \frac{1}{6}(-6u^2 + 2u + 5)$	58
4.8. PACF de un proceso LSARMA(1,1) con parámetros $\phi(u) = \frac{7}{6}(u - 0.5)^2$ y $\theta(u) = \frac{1}{6}(-6u^2 + 2u + 5)$	58
4.9. Función de variación en el tiempo $\phi(u) = u - 0.2$	61
4.10. Simulación de un proceso LSAR(1) con parámetro $\phi(u) = u - 0.2$. . .	61
4.11. ACF de un proceso LSAR(1) con parámetros $\phi(u) = u - 0.2$	62
4.12. PACF de un proceso LSAR(1) con parámetros $\phi(u) = u - 0.2$	62
5.1. Curvas de nivel de $R(\theta(a, b))$ para $\theta(u) = a + bu$	69
5.2. Superficie $R(\theta(a, b))$ para $\theta(u) = a + bu$	70
6.1. Función de variación en el tiempo $\theta(u) = u - 0.8$	96
6.2. Simulación de un proceso LSMA(1) con parámetro $\theta(u) = u - 0.8$. . .	96
6.3. ACF de un proceso LSMA(1) con parámetro $\theta(u) = u - 0.8$	97
6.4. PACF de un proceso LSMA(1) con parámetro $\theta(u) = u - 0.8$	97
6.5. Evolución de θ y σ por ventanas.	98
6.6. Función de variación en el tiempo $\theta(u) = 0.8 - 1.5u$	101
6.7. Función de variación en el tiempo $\sigma(u) = 1.5 - 0.5u$	102

6.8. Simulación de un proceso LSMA(1) con parámetros $\theta(u) = 0.8 - 1.5u$ y $\sigma(u) = 1.5 - 0.5u$	102
6.9. ACF de un proceso LSMA(1) con parámetros $\theta(u) = 0.8 - 1.5u$ y $\sigma(u) = 1.5 - 0.5u$	103
6.10. PACF de un proceso LSMA(1) con parámetros $\theta(u) = 0.8 - 1.5u$ y $\sigma(u) = 1.5 - 0.5u$	103
6.11. Evolución de θ y σ por ventanas.	104
6.12. Función de variación en el tiempo $x_1(u) = 1$, $x_2(u) = u$	107
6.13. Función de variación en el tiempo $\theta(u) = 0.8u - 0.8$	108
6.14. Función de variación en el tiempo $\sigma(u) = 1 + 0.25u$	108
6.15. Simulación de un proceso LSMA(1) con parámetros $\theta(u) = 0.8u - 0.8$ y $\sigma(u) = 1 + 0.25u$	109
6.16. ACF de un proceso LSMA(1) con parámetros $\theta(u) = 0.8u - 0.8$ y $\sigma(u) = 1 + 0.25u$	109
6.17. PACF de un proceso LSMA(1) con parámetros $\theta(u) = 0.8u - 0.8$ y $\sigma(u) = 1 + 0.25u$	110
6.18. Evolución de θ y σ por ventanas.	110
6.19. Función de variación en el tiempo $x_1(u) = u$, $x_2(u) = \sin(2\pi u)$	114
6.20. Funciones de variación en el tiempo $\theta_1(u) = u - 0.7$ y $\theta_2(u) = 0.5u$. .	115
6.21. Función de variación en el tiempo $\sigma(u) = 1.025 - 0.5u + 0.5u^2$	115

6.22. Simulación de un proceso LSMA(2) con parámetros $\theta_1(u) = u-0.7$, $\theta_2(u) =$ $0.5u$ y $\sigma(u) = 1.025 - 0.5u + 0.5u^2$	116
6.23. ACF de un proceso LSMA(2) con parámetros $\theta_1(u) = u-0.7$, $\theta_2(u) =$ $0.5u$ y $\sigma(u) = 1.025 - 0.5u + 0.5u^2$	116
6.24. PACF de un proceso LSMA(2) con parámetros $\theta_1(u) = u-0.7$, $\theta_2(u) =$ $0.5u$ y $\sigma(u) = 1.025 - 0.5u + 0.5u^2$	117
6.25. Evolución de θ_1 , θ_2 y σ por ventanas.	117
6.26. Función de variación en el tiempo $x_1(u) = 1$, $x_2(u) = u$	121
6.27. Funciones de variación en el tiempo $\theta_1(u) = u - 0.5$ y $\theta_2(u) = 0.5 - 0.5u$.	122
6.28. Función de variación en el tiempo $\sigma(u) = 1.25 - u + u^2$	122
6.29. Simulación de un proceso LSMA(2) con parámetros $\theta_1(u) = u-0.5$, $\theta_2(u) =$ $0.5 - 0.5u$ y $\sigma(u) = 1.25 - u + u^2$	123
6.30. ACF de un proceso LSMA(2) con parámetros $\theta_1(u) = u-0.5$, $\theta_2(u) =$ $0.5 - 0.5u$ y $\sigma(u) = 1.25 - u + u^2$	123
6.31. PACF de un proceso LSMA(2) con parámetros $\theta_1(u) = u-0.5$, $\theta_2(u) =$ $0.5 - 0.5u$ y $\sigma(u) = 1.25 - u + u^2$	124
6.32. Evolución de θ_1 , θ_2 y σ por ventanas.	124
7.1. Datos anillos de árbol.	130
7.2. ACF.	130
7.3. Periodograma suavizado.	131

7.4. Ajuste splines.	131
7.5. Análisis de residuos.	133
7.6. Ajuste.	133

Capítulo 1

Introducción

La propiedad de estacionaridad en las series de tiempo es una hipótesis que no necesariamente se cumple. En la práctica se pueden encontrar una gran variedad de series de tiempo en donde la estructura de covarianza, la media y la varianza del proceso no son constantes en el tiempo. Una de las metodologías propuestas, llamada procesos localmente estacionarias (LS) desarrollada por Dahlhaus (1997) se está convirtiendo en una herramienta importante para el análisis de series de tiempo no estacionarias. Esta metodología toma como hipótesis, que los parámetros de las series de tiempo no estacionarias varían suavemente en el tiempo, con lo cuál estas series podrían ser aproximadas localmente mediante series de tiempo estacionarias.

Muchos autores han sugerido definiciones para este tipo de procesos LS, incluyen-

do a Silverman et al. (1957), Priestley (1965) y Dahlhaus (1996b) quién desarrolló una definición formal de una familia de procesos LS que ha sido ampliamente discutida en la literatura, como por ejemplo Dahlhaus and Giraitis (1998), Dahlhaus (2000), Dahlhaus and Polonik (2006) entre otros.

La estimación de los parámetros ha sido estudiada por Dahlhaus (1996b), Dahlhaus (1996a), Dahlhaus (1997) para procesos localmente estacionarios de corta memoria (LSSM). Sin embargo, la estimación de la media de tales procesos ha recibido mucha menos atención.

Por otra parte, la teoría de los procesos LS se ha ampliado a series de larga memoria (LSLM), ver por ejemplo Beran (2009), Genton and Perrin (2004) y Jensen and Whitcher (2000).

La estimación de parámetros para los proceso LSLM ha sido estudiada por Jensen and Whitcher (2000), Beran (2009), Palma and Olea (2010), entre otros. Sin embargo, al igual que en los procesos LSSM, la estimación de la media de tales procesos ha recibido poca atención.

En este trabajo estudiaremos al estimador lineal e insesgado de varianza mínima (BLUE) para la media de un proceso LSSM, para lo cual veremos la consistencia, varianza asintótica y un teorema del límite central para este estimador. Además compararemos el BLUE con el estimador de mínimos cuadrados ordinarios (LSE),

mediante la eficiencia relativa en donde se analizará si tienen un comportamiento asintótico de igual orden o no, ya que en los procesos estacionarios de corta y larga memoria (ARMA, ARFIMA), la eficiencia relativa converge asintóticamente a 1. Ver Grenander and Rosenblatt (1957), Adenstedt (1974) y Palma (2007).

Los siguientes capítulos de este trabajo están organizadas como sigue. En el capítulo 2 se introducen los procesos localmente estacionarios de corta y larga memoria, en donde se dan algunos ejemplos clásicos. El capítulo 3 se enfoca a las propiedades asintóticas del estimador BLUE de β del siguiente modelo de regresión:

$$Y_{t,T} = X'(\frac{t}{T})\beta + \varepsilon_{t,T}, \quad t = 1, \dots, T.$$

Donde $X'(\frac{t}{T}) = \left(x_1(\frac{t}{T}), \dots, x_k(\frac{t}{T})\right)$ es un vector (fila) de k componentes no estocásticas, tales que $x_i(\cdot) \in C^2([0, 1])$ $i = 1, \dots, k$, $\beta = (\beta_1, \dots, \beta_k)'$ un vector de parámetros de la regresión y $\varepsilon_{t,T}$ es un proceso localmente estacionario de medias móviles de orden q (LSMA(q)).

Notamos que si $k = 1$ y $x_1(u) = 1$ para todo $u \in [0, 1]$ tenemos el caso particular de un proceso LSMA(q) de media constante μ . Por otro lado si $k = 1$ y $x_1(\cdot) \in C^2([0, 1])$ no constante, tenemos el caso particular de un proceso LSMA(q) con de tendencia de variación en el tiempo.

El capítulo 4 trata de dar una extensión de estos resultados para procesos localmente estacionarios autorregresivos de medias móviles de ordenes p, q respectivamente

(LSARMA(p, q)), dando conjeturas de las varianzas a asintóticas del BLUE de β para este caso.

En el capítulo 5 se estudia la eficiencia relativa de los estimadores BLUE y LSE en el caso de media constante y en un modelo de regresión como en el capítulo anterior. Para esto se verán simulaciones para distintos casos en donde el parámetro de medias móviles varía en el tiempo de forma lineal, trigonométrica, etc.

En el capítulo 6 se estudia la eficiencia relativa de los estimadores BLUE y LSE en el caso de media constante y en un modelo de regresión como en el capítulo anterior pero esta vez usaremos el método de Whittle (ver Dahlhaus (1996b), Dahlhaus (1996a), Dahlhaus (1997)) para estimar los parámetros del proceso LSMA(q). Para esto se verán simulaciones para distintos casos en donde el parámetro de medias móviles varía en el tiempo de forma lineal, cuadrática, etc.

En el capítulo 7, se da una aplicación a datos reales, en donde se ve el estimador BLUE comparado con el estimador LSE, esta es analizada mediante la eficiencia relativa. Es importante mencionar que de este análisis se obtiene la respuesta si es o no necesario buscar el estimador BLUE o simplemente quedarnos con el estimador LSE, ya que este último es más rápido (computacionalmente) de calcular y no depende de los parámetros. Finalmente, el capítulo 8 están las conclusiones de este trabajo, mientras que las demostraciones de los resultados establecidos se encuentran en el apéndice.

Capítulo 2

Procesos Localmente Estacionarios

2.1. Definición

Definición 2.1.

Un proceso Localmente Estacionario con función de transferencia A^0 y función de tendencia μ puede ser definido por la representación espectral

$$Y_{t,T} = \mu\left(\frac{t}{T}\right) + \int_{-\pi}^{\pi} A_{t,T}^0(\lambda) e^{i\lambda t} dB(\lambda) \quad (2.1)$$

para $t = 1, \dots, T$. Donde $B(\lambda)$ es un movimiento Browniano en $[-\pi, \pi]$, $\mu(\cdot)$ es una función continua, y existe una constante K positiva y una función $A : [0, 1] \times \mathbb{R} \rightarrow \mathbb{C}$, 2π -periódica, con $A(u, -\lambda) = \overline{A(u, \lambda)}$ tal que

$$\sup_{t,\lambda} \left| A_{t,T}^0 - A\left(\frac{t}{T}, \lambda\right) \right| \leq \frac{K}{T} \quad (2.2)$$

para todo T .

Se tiene que la función de transferencia $A_{t,T}^0(\lambda)$ de esta clase de procesos no estacionarios cambia suavemente en el tiempo de manera que se pueden aproximar localmente por un proceso estacionario.

Para analizar las propiedades asintóticas de los procesos que satisfacen la definición 2.1, Dahlhaus (1996b) estableció un reescalamiento de el tiempo mediante el cambio de variable $u = t/T$, con esto, se puede analizar de mejor manera las propiedades asintóticas de los estimadores, se tiene además que si T es lo suficientemente grande, se tendrá mayor información disponible de la estructura local de la serie, ya que se tendría una grilla más fina del intervalo $[0, 1]$.

Por otro lado se puede notar que si A^0 no depende de t y T , entonces $Y_{t,T}$ no depende de T , y se obtiene la representación espectral ordinaria de un proceso estacionario y así la teoría asintótica de los procesos estacionarios es un caso particular de este tipo de procesos.

A continuación se presentan algunos ejemplos de procesos LS:

Ejemplo 2.1.1.

Suponga que $\{Y_t\}_t$ es un proceso estacionario con representación espectral

$$Y_t = \int_{-\pi}^{\pi} A(\lambda) e^{i\lambda t} d\xi(\lambda)$$

donde $A(\lambda)$ es la función de transferencia del proceso $\{Y_t\}_t$. Sean

$$\mu : [0, 1] \rightarrow \mathbb{R}, \quad \sigma : [0, 1] \rightarrow \mathbb{R}^+$$

funciones continuas. Entonces

$$X_{t,T} = \mu\left(\frac{t}{T}\right) + \sigma\left(\frac{t}{T}\right)Y_t,$$

es un proceso LS con $A_{t,T}^0(\lambda) = A\left(\frac{t}{T}, \lambda\right) = \sigma\left(\frac{t}{T}\right)A(\lambda)$.

Ejemplo 2.1.2.

Considere el siguiente proceso

$$Y_{t,T} = \phi\left(\frac{t}{T}\right)Y_{t-1,T} + \sigma\left(\frac{t}{T}\right)\epsilon_t, \quad t \in \mathbb{Z}, \quad (2.3)$$

donde $\{\epsilon_t\}_t$ una secuencia independiente idénticamente distribuida (iid) de media cero y varianza uno. Asumimos que $\sigma(u)$ y $\phi(u)$ son continuos en $\mathbb{R}$ con $\sigma(u) = \sigma(0)$, $\phi(u) = \phi(0)$ para $u < 0$ y $\sigma(u) = \sigma(1)$, $\phi(u) = \phi(1)$ para $u > 1$, las restricciones para los parámetros son $|\phi(u)| < 1$ y $\sigma(u) > 0$ para todo $u \in [0, 1]$ y además son derivables para todo $u \in (0, 1)$ con derivada acotada.

Dado que la secuencia $\{\epsilon_t\}_t$ es iid, el *Teorema de Cramer* garantiza que

$$\epsilon_t = \int_{-\pi}^{\pi} (2\pi)^{-1/2} e^{i\lambda t} d\xi(\lambda), \quad \text{para todo } t,$$

Se puede ver que

$$Y_{t,T} := \int_{-\pi}^{\pi} e^{i\lambda t} A_{t,T}^0(\lambda) d\xi(\lambda),$$

donde

$$A_{t,T}^0(\lambda) = \sum_{\ell=0}^{\infty} \left[\prod_{j=0}^{\ell-1} \phi\left(\frac{t-j}{T}\right) \right] \sigma\left(\frac{t-\ell}{T}\right) e^{-i\lambda\ell}.$$

es la solución de la ecuación (2.3). Ahora que se conoce $A_{t,T}^0(\lambda)$, se puede mostrar que la función $A(u, \lambda)$ definida por

$$A(u, \lambda) = \sigma(u) \left(1 - \phi(u) e^{-i\lambda}\right)^{-1},$$

cumple que

$$\sup_{t,\lambda} \left| A_{t,T}^0(\lambda) - A\left(\frac{t}{T}, \lambda\right) \right| \leq K \frac{\log^3(T)}{T},$$

es decir, satisface la condición (2.2) de la definición 2.1, ver Dahlhaus (1996b) para más detalles.

Ejemplo 2.1.3.

Otro ejemplo de procesos LS está dado por la siguiente expansión infinita de medias móviles

$$Y_{t,T} = \mu + \sigma\left(\frac{t}{T}\right) \sum_{j=0}^{\infty} \psi_j\left(\frac{t}{T}\right) \epsilon_{t-j} \quad (2.4)$$

donde $\{\epsilon_t\}_t$ es una secuencia de ruido blanco gaussiano de media cero y varianza unitaria, y $\{\psi_j(u)\}_j$ son coeficientes que satisfacen $\sum_{j=0}^{\infty} \psi_j(u)^2 < \infty$ para todo $u \in [0, 1]$. En este caso, la función de transferencia del proceso dado por la ecuación (2.4), es $A_{t,T}^0(\lambda) = \sigma\left(\frac{t}{T}\right) \sum_{j=0}^{\infty} \psi_j\left(\frac{t}{T}\right) e^{-i\lambda j} = A\left(\frac{t}{T}, \lambda\right)$, la cual satisface trivialmente la condición (2.2). El modelo dado por la ecuación (2.4) generaliza la expansión de Wold para procesos lineales estacionarios permitiendo que los coeficientes de la expansión infinita de medias móviles varíen suavemente en el tiempo.

2.2. Procesos Localmente Estacionarios de Corta Memoria

Las funciones de autocovarianza y autocorrelación se conocen como indicadores de la memoria de una serie de tiempo. Una manera sencilla de clasificar el tipo de memoria de una serie de tiempo estacionaria es mediante la cuantificación de la tasa de decaimiento de autocovarianzas o autocorrelaciones. En concreto, si la autocorrelación de un proceso $\{Y_t\}_t$ tiene un tipo de decaimiento exponencial a cero al incrementar el lag (k). Entonces $\{Y_t\}_t$ es un proceso de corta memoria (SM), tales como los procesos ARMA. Ver Brockwell and Davis (1991) para obtener más detalles. Este concepto se puede extender a los procesos LS, mediante la siguiente definición, ver Ferreira et al. (2013) y Palma et al. (2013).

Definición 2.2.

Un proceso $\{Y_{t,T}\}_t$ dado por la definición 2.1 con representación infinita de medias móviles definida por la ecuación (2.4), se dice Localmente Estacionario de Corta Memoria (LSSM) si existen constantes a y K positivas tales que los coeficientes de la expansión de medias móviles cumplen lo siguiente

$$\forall j \geq 1, \forall u \in [0, 1], \quad |\psi_j(u)| \leq K e^{-aj}. \quad (2.5)$$

Ejemplo 2.2.1.

Sea el proceso definido por

$$Y_{t,T} = \sum_{j=0}^{\infty} \phi\left(\frac{t}{T}\right)^j \epsilon_{t-j}, \quad (2.6)$$

donde $\{\epsilon_t\}_t$ es una secuencia de ruido blanco gaussiano de media cero y varianza unitaria, y $\phi(u) = 0.5u + 0.1$, $u \in [0, 1]$, luego vemos que para $j \geq 1$

$$\begin{aligned} |\phi(u)^j| &= e^{j \ln(0.5u+0.1)} \\ &\leq e^{j \ln(0.6)} \end{aligned}$$

Luego de acuerdo a la definición 2.2, $K = 1$ y $a = -\ln(0.6)$. Por tanto el proceso dado por la ecuación (2.6) es un proceso LSSM.

2.2.1. Procesos Localmente Estacionarios de Medias Móviles de Orden q

Definición 2.3.

Un caso particular del proceso dado por la ecuación (2.4) es el proceso de medias móviles de orden q definido por

$$Y_{t,T} = \mu\left(\frac{t}{T}\right) + \sigma\left(\frac{t}{T}\right) \sum_{j=0}^q \theta_j\left(\frac{t}{T}\right) \epsilon_{t-j} \quad (2.7)$$

para $t = 1, \dots, T$, donde $\mu(\cdot)$, $\sigma(\cdot)$ son funciones continuas y $\sigma(u) > 0$ para todo $u \in [0, 1]$, $\theta_0(u) \equiv 1$ y $\{\epsilon_t\}_t$ es una secuencia de ruido blanco de media cero y varianza uno. ($\epsilon_t \sim RB(0, 1)$). La función de transferencia es

$$A\left(\frac{t}{T}, \lambda\right) = \sigma\left(\frac{t}{T}\right) \sum_{j=0}^q \theta_j\left(\frac{t}{T}\right) e^{-i\lambda j}. \quad (2.8)$$

Y la densidad espectral que varía en el tiempo está dada por

$$f\left(\frac{t}{T}, \lambda\right) = \frac{\sigma\left(\frac{t}{T}\right)^2}{2\pi} \left| \sum_{j=0}^q \theta_j\left(\frac{t}{T}\right) e^{i\lambda j} \right|^2 \quad (2.9)$$

para $\lambda \in [-\pi, \pi]$.

Proposición 2.2.1.

De la definición 2.3 se tienen las siguientes propiedades:

$$1) \quad \mathbb{E}(Y_{t,T}) = \mu\left(\frac{t}{T}\right).$$

$$2) \quad Var(Y_{t,T}) = \sigma\left(\frac{t}{T}\right)^2 \sum_{j=0}^q \theta_j\left(\frac{t}{T}\right)^2.$$

$$3) \quad Cov(Y_{t,T}, Y_{s,T}) = \begin{cases} \sigma\left(\frac{t}{T}\right)\sigma\left(\frac{s}{T}\right) \sum_{j=0}^q \theta_{t-s+j}\left(\frac{t}{T}\right)\theta_j\left(\frac{s}{T}\right) & , \quad 0 < t-s \leq q \\ 0 & , \quad t-s > q \end{cases}$$

para $t, s = 1, \dots, T$, $t > s$ y $\theta_j(u) = 0$ si $j > q$.

Ejemplo 2.2.2.

Un caso particular de (2.7) es un proceso localmente estacionario de medias móviles de orden $q = 1$, LSMA(1), dado por

$$Y_{t,T} = \mu\left(\frac{t}{T}\right) + \sigma\left(\frac{t}{T}\right) \left[\theta\left(\frac{t}{T}\right) \epsilon_{t-1} + \epsilon_t \right],$$

$t = 1, \dots, T$ donde $\{\epsilon_t\}_t$ es una secuencia de ruido blanco de media cero y varianza uno. La estructura de covarianza del modelo está dada por

$$Cov(Y_{t,T}, Y_{s,T}) = \begin{cases} \sigma\left(\frac{t}{T}\right)^2 \left[1 + \theta\left(\frac{t}{T}\right)^2 \right] & , \quad s = t \\ \sigma\left(\frac{t}{T}\right)\sigma\left(\frac{t-1}{T}\right)\theta\left(\frac{t}{T}\right) & , \quad s = t-1 \\ \sigma\left(\frac{t}{T}\right)\sigma\left(\frac{t+1}{T}\right)\theta\left(\frac{t+1}{T}\right) & , \quad s = t+1 \\ 0 & , \quad \text{o.c.} \end{cases}$$

En este caso, la función de transferencia está dada por

$$A_{t,T}^0(\lambda) = A\left(\frac{t}{T}, \lambda\right) = \sigma\left(\frac{t}{T}\right) \left[1 + \theta\left(\frac{t}{T}\right) e^{-i\lambda}\right]$$

Además, la densidad espectral que varía en el tiempo es

$$f\left(\frac{t}{T}, \lambda\right) = \frac{1}{2\pi} \left|A\left(\frac{t}{T}, \lambda\right)\right|^2 = \frac{\sigma\left(\frac{t}{T}\right)^2}{2\pi} \left[1 + \theta\left(\frac{t}{T}\right)^2 + 2\theta\left(\frac{t}{T}\right) \cos(\lambda)\right],$$

ver Dahlhaus (1996a).

2.3. Procesos Localmente Estacionarios de Larga Memoria

Un proceso de larga memoria $\{Y_{t,T}\}_t$ localmente estacionario puede ser definido especificando la decadencia hiperbólica de la función de autocovarianzas, ver Ferreira et al. (2013) y Palma et al. (2013).

Definición 2.4.

Un proceso $\{Y_{t,T}\}_t$ dado por la definición 2.1 con representación infinita de medias móviles definida por la ecuación (2.4), se dice Localmente Estacionario de Larga Memoria (LSLM) si existe una constante K positiva tal que los coeficientes de la expansión de medias móviles cumplen lo siguiente

$$|\psi_j(u)| \leq K j^{d-1}. \quad (2.10)$$

Para $u \in [0, 1]$ y algún $d \in (0, 1/2)$.

Ejemplo 2.3.1.

Una generalización del modelo de ruido fraccionario es el proceso de ruido fraccionario localmente estacionario (LSFN), el cual está dado por la ecuación (2.4) en donde los coeficientes

$$\psi_j(u) = \frac{\Gamma[j + d(u)]}{\Gamma[j + 1]\Gamma[d(u)]}$$

donde $\Gamma(\cdot)$ es la función Gamma y $d(\cdot)$ es el parámetro de larga memoria que varia suavemente en el tiempo. De Palma (2010), se tiene que las covarianzas del proceso LSFN son

$$Cov(Y_{t,T}, Y_{s,T}) = \sigma\left(\frac{t}{T}\right)\sigma\left(\frac{s}{T}\right) \frac{\Gamma\left[1 - d\left(\frac{s}{T}\right) - d\left(\frac{t}{T}\right)\right] \Gamma\left[s - t - d\left(\frac{s}{T}\right)\right]}{\Gamma\left[1 - d\left(\frac{s}{T}\right)\right] \Gamma\left[d\left(\frac{s}{T}\right)\right] \Gamma\left[s - t + 1 - d\left(\frac{t}{T}\right)\right]}.$$

para $s, t \in \{1, \dots, T\}$, $s > t$ y la densidad espectral que varía en el tiempo está dada por

$$f\left(\frac{t}{T}, \lambda\right) = \frac{\sigma\left(\frac{t}{T}\right)^2}{2\pi} \left[2 \sin\left(\frac{\lambda}{2}\right)\right]^{-2d(t/T)},$$

para $\lambda \in [-\pi, \pi]$. Además se tiene que

$$f(u, \lambda) \sim \frac{\sigma(u)^2}{2\pi} |\lambda|^{-2d(u)}.$$

Donde $a_\lambda \sim b_\lambda$ significa que $a_\lambda/b_\lambda \rightarrow 1$ si $|\lambda| \rightarrow 0$

Ejemplo 2.3.2.

Otro ejemplo es el proceso localmente estacionario integrado fraccionadamente de medias móviles LSARFIMA $\left(0, d(u), 1\right)$, el cual está dado por la ecuación

$$Y_{t,T} = \sigma\left(\frac{t}{T}\right) \left[1 + \theta\left(\frac{t}{T}\right)B\right] (1 - B)^{-d(t/T)} \epsilon_t$$

donde B es el operador de rezagos, $\theta(\cdot)$ es el parámetro de medias móviles que varia suavemente en el tiempo, con la condición $|\theta(u)| < 1$ para todo $u \in [0, 1]$ y $d(\cdot)$ es el parámetro de larga memoria que varia suavemente en el tiempo. De Palma (2010), se tiene que las covarianzas del proceso LSARFIMA $(0, d(u), 1)$ son

$$\begin{aligned} Cov(Y_{t,T}, Y_{s,T}) &= \sigma\left(\frac{t}{T}\right)\sigma\left(\frac{s}{T}\right) \frac{\Gamma\left[1 - d\left(\frac{s}{T}\right) - d\left(\frac{t}{T}\right)\right] \Gamma\left[s - t - d\left(\frac{s}{T}\right)\right]}{\Gamma\left[1 - d\left(\frac{s}{T}\right)\right] \Gamma\left[d\left(\frac{s}{T}\right)\right] \Gamma\left[s - t + 1 - d\left(\frac{t}{T}\right)\right]} \\ &\times \left[1 + \theta\left(\frac{s}{T}\right)\theta\left(\frac{t}{T}\right) - \theta\left(\frac{s}{T}\right) \frac{s - t - d\left(\frac{t}{T}\right)}{s - t - 1 + d\left(\frac{s}{T}\right)} - \theta\left(\frac{t}{T}\right) \frac{s - t - d\left(\frac{s}{T}\right)}{s - t - 1 + d\left(\frac{t}{T}\right)}\right] \end{aligned}$$

para $s, t \in \{1, \dots, T\}$, $s > t$.

2.4. Covarianza Local

Definición 2.5.

Sea $\{Y_{t,T}\}_t$ un proceso LS que satisface la definición 2.1, con densidad espectral que evoluciona en el tiempo dada por $f(u, \lambda) = \frac{1}{2\pi} |A(u, \lambda)|^2$. Se define la autocovarianza local de lag k del proceso en el tiempo u por

$$\gamma(u, k) = \int_{-\pi}^{\pi} f(u, \lambda) e^{i\lambda k} d\lambda, \quad k \in \mathbb{Z}. \quad (2.11)$$

de Dahlhaus (1996b) se tiene que el proceso tiene a nivel local la misma función de autocovarianza, pues

$$\begin{aligned} Cov(Y_{[uT],T}, Y_{[uT]+k,T}) &= \int_{-\pi}^{\pi} A_{[uT],T}^0(\lambda) A_{[uT]+k,T}^0(-\lambda) e^{i\lambda k} d\lambda \\ &= \gamma(u, k) + O(T^{-1}), \end{aligned} \quad (2.12)$$

uniformemente en u y k . Así la expresión $\gamma(u, k)$ justifica la covarianza local del proceso en el tiempo $u = t/T$.

Proposición 2.4.1.

Para un proceso LSMA(1) con media constante μ y $\sigma(u)^2 = 1$, definido por

$$Y_{t,T} = \mu + \theta\left(\frac{t}{T}\right)\epsilon_{t-1} + \epsilon_t,$$

se tiene que

$$\gamma(u, k) = \begin{cases} 1 + \theta(u)^2 & , \quad k = 0 \\ \theta(u) & , \quad |k| = 1. \end{cases}$$

Capítulo 3

Regresión Lineal con Errores

LSMA(q)

En este capítulo estudiamos el marco teórico de las propiedades asintóticas del BLUE para el vector de parámetros β de una regresión lineal, en donde los k (≥ 1) regresores son no estocásticos de variación suave en el tiempo, y las perturbaciones son un proceso LSMA(q), es decir, analizaremos la teoría suponiendo que los parámetros del proceso LSMA(q) son conocidos. Además se comparan las varianzas teóricas exactas, muestrales y asintóticas del BLUE de β mediante estudios de simulación.

3.1. Definición

Definición 3.1.

Un proceso Localmente Estacionario con función de transferencia A^0 puede ser definido por la representación espectral

$$Y_{t,T} = X'(\frac{t}{T})\beta + \int_{-\pi}^{\pi} A_{t,T}^0(\lambda)e^{i\lambda t}dB(\lambda) \quad (3.1)$$

para $t = 1, \dots, T$. Donde $X'(\frac{t}{T}) = \left(x_1(\frac{t}{T}), \dots, x_k(\frac{t}{T})\right)$ es un vector de k componentes no estocásticas, tales que $x_i(\cdot) \in C^2([0, 1])$ $i = 1, \dots, k$, $\beta = (\beta_1, \dots, \beta_k)'$ es un vector de parámetros desconocidos de la regresión, $B(\lambda)$ es un movimiento Browniano en $[-\pi, \pi]$, además existe una constante K positiva y una función $A : [0, 1] \times \mathbb{R} \rightarrow \mathbb{C}$, 2π -periódica, con $A(u, -\lambda) = \overline{A(u, \lambda)}$ tal que

$$\sup_{t, \lambda} |A_{t,T}^0 - A(\frac{t}{T}, \lambda)| \leq \frac{K}{T} \quad (3.2)$$

para todo T .

Observación 3.1.1.

Notamos que si $k = 1$ y $x_1(u) = 1$ para todo $u \in [0, 1]$ tenemos el caso particular de un proceso con media constante μ . Por otro lado si $k = 1$ y $x_1(\cdot) \in C^2([0, 1])$ no constante, tenemos el caso particular de un proceso con de tendencia de variación en el tiempo $x_1(u)\beta$.

Definición 3.2.

Un ejemplo de estos procesos está dado por la siguiente expansión infinita de medias móviles

$$Y_{t,T} = X'(\frac{t}{T})\beta + \sigma(\frac{t}{T}) \sum_{j=0}^{\infty} \psi_j(\frac{t}{T})\epsilon_{t-j} \quad (3.3)$$

Donde $X'(\frac{t}{T}) = \left(x_1(\frac{t}{T}), \dots, x_k(\frac{t}{T})\right)$ es un vector de k componentes no estocásticas, tales que $x_i(\cdot) \in C^2([0, 1])$ $i = 1, \dots, k$, $\beta = (\beta_1, \dots, \beta_k)'$ es un vector de parámetros desconocidos de la regresión, $\{\epsilon_t\}_t$ es una secuencia de ruido blanco de media cero y varianza unitaria, y $\{\psi_j(u)\}_j$ son coeficientes que satisfacen $\sum_{j=0}^{\infty} \psi_j(u)^2 < \infty$ para todo $u \in [0, 1]$.

Definición 3.3.

Otro ejemplo de estos procesos está dado por la expansión de medias móviles de orden q dada por

$$Y_{t,T} = X'(\frac{t}{T})\beta + \sigma(\frac{t}{T}) \sum_{j=0}^q \theta_j(\frac{t}{T})\epsilon_{t-j} \quad (3.4)$$

para $t = 1, \dots, T$, donde $\theta_0(u) \equiv 1$ y $\{\epsilon_t\}_t$ es una secuencia de ruido blanco de media cero y varianza uno. $X'(\frac{t}{T}) = \left(x_1(\frac{t}{T}), \dots, x_k(\frac{t}{T})\right)$ es un vector de k componentes no estocásticas, tales que $x_i(\cdot) \in C^2([0, 1])$ $i = 1, \dots, k$, $\beta = (\beta_1, \dots, \beta_k)'$ es un vector de parámetros desconocidos de la regresión.

3.2. Estimación

Consideremos el proceso $\{Y_{t,T}\}_t$ dado por la *definición 3.3*, ahora si definimos $Y_T = (Y_{1,T}, Y_{2,T}, \dots, Y_{T,T})'$, X_T la matriz de diseño de la regresión y Γ la matriz de covarianzas de $\varepsilon_T = (\varepsilon_{1,T}, \dots, \varepsilon_{T,T})'$ dada por

$$\Gamma = \left\{ \int_{[-\pi, \pi]} e^{i\lambda(r-s)} A_{r,T}^0(\lambda) \overline{A_{s,T}^0(\lambda)} d\lambda \right\}_{r,s=1, \dots, T},$$

y

$$A_{t,T}^0(\lambda) = \sigma\left(\frac{t}{T}\right) \sum_{j=0}^q \theta_j\left(\frac{t}{T}\right) e^{-i\lambda j} = A\left(\frac{t}{T}, \lambda\right) \quad (3.5)$$

se tiene que el BLUE de β está dado por

$$\tilde{\beta}_{T,\Theta} = \left(X_T' \Gamma^{-1} X_T \right)^{-1} X_T' \Gamma^{-1} Y_T \quad (3.6)$$

donde $\Theta = (\theta_1, \dots, \theta_q, \sigma)'$. Por otro lado, tenemos que BLUE es insesgado y su varianza es

$$Var(\tilde{\beta}_{T,\Theta}) = \left(X_T' \Gamma^{-1} X_T \right)^{-1}. \quad (3.7)$$

Ahora nos interesa estudiar el comportamiento asintótico de $Var(\tilde{\beta}_{T,\Theta})$, pero de (3.7) notamos que en primer lugar la matriz Γ debe ser invertible, esto se aborda en la *proposición 3.3.1*. Luego necesitamos conocer la forma de Γ^{-1} , pero por otro lado se sabe que el número de operaciones para invertir una matriz cuadrada de dimensiones $T \times T$ es del orden $O(T^3)$, ver Gastinel (1966), por tanto a priori es complicado obtener una expresión simplificada para $Var(\tilde{\beta}_{T,\Theta})$.

3.3. Teoría Asintótica

En esta sección se darán las principales propiedades asintóticas del BLUE de β para un proceso LSMA(q). Concretamente, se mostrará la consistencia de este estimador, también veremos la tasa de crecimiento de la varianza y por último un *Teorema del Límite Central*. Estas propiedades están dadas bajo las siguientes condiciones de regularidad.

Supuestos 3.1.

S3.1 De la definición 3.3, $\theta_0(u) \equiv 1$ para todo $u \in [0, 1]$, $\theta_j(\cdot) \in C^2([0, 1])$ para todo $j \in \{1, \dots, q\}$ con derivadas acotadas.

S3.2 Las raíces del polinomio $p(z) = 1 + \theta_1(u)z + \theta_2(u)z^2 + \dots + \theta_q(u)z^q$ están fuera del disco unitario para todo $u \in [0, 1]$.

S3.3 $\sigma(\cdot) \in C^2([0, 1])$ tal que $\sigma(u) > 0$ para todo $u \in [0, 1]$.

S3.4 Los vectores regresores no estocástico son funciones continuas tales que $\lim_{t/T \rightarrow u} X(t/T) = X(u)$ para todo $u \in [0, 1]$.

S3.5 Cada componente del vector $X(\cdot)$ está en $C^2([0, 1])$.

S3.6 Existen constantes positivas a y K , tales que $|\sigma(u)\psi_j(u)| \leq Ke^{-aj}$, para $j \geq 1$ y para todo $u \in [0, 1]$.

Proposición 3.3.1.

Sea $\{Y_{t,T}\}_t$ un proceso que satisface la definición 2.3 y cumple con los supuestos S3.1-

S3.6. Entonces la matriz

$$\Gamma = \left\{ \int_{[-\pi, \pi]} e^{i\lambda(r-s)} A_{r,T}^0(\lambda) \overline{A_{s,T}^0(\lambda)} d\lambda \right\}_{r,s=1,\dots,T}$$

es invertible.

Teorema 3.1 (Varianza asintótica).

Sea $\{Y_{t,T}\}_t$ un proceso que satisface la definición 3.3 y los supuestos S3.1-S3.6. Sea

$\tilde{\beta}_{T,\Theta}$ el BLUE de β . Entonces

$$TVar(\tilde{\beta}_{T,\Theta}) \rightarrow V = \left[\int_0^1 \frac{X(u)X'(u)}{\sigma(u)^2 \left[\sum_{j=0}^q \theta_j(u) \right]^2} du \right]^{-1}. \quad (3.8)$$

Cuando $T \rightarrow \infty$. En términos de la densidad espectral se tiene que

$$TVar(\tilde{\beta}_{T,\Theta}) \rightarrow V = 2\pi \left[\int_0^1 \frac{X(u)X'(u)}{f(u,0)} du \right]^{-1}. \quad (3.9)$$

Cuando $T \rightarrow \infty$.

La consistencia está establecida en el siguiente *Teorema*

Teorema 3.2 (Consistencia).

Sea $\{Y_{t,T}\}_t$ un proceso que satisface la definición 3.3 y los supuestos S3.1-S3.6. Sea

$\tilde{\beta}_{T,\Theta}$ el BLUE de β . Entonces $\tilde{\beta}_{T,\Theta}$ es un estimador consistente, es decir,

$$\tilde{\beta}_{T,\Theta} \xrightarrow{\mathbb{P}} \beta,$$

cuando $T \rightarrow \infty$.

Teorema 3.3 (Normalidad).

Sea $\{Y_{t,T}\}_t$ un proceso que satisface la definición 3.3 y los supuestos S3.1-S3.6, donde $\{\epsilon_t\}_t$ es una secuencia de errores independientes e idénticamente distribuidas tal que $\mathbb{E}(\epsilon_t) = 0$, $\text{Var}(\epsilon_t) = 1$ y el n -ésimo cumulante $\kappa_n < \infty$ para todo $n \geq 3$. Sea $\tilde{\beta}_{T,\Theta}$ el BLUE de β . Entonces

$$\sqrt{T}(\tilde{\beta}_{T,\Theta} - \beta) \xrightarrow{\mathcal{D}} N(0, V)$$

cuando $T \rightarrow \infty$, donde V está dado por (3.8).

Ejemplo 3.3.1.

Sea el proceso

$$Y_{t,T} = \mu + \theta\left(\frac{t}{T}\right)\epsilon_{t-1} + \epsilon_t, \quad t = 1, \dots, T.$$

Donde $\forall u \in [0, 1], \theta(u) = \theta$ constante, tal que $|\theta| < 1$ y $\epsilon_t \sim RB(0, 1)$. Es decir $\{Y_{t,T}\}_t$ es un proceso MA(1). Sea $\tilde{\mu}_{T,\Theta}$ el BLUE de μ , luego por el Teorema 3.1 se tiene que

$$TVar(\tilde{\mu}_{T,\Theta}) \sim \left[\int_0^1 \frac{1}{[1 + \theta(u)]^2} du \right]^{-1} = [1 + \theta]^2.$$

Ejemplo 3.3.2.

Sea el proceso

$$Y_{t,T} = \mu + \theta\left(\frac{t}{T}\right)\epsilon_{t-1} + \epsilon_t, \quad t = 1, \dots, T.$$

Donde $\theta(u) = a + bu + cu^2$, tal que las constantes a, b, c cumplen que $|\theta(u)| < 1$ para todo $u \in [0, 1]$ y $\epsilon_t \sim RB(0, 1)$. Es decir $\{Y_{t,T}\}_t$ es un proceso LSMA(1). Sea $\tilde{\mu}_{T,\Theta}$ el BLUE de μ , luego por el *Teorema 3.1* se tiene que

$$TVar(\tilde{\mu}_{T,\Theta}) \sim V = \left[\int_0^1 \frac{1}{\left[1 + a + bu + cu^2\right]^2} du \right]^{-1}.$$

Sea $\Delta = 4ac - b^2$, luego $V = \frac{2c}{\Delta(1 + a + b + c)} + \frac{2c}{\Delta}g(a, b, c)$ y

$$g(a, b, c) = \begin{cases} \frac{2}{\sqrt{-\Delta}} \left[\operatorname{arctanh}\left(\frac{b+2c}{\sqrt{-\Delta}}\right) - \operatorname{arctanh}\left(\frac{b}{\sqrt{-\Delta}}\right) \right] & , \quad \Delta < 0 \\ \frac{4c}{b(b+2c)} & , \quad \Delta = 0 \text{ y } c \neq 0 \\ \frac{2}{\sqrt{\Delta}} \left[\arctan\left(\frac{b+2c}{\sqrt{\Delta}}\right) - \arctan\left(\frac{b}{\sqrt{\Delta}}\right) \right] & , \quad \Delta > 0 \end{cases}$$

Ver Gradshteyn and Ryzhik (2000, p. 79-80).

Ejemplo 3.3.3.

Sea el proceso

$$Y_{t,T} = \mu + \theta\left(\frac{t}{T}\right)\epsilon_{t-1} + \epsilon_t, \quad t = 1, \dots, T.$$

Donde $\theta(u) = \cos(u)^3 - 1$ y $\epsilon_t \sim RB(0, 1)$. Es decir $\{Y_{t,T}\}_t$ es un proceso LSMA(1).

Sea $\tilde{\mu}_{T,\Theta}$ el BLUE de μ , luego por el *Teorema 3.1* se tiene que

$$TVar(\tilde{\mu}_{T,\Theta}) \sim V = \left[\int_0^1 \frac{1}{[\cos(u)^3]^2} du \right]^{-1}.$$

De Gradshteyn and Ryzhik (2000, p. 158), se tiene que

$$V = \left[\frac{1}{5} \tan(1)^5 + \frac{2}{3} \tan(1)^3 + \tan(1) \right]^{-1}.$$

Ejemplo 3.3.4.

Supongamos que $k = 2, q = 1$ y $\sigma(u) = 1$ para todo $u \in [0, 1]$, así tenemos el siguiente modelo de regresión:

$$\begin{aligned} Y_{t,T} &= X'(\tfrac{t}{T})\beta + \theta(\tfrac{t}{T})\epsilon_{t-1} + \epsilon_t \\ &= x_1(\tfrac{t}{T})\beta_1 + x_2(\tfrac{t}{T})\beta_2 + \theta(\tfrac{t}{T})\epsilon_{t-1} + \epsilon_t, \quad t = 1, \dots, T. \end{aligned}$$

Tal que $x_1(\cdot), x_2(\cdot) \in C^2([0, 1])$, $\theta(u) \in C^2$ con derivadas acotadas y $|\theta(u)| < 1$ para todo $u \in [0, 1]$, $\beta = (\beta_1, \beta_2)'$ y $\epsilon_t \sim RB(0, 1)$.

Sea $\tilde{\beta}_{T,\Theta}$ el BLUE de β definido por

$$\tilde{\beta}_{T,\Theta} = \left(X_T' \Gamma^{-1} X_T \right)^{-1} X_T' \Gamma^{-1} Y_T$$

Donde X_T es la matriz de diseño de la regresión dada por

$$X_T = \begin{bmatrix} x_1\left(\frac{1}{T}\right) & x_2\left(\frac{1}{T}\right) \\ x_1\left(\frac{2}{T}\right) & x_2\left(\frac{2}{T}\right) \\ \vdots & \vdots \\ x_1\left(\frac{T}{T}\right) & x_2\left(\frac{T}{T}\right) \end{bmatrix},$$

$Y_T = (Y_{1,T}, Y_{2,T}, \dots, Y_{T,T})'$ y Γ^{-1} es la matriz inversa de $Var(Y_T) = \Gamma$.

Entonces

$$TVar(\tilde{\beta}_{T,\Theta}) \rightarrow \Omega^{-1}$$

Cuando $T \rightarrow \infty$. Donde

$$\Omega = \int_0^1 \frac{1}{[1 + \theta(u)]^2} \begin{bmatrix} x_1(u)^2 & x_1(u)x_2(u) \\ x_2(u)x_1(u) & x_2(u)^2 \end{bmatrix} du.$$

3.4. Estudio de Simulación

Esta sección trata sobre el cálculo de la varianza del BLUE de β para el proceso $\{Y_{t,T}\}_t$ que satisface la definición 3.3, se mostrará la exactitud de la fórmula asintótica dada por el *Teorema 3.1*, comparándola con la varianza muestral del BLUE de β obtenida a partir de varias simulaciones y la varianza teórica del BLUE de β , dada por la ecuación (3.7). Estas comparaciones se ilustran con un proceso LSMA(1) y LSMA(2) con parámetros de variación en el tiempo que evolucionan mediante polinomios, funciones armónicas, logarítmicas, etc. Y regresores tales que $x_i(\cdot) \in C^2([0, 1])$ para $i \in \{1, \dots, k\}$.

Ejemplo 3.4.1.

En este primer ejemplo, estudiamos el comportamiento de la varianza del BLUE de la media constante μ de un proceso LSMA(1), definido por

$$Y_{t,T} = \mu + \theta\left(\frac{t}{T}\right)\epsilon_{t-1} + \epsilon_t$$

donde $\epsilon_t \stackrel{iid}{\sim} N(0, 1)$ y $\theta(u) = 3.5(u - 0.5)^2$, $u \in [0, 1]$.




Figura 3.1: Función de variación en el tiempo $\theta(u) = 3.5(u - 0.5)^2$.




Figura 3.2: Simulación de un proceso LSMA(1) con parámetro $\theta(u) = 3.5(u - 0.5)^2$.




Figura 3.3: ACF de un proceso LSMA(1) con parámetro $\theta(u) = 3.5(u - 0.5)^2$.




Figura 3.4: PACF de un proceso LSMA(1) con parámetro $\theta(u) = 3.5(u - 0.5)^2$.

Tabla 3.1: Comparación varianza teórica del BLUE de la media constante μ de un proceso LSMA(1) con parámetro $\theta(u) = 3.5(u - 0.5)^2$.

Método	Tamaño Muestral				
	T=1000	T=2000	T=3000	T=4000	T=5000
Exacta	0.00149496	0.00074763	0.00049845	0.00037385	0.00029909
Muestral	0.00150447	0.00073363	0.00048347	0.00037694	0.00030638
Asintótica	0.00149555	0.00074777	0.00049851	0.00037388	0.00029912

Método	Tamaño Muestral				
	T=6000	T=7000	T=8000	T=9000	T=10000
Exacta	0.00024924	0.00021364	0.00018693	0.00016617	0.00014955
Muestral	0.00025559	0.00020976	0.00018160	0.00016783	0.00014391
Asintótica	0.00024927	0.00021366	0.00018695	0.00016618	0.00014956

Observación 3.4.1.

Las muestras de este proceso LSMA(1) fueron simuladas mediante el algoritmo de recursión usando 1000 trayectorias de tamaños $T = 1000$, $T = 2000$, $T = 3000$, $T = 4000$, $T = 5000$, $T = 6000$, $T = 7000$, $T = 8000$, $T = 9000$ y $T = 10000$. La tabla 3.1 muestra el estudio de simulación para ilustrar el cálculo de la varianza del BLUE de μ , en donde se compara la varianza muestral del BLUE, la varianza exacta del BLUE, que está dada por la ecuación (3.7) y la varianza asintótica del BLUE, que está dada por la expresión (3.8).

Ejemplo 3.4.2.

En este ejemplo, estudiamos el comportamiento de la varianza del BLUE del parámetro de tendencia β con errores LSMA(1), definido por

$$Y_{t,T} = x\left(\frac{t}{T}\right)\beta + \theta\left(\frac{t}{T}\right)\epsilon_{t-1} + \epsilon_t$$

donde $\epsilon_t \stackrel{iid}{\sim} N(0, 1)$, $x(u) = \sin(2\pi u)$, $u \in [0, 1]$ y $\theta(u) = 0.2 - u$, $u \in [0, 1]$.




Figura 3.5: Función de variación en el tiempo $\theta(u) = 0.2 - u$.




Figura 3.6: Simulación de un proceso LSMA(1) con parámetro $\theta(u) = 0.2 - u$.




Figura 3.7: ACF de un proceso LSMA(1) con parámetro $\theta(u) = 0.2 - u$.




Figura 3.8: PACF de un proceso LSMA(1) con parámetro $\theta(u) = 0.2 - u$.

Tabla 3.2: Comparación varianza teórica del BLUE del parámetro de tendencia β de un proceso LSMA(1) con parámetro $\theta(u) = 0.2 - u$

Método	Tamaño Muestral				
	T=1000	T=2000	T=3000	T=4000	T=5000
Exacta	0.00058534	0.00029348	0.00019584	0.00014695	0.00011760
Muestral	0.00056946	0.00029517	0.00020067	0.00014465	0.00011463
Asintótica	0.00058868	0.00029434	0.00019623	0.00014717	0.00011774

Método	Tamaño Muestral				
	T=6000	T=7000	T=8000	T=9000	T=10000
Exacta	0.00009802	0.00008403	0.00007353	0.00006537	0.00005883
Muestral	0.00009945	0.00008835	0.00007085	0.00006972	0.00006107
Asintótica	0.00009811	0.00008410	0.00007358	0.00006541	0.00005887

Observación 3.4.2.

Las muestras de este proceso LSMA(1) fueron simuladas mediante el algoritmo de recursión usando 1000 trayectorias de tamaños $T = 1000$, $T = 2000$, $T = 3000$, $T = 4000$, $T = 5000$, $T = 6000$, $T = 7000$, $T = 8000$, $T = 9000$ y $T = 10000$. La tabla 3.2 muestra el estudio de simulación para ilustrar el cálculo de la varianza del BLUE de μ , en donde se compara la varianza muestral del BLUE, la varianza exacta del BLUE, que está dada por la ecuación (3.7) y la varianza asintótica del BLUE, que está dada por la expresión (3.8).

Ejemplo 3.4.3.

En este otro ejemplo, estudiamos el comportamiento de la varianza del BLUE de β de una regresión lineal con errores LSMA(1), definido por

$$Y_{t,T} = x_1\left(\frac{t}{T}\right)\beta_1 + x_2\left(\frac{t}{T}\right)\beta_2 + \theta\left(\frac{t}{T}\right)\epsilon_{t-1} + \epsilon_t$$

donde $\epsilon_t \stackrel{iid}{\sim} N(0, 1)$, $x_1(u) = u^2$, $x_2(u) = e^u$, $u \in [0, 1]$ y $\theta(u) = \log(0.5 + u)$, $u \in [0, 1]$.




Figura 3.9: Función de variación en el tiempo $\theta(u) = \log(0.5 + u)$.




Figura 3.10: Simulación de un proceso LSMA(1) con parámetro $\theta(u) = \log(0.5 + u)$.




Figura 3.11: ACF de un proceso LSMA(1) con parámetro $\theta(u) = \log(0.5 + u)$.




Figura 3.12: PACF de un proceso LSMA(1) con parámetro $\theta(u) = \log(0.5 + u)$.

Tabla 3.3: Comparación matriz de covarianza teórica del BLUE de β de una regresión lineal con errores LSMA(1) con parámetro $\theta(u) = \log(0.5 + u)$.

Método	Varianza		Covarianza
	$\tilde{\beta}_{1,T,\Theta}$	$\tilde{\beta}_{2,T,\Theta}$	$(\tilde{\beta}_{1,T,\Theta}, \tilde{\beta}_{2,T,\Theta})$
T=1000			
Exacta	0.01824951	0.00065214	-0.00259328
Muestral	0.01821636	0.00068231	-0.00260742
Asintótica	0.01804399	0.00063624	-0.00253320
Método	Varianza		Covarianza
	$\tilde{\beta}_{1,T,\Theta}$	$\tilde{\beta}_{2,T,\Theta}$	$(\tilde{\beta}_{1,T,\Theta}, \tilde{\beta}_{2,T,\Theta})$
T=3000			
Exacta	0.00603814	0.00021389	-0.00085123
Muestral	0.00586865	0.00021478	-0.00084573
Asintótica	0.00601466	0.00021208	-0.00084440

Método	Varianza		Covarianza
	$\tilde{\beta}_{1,T,\Theta}$	$\tilde{\beta}_{2,T,\Theta}$	$(\tilde{\beta}_{1,T,\Theta}, \tilde{\beta}_{2,T,\Theta})$
T=5000			
Exacta	0.00361730	0.00012790	-0.00050911
Muestral	0.00377108	0.00012826	-0.00053240
Asintótica	0.00360880	0.00012725	-0.00050664
Método	Varianza		Covarianza
	$\tilde{\beta}_{1,T,\Theta}$	$\tilde{\beta}_{2,T,\Theta}$	$(\tilde{\beta}_{1,T,\Theta}, \tilde{\beta}_{2,T,\Theta})$
T=10000			
Exacta	0.00180653	0.00006379	-0.00025394
Muestral	0.00181822	0.00006302	-0.00025665
Asintótica	0.00180440	0.00006362	-0.00025332

Observación 3.4.3.

Las muestras de este proceso LSMA(1) fueron simuladas mediante el algoritmo de recursión usando 1000 trayectorias de tamaños $T = 1000$, $T = 3000$, $T = 5000$ y $T = 10000$. La tabla 3.3 muestra el estudio de simulación para ilustrar el cálculo de la matriz de covarianza del BLUE de β , en donde se compara la matriz de covarianza muestral del BLUE, la matriz de covarianza exacta del BLUE, que está dada por la ecuación (3.7) y la matriz de covarianza asintótica del BLUE, que está dada por la expresión (3.8).

Ejemplo 3.4.4.

En este ejemplo estudiamos el comportamiento de la varianza del BLUE de β de una regresión lineal con errores LSMA(2), definido por

$$Y_{t,T} = x_1\left(\frac{t}{T}\right)\beta_1 + x_2\left(\frac{t}{T}\right)\beta_2 + \sigma\left(\frac{t}{T}\right)\left[\theta_2\left(\frac{t}{T}\right)\epsilon_{t-2} + \theta_1\left(\frac{t}{T}\right)\epsilon_{t-1} + \epsilon_t\right]$$

donde $\epsilon_t \stackrel{iid}{\sim} N(0, 1)$, $x_1(u) = u$, $x_2(u) = e^{-u}$, $u \in [0, 1]$, $\sigma(u) = \sqrt{0.5 + u}$, $u \in [0, 1]$ y $\theta_1(u) = u - 0.5$, $\theta_2(u) = 0.5\sqrt{u} - 0.5$, $u \in [0, 1]$.




Figura 3.13: Función de variación en el tiempo $x_1(u) = u$, $x_2(u) = e^{-u}$.




Figura 3.14: Funciones de variación en el tiempo $\theta_1(u) = u - 0.5$, $\theta_2(u) = 0.5\sqrt{u} - 0.5$.




Figura 3.15: Función de variación en el tiempo $\sigma(u) = \sqrt{0.5 + u}$.




Figura 3.16: Simulación de un proceso LSMA(2) con parámetros $\theta_1(u) = u - 0.5$, $\theta_2(u) = 0.5\sqrt{u} - 0.5$ y $\sigma(u) = \sqrt{0.5 + u}$.




Figura 3.17: ACF de un proceso LSMA(2) con parámetros $\theta_1(u) = u - 0.5$, $\theta_2(u) = 0.5\sqrt{u} - 0.5$ y $\sigma(u) = \sqrt{0.5 + u}$.




Figura 3.18: PACF de un proceso LSMA(2) con parámetros $\theta_1(u) = u - 0.5$, $\theta_2(u) = 0.5\sqrt{u} - 0.5$ y $\sigma(u) = \sqrt{0.5 + u}$.

Tabla 3.4: Comparación matriz de covarianza teórica del BLUE de β de una regresión lineal con errores LSMA(2) de parámetros $\theta_1(u) = u - 0.5$, $\theta_2(u) = 0.5\sqrt{u} - 0.5$ y $\sigma(u) = \sqrt{0.5 + u}$.

Método	Varianza		Covarianza
	$\tilde{\beta}_{1,T,\Theta}$	$\tilde{\beta}_{2,T,\Theta}$	$(\tilde{\beta}_{1,T,\Theta}, \tilde{\beta}_{2,T,\Theta})$
T=1000			
Exacta	0.00800724	0.00083814	-0.00136840
Muestral	0.00757377	0.00082073	-0.00118721
Asintótica	0.00778900	0.00074928	-0.00123067
Método	Varianza		Covarianza
	$\tilde{\beta}_{1,T,\Theta}$	$\tilde{\beta}_{2,T,\Theta}$	$(\tilde{\beta}_{1,T,\Theta}, \tilde{\beta}_{2,T,\Theta})$
T=3000			
Exacta	0.00262482	0.00026107	-0.00042800
Muestral	0.00249987	0.00025377	-0.00040002
Asintótica	0.00259633	0.00024976	-0.00041022

Método	Varianza		Covarianza
	$\tilde{\beta}_{1,T,\Theta}$	$\tilde{\beta}_{2,T,\Theta}$	$(\tilde{\beta}_{1,T,\Theta}, \tilde{\beta}_{2,T,\Theta})$
T=5000			
Exacta	0.00156864	0.00015413	-0.00025288
Muestral	0.00154800	0.00015354	-0.00025606
Asintótica	0.00155780	0.00014986	-0.00024613
Método	Varianza		Covarianza
	$\tilde{\beta}_{1,T,\Theta}$	$\tilde{\beta}_{2,T,\Theta}$	$(\tilde{\beta}_{1,T,\Theta}, \tilde{\beta}_{2,T,\Theta})$
T=10000			
Exacta	0.00078177	0.00007606	-0.00012485
Muestral	0.00079948	0.00008216	-0.00013725
Asintótica	0.00077890	0.00007493	-0.00012307

Observación 3.4.4.

Las muestras de este proceso fueron simuladas mediante el algoritmo de recursión usando 1000 trayectorias de tamaños $T = 1000$, $T = 3000$, $T = 5000$ y $T = 10000$.

La tabla 3.4 muestra el estudio de simulación para ilustrar el cálculo de la matriz de covarianza del BLUE de β , en donde se compara la matriz de covarianza muestral del BLUE, la matriz de covarianza exacta del BLUE, que está dada por la ecuación (3.7) y la matriz de covarianza asintótica del BLUE, que está dada por la expresión (3.8).

Capítulo 4

Extensiones

La idea de este capítulo es extender a un proceso LSARMA(q) las propiedades asintóticas del BLUE para el vector de parámetros β de una regresión lineal como fue visto en el capítulo anterior.

Realizaremos simulaciones para ver el comportamiento asintótico de la varianza del BLUE para la media constante μ de un proceso LSARMA(p, q), es decir, analizaremos la teoría suponiendo que los parámetros del proceso LSARMA(p, q) son conocidos. De lo anterior, extendemos el estudio de simulaciones para el caso $\mu\left(\frac{t}{T}\right) = X'\left(\frac{t}{T}\right)\beta$. Donde $X'\left(\frac{t}{T}\right) = \left(x_1\left(\frac{t}{T}\right), \dots, x_k\left(\frac{t}{T}\right)\right)$ es un vector de k componentes no estocásticas, tales que $x_i(\cdot) \in C^2([0, 1])$ $i = 1, \dots, k$, $\beta = (\beta_1, \dots, \beta_k)'$.

4.1. Extensión a un Proceso LSARMA(p, q)

Definición 4.1.

Sea el proceso

$$Y_{t,T} = X'(\frac{t}{T})\beta + \sum_{l=1}^p \phi_l(\frac{t}{T}) \left(Y_{t-l,T} - X'(\frac{t-l}{T})\beta \right) + \sigma(\frac{t}{T}) \sum_{j=0}^q \theta_j(\frac{t}{T}) \epsilon_{t-j,T} \quad (4.1)$$

para $t = 1, \dots, T$. Un proceso de corta memoria LSARMA(p, q), donde $X'(\frac{t}{T}) = \left(x_1(\frac{t}{T}), \dots, x_k(\frac{t}{T}) \right)$ es un vector de k componentes no estocásticas, tales que $x_i(\cdot) \in C^2([0, 1])$ $i = 1, \dots, k$, $\beta = (\beta_1, \dots, \beta_k)'$. Las raíces del polinomio

$$\Phi(z, u) = 1 + \phi_1(u)z + \dots + \phi_p(u)z^p$$

están fuera del disco unitario $D = \{z \in \mathbb{C} : |z| \leq 1\}$ para todo $u \in [0, 1]$ y $\epsilon_t \sim RB(0, 1)$.

Sea Γ matriz de covarianzas del proceso LSARMA(p, q) dada por

$$\Gamma = \left\{ \int_{[-\pi, \pi]} e^{i\lambda(r-s)} A_{r,T}^0(\lambda) \overline{A_{s,T}^0(\lambda)} d\lambda \right\}_{r,s=1,\dots,T},$$

y

$$A_{t,T}^0(\lambda) = \sum_{j=0}^{\infty} \Psi_{t,T,j} e^{-i\lambda j}$$

Donde $\sum_{j=0}^{\infty} |\Psi_{t,T,j}| < \infty$.

La densidad espectral de este proceso está dada por

$$f(u, \lambda) = \frac{\sigma(u)}{2\pi} \left| \frac{\sum_{j=0}^q \theta_j(u) e^{i\lambda j}}{\sum_{l=0}^p \phi_l(u) e^{i\lambda l}} \right|^2, \quad u \in [0, 1], \lambda \in [-\pi, \pi].$$

Donde $\theta_0(u) = 1$, $\phi_0(u) = -1$ para todo $u \in [0, 1]$.

Conjetura 4.1.1.

Para el proceso dado en la definición 4.1 se tiene que el BLUE de β está dado por

$$\tilde{\beta}_{T,\Theta} = \left(X_T' \Gamma^{-1} X_T \right)^{-1} X_T' \Gamma^{-1} Y_T$$

donde $\Theta = (\theta_1, \dots, \theta_q, \sigma)'$, $Y_T = (Y_{1,T}, Y_{2,T}, \dots, Y_{T,T})'$ y X_T' es la matriz de diseño.

Luego la varianza de $\tilde{\beta}_{T,\Theta}$ es

$$\text{Var}(\tilde{\beta}_{T,\Theta}) = \left(X_T' \Gamma^{-1} X_T \right)^{-1}. \quad (4.2)$$

Luego la varianza asintótica está dada por

$$\text{TVar}(\tilde{\beta}_{T,\Theta}) \sim V = \left[\int_0^1 \frac{X(u)X'(u)}{\sigma(u)^2} \left[\frac{\sum_{l=0}^p \phi_l(u)}{\sum_{j=0}^q \theta_j(u)} \right]^2 du \right]^{-1}. \quad (4.3)$$

En términos de la densidad espectral se tiene que

$$\text{TVar}(\tilde{\beta}_{T,\Theta}) \sim 2\pi \left[\int_0^1 \frac{X(u)X'(u)}{f(u,0)} du \right]^{-1}. \quad (4.4)$$

Ejemplo 4.1.1.

Supongamos que $k = 2, p = 1, q = 0$ y $\sigma(u) = 1$ para todo $u \in [0, 1]$, así tenemos el

siguiente modelo

$$\begin{aligned}
Y_{t,T} &= X'(\tfrac{t}{T})\beta + \phi(\tfrac{t}{T})\left(Y_{t-1,T} - X'(\tfrac{t-1}{T})\beta\right) + \epsilon_t \\
&= x_1(\tfrac{t}{T})\beta_1 + x_2(\tfrac{t}{T})\beta_2 + \\
&\quad \phi(\tfrac{t}{T})\left(Y_{t-1,T} - x_1(\tfrac{t-1}{T})\beta_1 + x_2(\tfrac{t-1}{T})\beta_2\right) + \epsilon_t
\end{aligned}$$

para $t = 1, \dots, T$. Tal que $Y_{0,T} = 0$, $x_1(\cdot), x_2(\cdot) \in C^2([0, 1])$, $\phi(u) \in C^2([0, 1])$ con derivadas acotadas y $|\phi(u)| < 1$ para todo $u \in [0, 1]$, $\beta = (\beta_1, \beta_2)'$ y $\epsilon_t \sim RB(0, 1)$.

Sea $\tilde{\beta}_{T,\Theta}$ el BLUE de β definido por

$$\tilde{\beta}_{T,\Theta} = \left(X_T' \Gamma^{-1} X_T\right)^{-1} X_T' \Gamma^{-1} Y_T$$

Donde X_T es la matriz de diseño de la regresión dada por

$$X_T = \begin{bmatrix} x_1(\frac{1}{T}) & x_2(\frac{1}{T}) \\ x_1(\frac{2}{T}) & x_2(\frac{2}{T}) \\ \vdots & \vdots \\ x_1(\frac{T}{T}) & x_2(\frac{T}{T}) \end{bmatrix},$$

$Y_T = (Y_{1,T}, Y_{2,T}, \dots, Y_{T,T})'$ y Γ^{-1} es la matriz inversa de $Var(Y_T) = \Gamma$.

Entonces

$$TVar(\tilde{\beta}_{T,\Theta}) \rightarrow \Omega^{-1}$$

Cuando $T \rightarrow \infty$. Donde

$$\Omega = \int_0^1 [\phi(u) - 1]^2 \begin{bmatrix} x_1(u)^2 & x_1(u)x_2(u) \\ x_2(u)x_1(u) & x_2(u)^2 \end{bmatrix} du.$$

4.2. Estudio de Simulación

En esta sección estudiamos el comportamiento de la varianza teórica del BLUE mediante simulaciones para procesos localmente estacionarios de corta memoria LSAR(q) y LSARMA(p, q). Compararemos las fórmulas asintóticas de las varianzas dadas por las *Conjeturas* antes mostradas con la varianza muestral del BLUE de μ y la varianza teórica del BLUE de μ , dada por la ecuación (4.2).

Ejemplo 4.2.1.

En este primer ejemplo, estudiamos el comportamiento de la varianza del BLUE de la media constante μ del proceso LSAR(3), definido por

$$Y_{t,T} = \mu + \phi_1\left(\frac{t}{T}\right)\left(Y_{t-1,T} - \mu\right) + \phi_2\left(\frac{t}{T}\right)\left(Y_{t-2,T} - \mu\right) + \phi_3\left(\frac{t}{T}\right)\left(Y_{t-3,T} - \mu\right) + \epsilon_t$$

donde $\epsilon_t \stackrel{iid}{\sim} N(0, 1)$, $\phi_1(u) = \frac{7}{6}(u - 0.5)^2$, $\phi_2(u) = \frac{1}{12}(12u^2 - 4u + 3)$ y $\phi_3(u) = \frac{1}{15}(-4u^2 + 2u + 4)$, $u \in [0, 1]$.




Figura 4.1: Funciones de variación en el tiempo $\phi_1(u) = \frac{7}{6}(u - 0.5)^2$, $\phi_2(u) = \frac{1}{12}(12u^2 - 4u + 3)$ y $\phi_3(u) = \frac{1}{15}(-4u^2 + 2u + 4)$.




Figura 4.2: Simulación de un proceso LSAR(3) con parámetros $\phi_1(u) = \frac{7}{6}(u - 0.5)^2$, $\phi_2(u) = \frac{1}{12}(12u^2 - 4u + 3)$ y $\phi_3(u) = \frac{1}{15}(-4u^2 + 2u + 4)$.




Figura 4.3: ACF de un proceso LSAR(3) con parámetros $\phi_1(u) = \frac{7}{6}(u - 0.5)^2$, $\phi_2(u) = \frac{1}{12}(12u^2 - 4u + 3)$ y $\phi_3(u) = \frac{1}{15}(-4u^2 + 2u + 4)$.




Figura 4.4: PACF de un proceso LSAR(3) con parámetros $\phi_1(u) = \frac{7}{6}(u - 0.5)^2$, $\phi_2(u) = \frac{1}{12}(12u^2 - 4u + 3)$ y $\phi_3(u) = \frac{1}{15}(-4u^2 + 2u + 4)$.

Tabla 4.1: Comparación varianza teórica del BLUE de la media constante μ del proceso LSAR(3) con parámetros $\phi_1(u) = \frac{7}{6}(u - 0.5)^2$, $\phi_2(u) = \frac{1}{12}(12u^2 - 4u + 3)$ y $\phi_3(u) = \frac{1}{15}(-4u^2 + 2u + 4)$.

Método	Tamaño Muestral				
	T=1000	T=2000	T=3000	T=4000	T=5000
Exacta	0.00357312	0.00178953	0.00119369	0.00089552	0.00071653
Muestral	0.00384710	0.00179665	0.00126256	0.00085099	0.00070820
Asintótica	0.00358510	0.00179255	0.00119503	0.00089627	0.00071702

Método	Tamaño Muestral				
	T=6000	T=7000	T=8000	T=9000	T=10000
Exacta	0.00059718	0.00051191	0.00044795	0.00039819	0.00035839
Muestral	0.00060775	0.00051299	0.00044356	0.00040788	0.00037213
Asintótica	0.00059751	0.00051215	0.00044813	0.00039834	0.00035851

Observación 4.2.1.

Las muestras de este proceso LSAR(3) fueron simuladas mediante el algoritmo de recursión. La tabla 4.1 muestra el estudio de simulación para ilustrar el cálculo de la varianza teórica del BLUE de μ .

La varianza exacta está dada por (4.2) y la varianza asintótica está dada por (4.3). Notamos que las fórmulas dadas por las *Conjeturas* tienen una buena precisión, con lo cual nos queda la tarea de poder demostrar estas fórmulas.

Ejemplo 4.2.2.

Sea el proceso LSARMA(1,1) con media constante μ , definido por

$$Y_{t,T} = \mu + \phi_1\left(\frac{t}{T}\right)\left(Y_{t-1,T} - \mu\right) + \theta\left(\frac{t}{T}\right)\epsilon_{t-1,T} + \epsilon_t,$$

donde $\epsilon_t \stackrel{iid}{\sim} N(0, 1)$, $\phi(u) = \frac{7}{6}(u - 0.5)^2$ y $\theta(u) = \frac{1}{6}(-6u^2 + 2u + 5)$, $u \in [0, 1]$




Figura 4.5: Funciones de variación en el tiempo $\phi(u) = \frac{7}{6}(u - 0.5)^2$ y $\theta(u) = \frac{1}{6}(-6u^2 + 2u + 5)$.




Figura 4.6: Simulación de un proceso LSARMA(1,1) con parámetros $\phi(u) = \frac{7}{6}(u - 0.5)^2$ y $\theta(u) = \frac{1}{6}(-6u^2 + 2u + 5)$.




Figura 4.7: ACF de un proceso LSARMA(1,1) con parámetros $\phi(u) = \frac{7}{6}(u - 0.5)^2$ y $\theta(u) = \frac{1}{6}(-6u^2 + 2u + 5)$.




Figura 4.8: PACF de un proceso LSARMA(1,1) con parámetros $\phi(u) = \frac{7}{6}(u - 0.5)^2$ y $\theta(u) = \frac{1}{6}(-6u^2 + 2u + 5)$.

Tabla 4.2: Comparación varianza teórica del BLUE de la media constante μ de un proceso LSARMA(1,1) con parámetros $\phi(u) = \frac{7}{6}(u - 0.5)^2$ y $\theta(u) = \frac{1}{6}(-6u^2 + 2u + 5)$.

Método	Tamaño Muestral				
	T=1000	T=2000	T=3000	T=4000	T=5000
Exacta	0.00499939	0.00250116	0.00166780	0.00125099	0.00100086
Muestral	0.00484383	0.00240858	0.00155947	0.00130238	0.00099043
Asintótica	0.00500568	0.00250284	0.00166856	0.00125142	0.00100113

Método	Tamaño Muestral				
	T=6000	T=7000	T=8000	T=9000	T=10000
Exacta	0.00083408	0.00071495	0.00062560	0.00055610	0.00050050
Muestral	0.00082930	0.00073423	0.00067886	0.00055901	0.00050325
Asintótica	0.00083428	0.00071509	0.00062571	0.00055618	0.00050056

Observación 4.2.2.

Las muestras de este proceso LSARMA(1,1) fueron simuladas mediante el algoritmo de recursión. La tabla 4.2 muestra el estudio de simulación para ilustrar el cálculo de la varianza teórica del BLUE de μ .

La varianza exacta está dada por (4.2) y la varianza asintótica está dada por (4.3). Al igual que el caso anterior, notamos que las fórmulas dadas por las *Conjeturas* tienen una buena precisión, con lo cual nos queda la tarea de poder demostrar estas fórmulas.

Ejemplo 4.2.3.

En este ejemplo, estudiamos el comportamiento de la varianza del BLUE de β para un proceso LSAR(1), definido por

$$\begin{aligned} Y_{t,T} &= X'(\tfrac{t}{T})\beta + \phi(\tfrac{t}{T})\left(Y_{t-1,T} - X'(\tfrac{t-1}{T})\beta\right) + \epsilon_t \\ &= x_1(\tfrac{t}{T})\beta_1 + x_2(\tfrac{t}{T})\beta_2 + \\ &\quad \phi(\tfrac{t}{T})\left(Y_{t-1,T} - x_1(\tfrac{t-1}{T})\beta_1 + x_2(\tfrac{t-1}{T})\beta_2\right) + \epsilon_t \end{aligned}$$

para $t = 1, \dots, T$. Tal que $Y_{0,T} = 0$, $x_1(u) = u$, $x_2(u) = \sqrt{u}$, $\phi(u) = u - 0.2$ y $\epsilon_t \stackrel{iid}{\sim} N(0, 1)$.




Figura 4.9: Función de variación en el tiempo $\phi(u) = u - 0.2$.




Figura 4.10: Simulación de un proceso LSAR(1) con parámetro $\phi(u) = u - 0.2$.




Figura 4.11: ACF de un proceso LSAR(1) con parámetros $\phi(u) = u - 0.2$.




Figura 4.12: PACF de un proceso LSAR(1) con parámetros $\phi(u) = u - 0.2$.

Tabla 4.3: Comparación varianza teórica del BLUE de β del proceso LSAR(1) con parámetro $\phi(u) = u - 0.2$.

Método	Varianza		Covarianza
	$\tilde{\beta}_{1,T,\Theta}$	$\tilde{\beta}_{2,T,\Theta}$	$(\tilde{\beta}_{1,T,\Theta}, \tilde{\beta}_{2,T,\Theta})$
T=1000			
Exacta	0.1798362	0.08475683	-0.11910079
Muestral	0.1923121	0.08994938	-0.12680360
Asintótica	0.1804738	0.08492883	-0.11943959
Método	Varianza		Covarianza
	$\tilde{\beta}_{1,T,\Theta}$	$\tilde{\beta}_{2,T,\Theta}$	$(\tilde{\beta}_{1,T,\Theta}, \tilde{\beta}_{2,T,\Theta})$
T=3000			
Exacta	0.06008659	0.02829029	-0.03977523
Muestral	0.06365710	0.02973039	-0.04213601
Asintótica	0.06015792	0.02830961	-0.03981320

Método	Varianza		Covarianza
	$\tilde{\beta}_{1,T,\Theta}$	$\tilde{\beta}_{2,T,\Theta}$	$(\tilde{\beta}_{1,T,\Theta}, \tilde{\beta}_{2,T,\Theta})$
T=5000			
Exacta	0.03606905	0.01697880	-0.02387423
Muestral	0.03625299	0.01711079	-0.02408282
Asintótica	0.03609475	0.01698577	-0.02388792
Método	Varianza		Covarianza
	$\tilde{\beta}_{1,T,\Theta}$	$\tilde{\beta}_{2,T,\Theta}$	$(\tilde{\beta}_{1,T,\Theta}, \tilde{\beta}_{2,T,\Theta})$
T=10000			
Exacta	0.01804095	0.00849114	-0.01194054
Muestral	0.01781084	0.00836629	-0.01179634
Asintótica	0.01804738	0.00849288	-0.01194396

Observación 4.2.3.

Las muestras de este proceso LSAR(1) fueron simuladas mediante el algoritmo de recursión. La tabla 4.3 muestra el estudio de simulación para ilustrar el cálculo de la varianza teórica del BLUE de β .

La varianza exacta está dada por (4.2) y la varianza asintótica está dada por (4.3). Notamos que las fórmulas dadas por las *Conjeturas* tienen una buena precisión, con lo cual nos queda la tarea de poder demostrar estas fórmulas.

Capítulo 5

Eficiencia Relativa

Este capítulo trata de visualizar el comportamiento de la eficiencia relativa entre el LSE y el BLUE de μ (constante) para el caso particular del proceso LSMA(1), donde $\theta(u)$ toma la forma lineal y/o trigonométrica. Mostraremos la superficie y curvas de nivel que se generan para el caso lineal $\theta(u) = a + bu$ donde $|\theta(u)| < 1$ y veremos ejemplos en donde la eficiencia es cercano a 1 y otros donde es muy lejano a 1.

También compararemos las matrices de covarianzas del LSE y el BLUE del vector de parámetros β para el caso de una regresión lineal con errores LSMA(1) y LSMA(2).

5.1. Proceso LSMA con Media μ Constante

Estudiaremos la eficiencia relativa del LSE y BLUE para procesos localmente estacionarios de corta memoria LSMA(1) con distintas funciones $\theta(u)$.

Definición 5.1.

Sea el proceso

$$Y_{t,T} = \mu + \theta\left(\frac{t}{T}\right)\epsilon_{t-1} + \epsilon_t, \quad t = 1, \dots, T.$$

Donde $\theta(\cdot) \in C^2([0, 1])$, tal que $|\theta(u)| < 1$ para todo $u \in [0, 1]$ y $\epsilon_t \sim RB(0, 1)$. Es decir $\{Y_{t,T}\}_t$ es un proceso LSMA(1).

Sean $\hat{\mu}_T$, $\tilde{\mu}_{T,\theta}$ el LSE y BLUE de μ respectivamente, con esto definimos el radio de eficiencia relativa

$$R(\theta) = \frac{Var(\hat{\mu}_T)}{Var(\tilde{\mu}_{T,\theta})}. \quad (5.1)$$

Proposición 5.1.1.

Sea el proceso

$$Y_{t,T} = \mu + \sigma\left(\frac{t}{T}\right)[\theta\left(\frac{t}{T}\right)\epsilon_{t-1} + \epsilon_t], \quad t = 1, \dots, T.$$

Un proceso localmente estacionario de corta memoria LSMA(1), tal que $\forall u \in [0, 1]$, $|\theta(u)| < 1$, $\sigma(\cdot) \in C^2([0, 1])$, tal que $\sigma(u) > 0$ para todo $u \in [0, 1]$ y $\epsilon_t \sim RB(0, 1)$.

Sea

$$\hat{\mu}_T = \frac{\sum_{t=1}^T Y_{t,T}}{T}$$

El LSE de μ .

Luego el comportamiento asintótico de la varianza de este, está dado por

$$TVar(\hat{\mu}_T) \sim \int_0^1 \sigma(u)^2 [1 + \theta(u)]^2 du. \quad (5.2)$$

Donde $a_T \sim b_T$ significa que $a_T/b_T \rightarrow 1$ cuando $T \rightarrow \infty$.

5.1.1. Caso θ Constante

Sea el proceso

$$Y_{t,T} = \mu + \theta\left(\frac{t}{T}\right)\epsilon_{t-1} + \epsilon_t, \quad t = 1, \dots, T.$$

Donde $\forall u \in [0, 1], \theta(u) = \theta$ constante, tal que $|\theta| < 1$ y $\epsilon_t \sim RB(0, 1)$. Es decir $\{Y_{t,T}\}_t$ es un proceso MA(1).

Sean $\hat{\mu}_T$, $\tilde{\mu}_{T,\theta}$ el LSE y BLUE de μ respectivamente, luego por el *Teorema 3.2* se tiene que

$$TVar(\tilde{\mu}_{T,\theta}) \sim \left[\int_0^1 \frac{1}{[1 + \theta(u)]^2} du \right]^{-1} = [1 + \theta]^2.$$

Sea $\hat{\mu}_T$ el estimador LSE de μ , luego por la *Proposición 5.1.1*

$$TVar(\hat{\mu}_T) \sim \int_0^1 [1 + \theta(u)]^2 du = [1 + \theta]^2.$$

Luego la eficiencia relativa

$$R(\theta) = \frac{Var(\hat{\mu}_T)}{Var(\tilde{\mu}_{T,\theta})} \sim \frac{[1 + \theta]^2}{[1 + \theta]^2} = 1.$$

Como fue establecido en Grenander and Rosenblatt (1957).

5.1.2. Caso θ Función Lineal

Supongamos que la función de variación en el tiempo $\theta(u)$ sigue un comportamiento lineal, es decir,

$$\theta(u) = a + bu, \quad u \in [0, 1] \text{ tal que } |\theta(u)| < 1 \text{ para todo } u.$$

Así tenemos que el radio de eficiencia es

$$R(\theta(a, b)) = \frac{\text{Var}(\hat{\mu}_T)}{\text{Var}(\tilde{\mu}_{T,\theta})} \quad (5.3)$$

$$\sim \left(\int_0^1 [1 + a + bu]^2 du \right) \left(\int_0^1 \frac{1}{[1 + a + bv]^2} dv \right) \quad (5.4)$$

Graficamos las curvas de nivel y la superficie $R(\theta(a, b))$




Figura 5.1: Curvas de nivel de $R(\theta(a, b))$ para $\theta(u) = a + bu$.




Figura 5.2: Superfície $R(\theta(a, b))$ para $\theta(u) = a + bu$.

De lo anterior apreciamos que en algunos puntos del dominio de $R(\theta(a, b))$ el LSE es menos eficiente, esto lo podemos notar del gráfico de las curvas de nivel. Observamos que si $a \rightarrow -1$ ó si $a + b \rightarrow -1$ la eficiencia relativa es mucho mayor a 1.

Ejemplo 5.1.1.

Para observar esto definamos $\theta(u) = u - 0.8$, $u \in [0, 1]$. Luego simulamos 1000 series de tiempo LSMA(1) de largo $T = 1000, 3000, 5000$ y 10000.

Y obtenemos la siguiente tabla resumen para el radio de eficiencia de los estimadores LSE y BLUE para la media constante μ de un proceso LSMA(1).

Tabla 5.1: Radio de Eficiencia: Varianza LSE v/s varianza BLUE de la media constante μ de un proceso LSMA(1) con parámetro $\theta(u) = u - 0.8$.

R	Tamaño Muestral			
	T=1000	T=3000	T=5000	T=10000
Exacto	2.35	2.37	2.38	2.38
Asintótico	2.38	2.38	2.38	2.38

Observación 5.1.1.

De la tabla 5.1 notamos que la varianza teórica y asintótica del LSE es aproximadamente un 238% mayor que la varianza teórica y asintótica del BLUE de μ . El radio exacto fue obtenido mediante la ecuación (5.3) y el radio asintótico está dado por (5.4).

Ejemplo 5.1.2.

Ahora definamos $\theta(u) = 0.2 + 0.5u$, $u \in [0, 1]$. Luego simulamos 1000 series de tiempo LSMA(1) de largo $T = 1000, 3000, 5000$ y 10000.

Y obtenemos la siguiente tabla resumen para el radio de eficiencia del LSE y BLUE para la media constante μ de un proceso LSMA(1).

Tabla 5.2: Radio de Eficiencia: Varianza LSE v/s varianza BLUE de la media constante μ de un proceso LSMA(1) con parámetro $\theta(u) = 0.2 + 0.5u$.

R	Tamaño Muestral			
	T=1000	T=3000	T=5000	T=10000
Exacto	1.04	1.04	1.04	1.04
Asintótico	1.04	1.04	1.04	1.04

Observación 5.1.2.

De la tabla 5.2 notamos que la varianza teórica y asintótica del LSE es aproximadamente un 4 % mayor que la varianza teórica y asintótica del BLUE de μ , por tanto el LSE de μ es relativamente eficiente en este caso. El radio exacto fue obtenido mediante la ecuación (5.3) y el radio asintótico está dado por (5.4).

5.1.3. Caso θ Función Trigonométrica

Supongamos que la función de variación en el tiempo $\theta(u)$ sigue un comportamiento trigonométrico, es decir,

$$\theta(u) = \sin(a + bu), \quad u \in [0, 1] \text{ tal que } |\theta(u)| < 1 \text{ para todo } u \in [0, 1].$$

Así tenemos que el radio de eficiencia es

$$R(\theta(a, b)) = \frac{Var(\hat{\mu}_T)}{Var(\tilde{\mu}_{T,\Theta})} \quad (5.5)$$

$$\sim \left(\int_0^1 [1 + \sin(a + bu)]^2 du \right) \left(\int_0^1 \frac{1}{[1 + \sin(a + bv)]^2} dv \right) \quad (5.6)$$

De lo anterior apreciamos que en algunos puntos del dominio de $R(\theta(a, b))$ el LSE es menos eficiente, esto lo podemos notar del gráfico de las curvas de nivel. Observamos que si $a + bu \rightarrow -\pi/2 + 2k\pi$, $k \in \mathbb{Z}$ la eficiencia relativa es mucho mayor a 1.

Ejemplo 5.1.3.

Para observar esto definamos $\theta(u) = \sin(-0.2 - 1.1u)$, $u \in [0, 1]$. Luego simulamos 1000 series de tiempo LSMA(1) de largo $T = 1000, 3000, 5000$ y 10000.

Y obtenemos la siguiente tabla resumen para el radio de eficiencia del LSE y BLUE para la media de un proceso LSMA(1).

Tabla 5.3: Radio de Eficiencia: Varianza LSE v/s varianza BLUE de la media constante μ de un proceso LSMA(1) con parámetro $\theta(u) = \sin(-0.2 - 1.1u)$.

R	Tamaño Muestral			
	T=1000	T=3000	T=5000	T=10000
Exacto	8.17	9.26	10.17	10.75
Asintótico	10.97	10.97	10.97	10.97

Observación 5.1.3.

De la tabla 5.3 notamos que la varianza teórica y asintótica del LSE es aproximadamente un 1000 % mayor que la varianza teórica y asintótica del BLUE de la media constante μ . El radio exacto fue obtenido mediante la ecuación (5.3) y el radio asintótico está dado por (5.4).

Ejemplo 5.1.4.

Ahora definamos $\theta(u) = \sin(0.5u + 0.2)$, $u \in [0, 1]$. Luego simulamos 1000 series de tiempo LSMA(1) de largo $T = 1000, 3000, 5000$ y 10000.

Y obtenemos la siguiente tabla resumen para el radio de eficiencia del LSE y BLUE para la media constante μ de un proceso LSMA(1).

Tabla 5.4: Radio de Eficiencia: Varianza LSE v/s varianza BLUE para la media constante μ de un proceso LSMA(1) con parámetro $\theta(u) = \sin(0.5u + 0.2)$.

R	Tamaño Muestral			
	T=1000	T=3000	T=5000	T=10000
Exacto	1.03	1.03	1.03	1.03
Asintótico	1.03	1.03	1.03	1.03

Observación 5.1.4.

De la tabla 5.4 notamos que la varianza teórica y asintótica del LSE es aproximadamente un 3 % mayor que la varianza teórica y asintótica del BLUE de μ , por tanto el LSE de μ es relativamente eficiente en este caso. El radio exacto fue obtenido mediante la ecuación (5.3) y el radio asintótico está dado por (5.4).

5.2. Regresión Lineal con Errores LSMA

En esta sección compararemos las matrices de covarianzas del LSE y el BLUE del vector de parámetros β para el caso de una regresión lineal con errores LSMA(1).

Definición 5.2.

Sea el proceso

$$Y_{t,T} = x_1\left(\frac{t}{T}\right)\beta_1 + x_2\left(\frac{t}{T}\right)\beta_2 + \theta\left(\frac{t}{T}\right)\epsilon_{t-1} + \epsilon_t, \quad t = 1, \dots, T.$$

Tal que $x_1(\cdot), x_2(\cdot) \in C^2([0, 1])$, $\theta(\cdot) \in C^2([0, 1])$ con derivadas acotadas y $|\theta(u)| < 1$ para todo $u \in [0, 1]$, $\beta = (\beta_1, \beta_2)'$ y $\epsilon_t \sim RB(0, 1)$.

Sean $\hat{\beta}_T$, $\tilde{\beta}_{T,\theta}$ el LSE y BLUE de β respectivamente, con esto definimos el radio de eficiencia relativa

$$R(\theta) = \frac{\det(\text{Var}(\hat{\beta}_T))}{\det(\text{Var}(\tilde{\beta}_{T,\theta}))}. \quad (5.7)$$

Proposición 5.2.1.

Sea

$$Y_{t,T} = x_1\left(\frac{t}{T}\right)\beta_1 + x_2\left(\frac{t}{T}\right)\beta_2 + \sigma\left(\frac{t}{T}\right)[\theta\left(\frac{t}{T}\right)\epsilon_{t-1} + \epsilon_t], \quad t = 1, \dots, T.$$

Tal que $x_1(\cdot), x_2(\cdot) \in C^2([0, 1])$, $\theta(\cdot) \in C^2([0, 1])$ con derivadas acotadas y $|\theta(u)| < 1$ para todo $u \in [0, 1]$, $\beta = (\beta_1, \beta_2)'$ y $\epsilon_t \sim RB(0, 1)$.

Sea $\hat{\beta}_T$ el estimador LSE de β definido por

$$\hat{\beta}_T = \left(X_T' X_T\right)^{-1} X_T' Y_T$$

Donde X_T es la matriz de diseno de la regresin dada por

$$X_T = \begin{bmatrix} x_1\left(\frac{1}{T}\right) & x_2\left(\frac{1}{T}\right) \\ x_1\left(\frac{2}{T}\right) & x_2\left(\frac{2}{T}\right) \\ \vdots & \vdots \\ x_1\left(\frac{T}{T}\right) & x_2\left(\frac{T}{T}\right) \end{bmatrix},$$

$$e Y_T = (Y_{1,T}, Y_{2,T}, \dots, Y_{T,T})'.$$

Se tiene que

$$Var(\hat{\beta}_T) = (X_T' X_T)^{-1} X_T' \Gamma X_T (X_T' X_T)^{-1}. \quad (5.8)$$

Entonces

$$TVar(\hat{\beta}_T) \rightarrow \Sigma^{-1} \Omega \Sigma^{-1}. \quad (5.9)$$

Cuando $T \rightarrow \infty$. Donde

$$\Omega = \int_0^1 \sigma(u)^2 [1 + \theta(u)]^2 \begin{bmatrix} x_1(u)^2 & x_1(u)x_2(u) \\ x_2(u)x_1(u) & x_2(u)^2 \end{bmatrix} du$$

y

$$\Sigma = \int_0^1 \begin{bmatrix} x_1(u)^2 & x_1(u)x_2(u) \\ x_2(u)x_1(u) & x_2(u)^2 \end{bmatrix} du.$$

Ejemplo 5.2.1.

En este ejemplo, estudiamos el comportamiento de la varianza del BLUE de β de una regresión lineal con errores LSMA(1), definido por

$$Y_{t,T} = x_1\left(\frac{t}{T}\right)\beta_1 + x_2\left(\frac{t}{T}\right)\beta_2 + \theta\left(\frac{t}{T}\right)\epsilon_{t-1} + \epsilon_t$$

Donde $\epsilon_t \stackrel{iid}{\sim} N(0, 1)$, $x_1(u) = u$, $x_2(u) = \sin(2\pi u)$, $u \in [0, 1]$ y $\theta(u) = 0.5 - u^2$, $u \in [0, 1]$. Luego simulamos 1000 series de tiempo LSMA(1) de largo $T = 1000, 3000, 5000$ y 10000.

Tabla 5.5: Matriz de covarianza teórica del LSE de β de una regresión lineal con errores LSMA(1) de parámetro $\theta(u) = 0.5 - u^2$.

Método	Varianza		Covarianza
	$\hat{\beta}_{1,T}$	$\hat{\beta}_{2,T}$	$(\hat{\beta}_{1,T}, \hat{\beta}_{2,T})$
T=1000			
Exacta	0.00423115	0.00420429	0.00268254
Muestral	0.00401619	0.00417747	0.00268177
Asintótica	0.00424268	0.00420828	0.00268747
Método	Varianza		Covarianza
	$\hat{\beta}_{1,T}$	$\hat{\beta}_{2,T}$	$(\hat{\beta}_{1,T}, \hat{\beta}_{2,T})$
T=3000			
Exacta	0.00141295	0.00140232	0.00089528
Muestral	0.00136537	0.00136908	0.00086790
Asintótica	0.00141423	0.00140276	0.00089582

Método	Varianza		Covarianza
	$\hat{\beta}_{1,T}$	$\hat{\beta}_{2,T}$	$(\hat{\beta}_{1,T}, \hat{\beta}_{2,T})$
T=5000			
Exacta	0.00084808	0.0008415	0.00053730
Muestral	0.00090352	0.00085823	0.00055899
Asintótica	0.00084854	0.00084166	0.00053749
Método	Varianza		Covarianza
	$\hat{\beta}_{1,T}$	$\hat{\beta}_{2,T}$	$(\hat{\beta}_{1,T}, \hat{\beta}_{2,T})$
T=10000			
Exacta	0.00042415	0.00042079	0.00026870
Muestral	0.00043715	0.00045810	0.00028685
Asintótica	0.00042427	0.00042083	0.00026875

Tabla 5.6: Matriz de covarianza teórica del BLUE de β de una regresión lineal con errores LSMA(1) de parámetro $\theta(u) = 0.5 - u^2$.

Método	Varianza		Covarianza
	$\tilde{\beta}_{1,T,\Theta}$	$\tilde{\beta}_{2,T,\Theta}$	$(\tilde{\beta}_{1,T,\Theta}, \tilde{\beta}_{2,T,\Theta})$
T=1000			
Exacta	0.00293252	0.00359134	0.00194498
Muestral	0.00271893	0.00345475	0.00174226
Asintótica	0.00292604	0.00358879	0.00193800
Método	Varianza		Covarianza
	$\tilde{\beta}_{1,T,\Theta}$	$\tilde{\beta}_{2,T,\Theta}$	$(\tilde{\beta}_{1,T,\Theta}, \tilde{\beta}_{2,T,\Theta})$
T=3000			
Exacta	0.00097608	0.00119655	0.00064679
Muestral	0.00092131	0.00117628	0.00060615
Asintótica	0.00097535	0.00119626	0.00064600

Método	Varianza		Covarianza
	$\tilde{\beta}_{1,T,\Theta}$	$\tilde{\beta}_{2,T,\Theta}$	$(\tilde{\beta}_{1,T,\Theta}, \tilde{\beta}_{2,T,\Theta})$
T=5000			
Exacta	0.00058547	0.00071786	0.00038789
Muestral	0.00057087	0.00069827	0.00038477
Asintótica	0.00058521	0.00071776	0.00038760
Método	Varianza		Covarianza
	$\tilde{\beta}_{1,T,\Theta}$	$\tilde{\beta}_{2,T,\Theta}$	$(\tilde{\beta}_{1,T,\Theta}, \tilde{\beta}_{2,T,\Theta})$
T=10000			
Exacta	0.00029267	0.00035891	0.00019387
Muestral	0.00028689	0.00038069	0.00019915
Asintótica	0.00029260	0.00035888	0.00019380

Tabla 5.7: Radio de Eficiencia: Determinante varianza LSE v/s determinante varianza BLUE de β para una regresión lineal con errores LSMA(1) de parámetro $\theta(u) = 0.5 - u^2$.

R	Tamaño Muestral			
	T=1000	T=3000	T=5000	T=10000
Exacto	1.569	1.574	1.574	1.575
Asintótico	1.576	1.576	1.576	1.576

Tabla 5.8: Radio de Eficiencia: Varianza LSE v/s varianza BLUE para β_1 de una regresión lineal con errores LSMA(1) de parámetro $\theta(u) = 0.5 - u^2$.

R	Tamaño Muestral			
	T=1000	T=3000	T=5000	T=10000
Exacto	1.442	1.447	1.448	1.449
Asintótico	1.449	1.449	1.449	1.449

Observación 5.2.1.

Las muestras de esta regresión fueron simuladas mediante el algoritmo de recursión. La tabla 5.5 muestra el estudio de simulación para ilustrar el cálculo de la varianza teórica del LSE de β y la tabla 5.6 muestra el estudio de simulación para ilustrar el cálculo de la varianza teórica del BLUE de β .

Para el LSE, la varianza exacta está dada por (5.8) y la varianza asintótica está dada por (5.9) y para el BLUE, la varianza exacta está dada por (3.7) y la varianza asintótica está dada por (3.8). De la tabla 5.7 notamos que el determinante de la matriz de varianza teórica y asintótica del LSE es aproximadamente un 57 % mayor respecto al determinante de la matriz de varianza teórica y asintótica del BLUE. Y de la tabla 5.8 notamos que la varianza teórica y asintótica del LSE de β_1 es aproximadamente un 44 % mayor respecto a la varianza teórica y asintótica del BLUE de β_1 .

Ejemplo 5.2.2.

En este ejemplo estudiamos el comportamiento de la varianza del BLUE de β de una regresión lineal con errores LSMA(2)

$$Y_{t,T} = x_1\left(\frac{t}{T}\right)\beta_1 + x_2\left(\frac{t}{T}\right)\beta_2 + \sigma\left(\frac{t}{T}\right)\left[\theta_2\left(\frac{t}{T}\right)\epsilon_{t-2} + \theta_1\left(\frac{t}{T}\right)\epsilon_{t-1} + \epsilon_t\right]$$

donde $\epsilon_t \stackrel{iid}{\sim} N(0, 1)$, $x_1(u) = u$, $x_2(u) = e^{-u}$, $u \in [0, 1]$, $\sigma(u) = \sqrt{0.5 + u}$, $u \in [0, 1]$ y $\theta_1(u) = u - 0.5$, $\theta_2(u) = 0.5\sqrt{u} - 0.5$, $u \in [0, 1]$.

Tabla 5.9: Comparación matriz de covarianza teórica del LSE de β de una regresión lineal con errores LSMA(2) de parámetros $\theta_1(u) = u - 0.5$, $\theta_2(u) = 0.5\sqrt{u} - 0.5$ y $\sigma(u) = \sqrt{0.5 + u}$.

Método	Varianza		Covarianza
	$\hat{\beta}_{1,T}$	$\hat{\beta}_{2,T}$	$(\hat{\beta}_{1,T}, \hat{\beta}_{2,T})$
T=1000			
Exacta	0.01425052	0.00283452	-0.00489251
Muestral	0.01485995	0.00297628	-0.00512581
Asintótica	0.01424579	0.00280557	-0.00487114
Método	Varianza		Covarianza
	$\hat{\beta}_{1,T}$	$\hat{\beta}_{2,T}$	$(\hat{\beta}_{1,T}, \hat{\beta}_{2,T})$
T=3000			
Exacta	0.00474914	0.00093843	-0.00162611
Muestral	0.00506705	0.00097231	-0.00175754
Asintótica	0.00474860	0.00093519	-0.00162371

Método	Varianza		Covarianza
	$\hat{\beta}_{1,T}$	$\hat{\beta}_{2,T}$	$(\hat{\beta}_{1,T}, \hat{\beta}_{2,T})$
T=5000			
Exacta	0.00284936	0.00056229	-0.00097509
Muestral	0.00281932	0.00052120	-0.00093939
Asintótica	0.00284916	0.00056111	-0.00097423
Método	Varianza		Covarianza
	$\hat{\beta}_{1,T}$	$\hat{\beta}_{2,T}$	$(\hat{\beta}_{1,T}, \hat{\beta}_{2,T})$
T=10000			
Exacta	0.00142463	0.00028085	-0.00048733
Muestral	0.00134595	0.00026223	-0.00045491
Asintótica	0.00142458	0.00028056	-0.00048711

Tabla 5.10: Comparación matriz de covarianza teórica del BLUE de β de una regresión lineal con errores LSMA(2) de parámetros $\theta_1(u) = u - 0.5$, $\theta_2(u) = 0.5\sqrt{u} - 0.5$ y $\sigma(u) = \sqrt{0.5 + u}$.

Método	Varianza		Covarianza
	$\tilde{\beta}_{1,T,\Theta}$	$\tilde{\beta}_{2,T,\Theta}$	$(\tilde{\beta}_{1,T,\Theta}, \tilde{\beta}_{2,T,\Theta})$
T=1000			
Exacta	0.00800724	0.00083814	-0.00136840
Muestral	0.00757377	0.00082073	-0.00118721
Asintótica	0.00778900	0.00074928	-0.00123067
Método	Varianza		Covarianza
	$\tilde{\beta}_{1,T,\Theta}$	$\tilde{\beta}_{2,T,\Theta}$	$(\tilde{\beta}_{1,T,\Theta}, \tilde{\beta}_{2,T,\Theta})$
T=3000			
Exacta	0.00262482	0.00026107	-0.00042800
Muestral	0.00249987	0.00025377	-0.00040002
Asintótica	0.00259633	0.00024976	-0.00041022

Método	Varianza		Covarianza
	$\tilde{\beta}_{1,T,\Theta}$	$\tilde{\beta}_{2,T,\Theta}$	$(\tilde{\beta}_{1,T,\Theta}, \tilde{\beta}_{2,T,\Theta})$
T=5000			
Exacta	0.00156864	0.00015413	-0.00025288
Muestral	0.00154800	0.00015354	-0.00025606
Asintótica	0.00155780	0.00014986	-0.00024613
Método	Varianza		Covarianza
	$\tilde{\beta}_{1,T,\Theta}$	$\tilde{\beta}_{2,T,\Theta}$	$(\tilde{\beta}_{1,T,\Theta}, \tilde{\beta}_{2,T,\Theta})$
T=10000			
Exacta	0.00078177	0.00007606	-0.00012485
Muestral	0.00079948	0.00008216	-0.00013725
Asintótica	0.00077890	0.00007493	-0.00012307

Tabla 5.11: Radio de Eficiencia: Determinante varianza LSE v/s determinante varianza BLUE de β de una regresión lineal con errores LSMA(2) de parámetros $\theta_1(u) = u - 0.5$, $\theta_2(u) = 0.5\sqrt{u} - 0.5$ y $\sigma(u) = \sqrt{0.5 + u}$.

R	Tamaño Muestral			
	T=1000	T=3000	T=5000	T=10000
Exacto	3.401	3.610	3.662	3.706
Asintótico	3.757	3.757	3.757	3.757

Observación 5.2.2.

Las muestras de esta regresión fueron simuladas mediante el algoritmo de recursión. La tabla 5.9 muestra el estudio de simulación para ilustrar el cálculo de la varianza teórica del LSE de β y la tabla 5.10 muestra el estudio de simulación para ilustrar el cálculo de la varianza teórica del BLUE de β .

Para el LSE, la varianza exacta está dada por (5.8) y la varianza asintótica está dada por (5.9) y para el BLUE, la varianza exacta está dada por (3.7) y la varianza asintótica está dada por (3.8). De la tabla 5.11 notamos que el determinante de la matriz de varianza teórica y asintótica del LSE es aproximadamente un 370 % mayor respecto al determinante de la matriz de varianza teórica y asintótica del BLUE.

Capítulo 6

Estimador de Whittle

En este capítulo usaremos el estimador de Whittle, introducida por Dahlhaus (1997), para estimar los parámetros de medias móviles de variación en el tiempo, para así obtener una estimación de la varianza del BLUE. Además compararemos esta varianza estimada con la varianza estimada del LSE mediante el radio de eficiencia relativa.

6.1. Estimación

Dahlhaus (1997) establece la metodología para estimar procesos localmente estacionarios de corta dependencia basado en una extensión local del estimador propuesto por Whittle (1953).

Sea $\theta \in \Theta \subset \mathbb{R}^p$ un vector de parámetros especificados en el modelo (2.1). Dada una muestra $\{Y_{1,T}, \dots, Y_{T,T}\}$ del proceso (2.1) podemos estimar θ minimizando la generalización de la función de Whittle donde el periodograma usual es reemplazado por periodogramas locales en cada uno de los segmentos de la muestra. Así, la función log-Verosimilitud de Whittle está dada por

$$\mathcal{L}_T(\theta) = \frac{1}{4\pi} \frac{1}{M} \int_{-\pi}^{\pi} \sum_{j=1}^M \left\{ \log f_{\theta}(u_j, \lambda) + \frac{I_N(u_j, \lambda)}{f_{\theta}(u_j, \lambda)} \right\} d\lambda$$

donde $f_{\theta}(u, \lambda) = |A_{\theta}(u, \lambda)|^2$ es la densidad espectral del proceso,

$$I_N(u, \lambda) = \frac{|D_N(u, \lambda)|^2}{2\pi H_{2,N}(0)}$$

es el periodograma con taper donde

$$D_N(u, \lambda) = \sum_{s=0}^{N-1} h\left(\frac{s}{N}\right) Y_{[uT]-N/2+s+1,T} e^{-i\lambda s}$$

$$H_{k,N} = \sum_{s=0}^{N-1} h^k\left(\frac{s}{N}\right) e^{-i\lambda s}$$

$T = S(M-1) + N$, $u_j = t_j/T$, $t_j = S(j-1) + N/2$, $j = 1, \dots, M$ y $h(\cdot)$ es el taper de los datos. De esta manera, la muestra $\{Y_{1,T}, \dots, Y_{T,T}\}$ es subdividida en M bloques de tamaño N y salto S entre cada uno de los bloques. Luego el espectro es estimado localmente por el periodograma local evaluado en el punto medio u_j en cada uno de los M bloques. Por lo tanto, el estimador de Whittle del vector de parámetros θ está dado por

$$\hat{\theta}_T = \arg \min \mathcal{L}_T(\theta)$$

donde la minimización es sobre el espacio paramétrico Θ .

Note que $\mathcal{L}_T(\theta)$ es una aproximación de la función de verosimilitud exacta Gaussiana, al igual que el caso estacionario, luego $\hat{\theta}_T$ es un estimador de máxima verosimilitud aproximado.

6.2. Teoría Asintótica

Para establecer propiedades asintóticas del estimador, Dahlhaus (1997) establece algunos supuestos:

Supuestos 6.1.

S6.1 La función $A(u, \lambda)$ es diferenciable en u y λ con derivadas uniformemente acotadas $(\partial/\partial u)(\partial/\partial \lambda)A$.

S6.2 El espacio paramétrico $\Theta \subset \mathbb{R}^p$ es compacto. La función $f_\theta(u, \lambda)$ es uniformemente acotada por arriba y por abajo. Las componentes de $f_\theta(u, \lambda)$, $\nabla f_\theta(u, \lambda)$ y $\nabla^2 f_\theta(u, \lambda)$ son continuas en $\Theta \times [0, 1] \times [-\pi, \pi]$, donde ∇ corresponde al gradiente con respecto a θ . $\nabla f_{\theta_0}^{-1}$ y $\nabla^2 f_{\theta_0}^{-1}$ son diferenciables en u y λ con derivadas uniformemente acotadas $(\partial/\partial u)(\partial/\partial \lambda)g$, donde $g = (\partial/\partial \theta_i)f_{\theta_0}^{-1}$ o $g = (\partial/\partial \theta_i)(\partial/\partial \theta_j)f_{\theta_0}^{-1}$

S6.3 θ_0 existe únicamente y se encuentra en el interior de Θ

S6.4 N, S y T cumplen con la relación $T^{1/4} \ll N \ll T^{1/2}/\ln T$ y $S = N$ o $S/N \rightarrow 0$

S6.5 El taper de los datos $h : \mathbb{R} \rightarrow \mathbb{R}$ con $h(x) = 0$ para todo $x \notin [0, 1]$, es una función continua en $\mathbb{R}$ y dos veces diferenciable.

A partir de los supuestos mencionados anteriormente, los *Teoremas 3.2 y 3.4* de Dahlhaus (1997) establecen la consistencia y la normalidad asintótica del estimador de Whittle, demostrando que $\hat{\theta}_T \rightarrow \theta_0$ en probabilidad cuando $T \rightarrow \infty$, y $\sqrt{T}(\hat{\theta}_T - \theta_0) \rightarrow N(0, \Gamma^{-1})$ en distribución cuando $T \rightarrow \infty$ donde

$$\Gamma = \frac{1}{4\pi} \int_0^1 \int_{-\pi}^{\pi} [\nabla \log f_{\theta_0}(u, \lambda)] [\nabla \log f_{\theta_0}(u, \lambda)]' d\lambda du$$

En el *Teorema 3.6* de Dahlhaus (1996b) se demuestra que Γ es el límite de la matriz de información de Fisher. Por lo tanto, $\hat{\theta}_T$ es un estimador (Fisher) eficiente. Si el modelo es estacionario (f_{θ} no depende de u), la varianza asintótica corresponde a la del caso estacionario, aun cuando el modelo subyacente es un proceso no estacionario. Además, se puede obtener la distribución asintótica del estimador si se ajusta un modelo no estacionario a una serie estacionaria.

6.3. Simulaciones

Esta sección trata sobre el cálculo estimado de la varianza del BLUE de β para el proceso $\{Y_{t,T}\}_t$ que satisface la definición 3.3 usando el estimador de Whittle para los parámetros $\theta_1, \dots, \theta_k$ y σ . Al igual que antes denotamos por $\hat{\beta}_T$ al LSE de β , $\tilde{\beta}_{T,\Theta}$ al BLUE de β suponiendo conocidos los parámetros $\Theta = (\theta_1, \dots, \theta_k, \sigma)$ y $\tilde{\beta}_{T,\hat{\Theta}}$ al BLUE de β con los parámetros $\hat{\Theta} = (\hat{\theta}_1, \dots, \hat{\theta}_k, \hat{\sigma})$ estimados por Whittle. También veremos el comportamiento de la matriz de varianza exacta del BLUE, que está dada por la ecuación (3.7) usando los parámetros estimados por Whittle, la cual llamaremos varianza exacta *plug-in*, analizaremos el comportamiento de la fórmula asintótica de la matriz de covarianzas del BLUE dada por el *Teorema 3.1* usando el mismo procedimiento, la cual llamaremos varianza asintótica *plug-in* y finalmente veremos la matriz de varianza muestral *plug-in*. Estas comparaciones se ilustran con un proceso LSMA(1) y LSMA(2) con parámetros de variación en el tiempo que evolucionan mediante polinomios, y regresores tales que $x_i(\cdot) \in C^2([0, 1])$ para $i \in \{1, \dots, k\}$.

Ejemplo 6.3.1.

En este primer ejemplo, estudiamos el comportamiento de la varianza del BLUE de la media constante μ de un proceso LSMA(1), definido por

$$Y_{t,T} = \mu + \theta\left(\frac{t}{T}\right)\epsilon_{t-1} + \epsilon_t$$

donde $\epsilon_t \stackrel{iid}{\sim} N(0, 1)$, $\theta(u) = u - 0.8$, $u \in [0, 1]$ y $\mu = 2$.




Figura 6.1: Función de variación en el tiempo $\theta(u) = u - 0.8$.




Figura 6.2: Simulación de un proceso LSMA(1) con parámetro $\theta(u) = u - 0.8$.




Figura 6.3: ACF de un proceso LSMA(1) con parámetro $\theta(u) = u - 0.8$.




Figura 6.4: PACF de un proceso LSMA(1) con parámetro $\theta(u) = u - 0.8$.




Figura 6.5: Evolución de θ y σ por ventanas.

Tabla 6.1: Estimaciones del LSE y BLUE de la media constante μ , y estimadores de Whittle de los parámetros $\theta(u) = a_0 + a_1 u$ y $\sigma(u) = b_0$ de un proceso LSMA(1). Tamaño muestral $T = 1000$.

Estimación de μ			Estimación de Whittle		
$\hat{\mu}_T$	$\tilde{\mu}_{T,\Theta}$	$\tilde{\mu}_{T,\hat{\Theta}}$	$\hat{a}_0$	$\hat{a}_1$	$\hat{b}_0$
1.998806	1.999115	1.998948	0.79826910	-1.0122344	0.9984992

Tabla 6.2: Comparación de la varianza del LSE y BLUE de la media constante μ de un proceso LSMA(1) con parámetro $\theta(u) = u - 0.8$ usando el estimador de Whittle. Tamaño muestral $T = 1000$.

	Método					
	Exacta	Exacta <i>plug-in</i>	Asintótica	Asintótica <i>plug-in</i>	Muestral	Muestral <i>plug-in</i>
Varianza						
$\hat{\mu}_T$	0.00177044	0.00175433	0.001773333	0.00175724	0.001880441	0.001880441
$\tilde{\mu}_{T,\Theta}$	0.00143800	0.00140777	0.001440000	0.00140969	0.001494618	0.001493673
Eficiencia						
R	1.23118100	1.24617700	1.231481000	1.24654100	1.258141000	1.258937000

Observación 6.3.1.

Las muestras de este proceso LSMA(1) fueron simuladas mediante el algoritmo de recursión usando 1000 trayectorias de tamaños $T = 1000$. La tabla 6.2 muestra el estudio de simulación para ilustrar el cálculo de la varianza del LSE y BLUE de μ , en donde se compara las varianzas exactas, asintóticas y muestrales estimadas usando el método de Whittle. Además se reporta el radio de eficiencia para cada varianza.

Ejemplo 6.3.2.

En este ejemplo, estudiamos el comportamiento de la varianza del BLUE de la media constante μ de un proceso LSMA(1), definido por

$$Y_{t,T} = \mu + \sigma\left(\frac{t}{T}\right) \left[\theta\left(\frac{t}{T}\right) \epsilon_{t-1} + \epsilon_t \right]$$

donde $\epsilon_t \stackrel{iid}{\sim} N(0, 1)$, $\theta(u) = 0.8 - 1.5u$, $\sigma(u) = 1.25 - 0.5u$, $u \in [0, 1]$ y $\mu = 2$.




Figura 6.6: Función de variación en el tiempo $\theta(u) = 0.8 - 1.5u$.




Figura 6.7: Función de variación en el tiempo $\sigma(u) = 1.5 - 0.5u$.




Figura 6.8: Simulación de un proceso LSMA(1) con parámetros $\theta(u) = 0.8 - 1.5u$ y $\sigma(u) = 1.5 - 0.5u$.




Figura 6.9: ACF de un proceso LSMA(1) con parámetros $\theta(u) = 0.8 - 1.5u$ y $\sigma(u) = 1.5 - 0.5u$.




Figura 6.10: PACF de un proceso LSMA(1) con parámetros $\theta(u) = 0.8 - 1.5u$ y $\sigma(u) = 1.5 - 0.5u$.




Figura 6.11: Evolución de θ y σ por ventanas.

Tabla 6.3: Estimaciones del LSE y BLUE de la media constante μ , y estimadores de Whittle de los parámetros $\theta(u) = a_0 + a_1u$ y $\sigma(u) = b_0 + b_1u$ de un proceso LSMA(1). Tamaño muestral $T = 1000$.

Estimación de μ			Estimación de Whittle			
$\hat{\mu}_T$	$\tilde{\mu}_{T,\Theta}$	$\tilde{\mu}_{T,\hat{\Theta}}$	$\hat{a}_0$	$\hat{a}_1$	$\hat{b}_0$	$\hat{b}_1$
2.000930	2.000700	2.000684	0.7970616	-1.5168464	1.2428036	-0.4956332

Tabla 6.4: Comparación de la varianza del LSE y BLUE de la media constante μ de un proceso LSMA(1) con parámetros $\theta(u) = 0.8 - 1.5u$ y $\sigma(u) = 1.5 - 0.5u$ usando el estimador de Whittle. Tamaño muestral $T = 1000$.

	Método					
	Exacta	Exacta <i>plug-in</i>	Asintótica	Asintótica <i>plug-in</i>	Muestral	Muestral <i>plug-in</i>
Varianza						
$\hat{\mu}_T$	0.00157761	0.00155418	0.00158250	0.00155906	0.00161610	0.00161610
$\tilde{\mu}_{T,\Theta}$	0.00038841	0.00035376	0.00038601	0.00035060	0.00040887	0.00041759
Eficiencia						
R	4.06175800	4.39326400	4.09958600	4.44688800	3.95258700	3.87007300

Observación 6.3.2.

Las muestras de este proceso LSMA(1) fueron simuladas mediante el algoritmo de recursión usando 1000 trayectorias de tamaños $T = 1000$. La tabla 6.4 muestra el estudio de simulación para ilustrar el cálculo de la varianza del LSE y BLUE de μ , en donde se compara las varianzas exactas, asintóticas y muestrales estimadas usando el método de Whittle. Además se reporta el radio de eficiencia para cada varianza.

Ejemplo 6.3.3.

En este ejemplo, estudiamos el comportamiento de la varianza del BLUE de β de una regresión lineal con errores LSMA(1), definido por

$$Y_{t,T} = x_1\left(\frac{t}{T}\right)\beta_1 + x_2\left(\frac{t}{T}\right)\beta_2 + \sigma\left(\frac{t}{T}\right)\left[\theta\left(\frac{t}{T}\right)\epsilon_{t-1} + \epsilon_t\right]$$

donde $\epsilon_t \stackrel{iid}{\sim} N(0, 1)$, $x_1(u) = 1$, $x_2(u) = u$, $u \in [0, 1]$ $\theta(u) = 0.8u - 0.8$ $\sigma(u) = 1 + 0.25u$, $u \in [0, 1]$ y $(\beta_1, \beta_2)' = (0.5, 1.0)$




Figura 6.12: Función de variación en el tiempo $x_1(u) = 1$, $x_2(u) = u$.




Figura 6.13: Función de variación en el tiempo $\theta(u) = 0.8u - 0.8$.




Figura 6.14: Función de variación en el tiempo $\sigma(u) = 1 + 0.25u$.




Figura 6.15: Simulación de un proceso LSMA(1) con parámetros $\theta(u) = 0.8u - 0.8$ y $\sigma(u) = 1 + 0.25u$.




Figura 6.16: ACF de un proceso LSMA(1) con parámetros $\theta(u) = 0.8u - 0.8$ y $\sigma(u) = 1 + 0.25u$.




Figura 6.17: PACF de un proceso LSMA(1) con parámetros $\theta(u) = 0.8u - 0.8$ y $\sigma(u) = 1 + 0.25u$.




Figura 6.18: Evolución de θ y σ por ventanas.

Tabla 6.5: Estimaciones del LSE y BLUE de β , y estimadores de Whittle de los parámetros $\theta_1(u) = a_0 + a_1u$ y $\sigma(u) = b_0 + c_bu$ de un proceso LSMA(1). Tamaño muestral $T = 1000$.

Estimación de β					
$\hat{\beta}_{1,T}$	$\hat{\beta}_{2,T}$	$\tilde{\beta}_{1,T,\Theta}$	$\tilde{\beta}_{2,T,\Theta}$	$\tilde{\beta}_{1,T,\hat{\Theta}}$	$\tilde{\beta}_{2,T,\hat{\Theta}}$
0.5017026	0.9971180	0.5006801	0.9994745	0.5009397	0.9987200
Estimación de Whittle					
$\hat{a}_0$	$\hat{a}_1$	$\hat{b}_0$	$\hat{b}_1$		
-0.7887266	0.7881779	1.0011059	0.2525151		

Tabla 6.6: Comparación de la varianza del LSE y BLUE de β de una regresión lineal con errores LSMA(1) de parámetros $\theta(u) = 0.8u - 0.8$ y $\sigma(u) = 1 + 0.25u$ usando el estimador de Whittle. Tamaño muestral $T = 1000$.

	Método					
	Exacta	Exacta <i>plug-in</i>	Asintótica	Asintótica <i>plug-in</i>	Muestral	Muestral <i>plug-in</i>
Varianza						
$\hat{\beta}_{1,T}$	0.00109844	0.00113824	0.00107771	0.00111767	0.00104947	0.00104947
$\tilde{\beta}_{1,T,\Theta}$	0.00047392	0.00050925	0.00044673	0.00048169	0.00044566	0.00045486
$\hat{\beta}_{2,T}$	0.00800149	0.00818941	0.00795086	0.00813922	0.00793069	0.00793069
$\tilde{\beta}_{2,T,\Theta}$	0.00442663	0.00454755	0.00430313	0.00441643	0.00450095	0.00457879
Covarianza						
$(\hat{\beta}_{1,T}, \hat{\beta}_{2,T})$	-0.00252721	-0.00260042	-0.00249493	-0.00256837	-0.00243296	-0.00243296
$(\tilde{\beta}_{1,T,\Theta}, \tilde{\beta}_{2,T,\Theta})$	-0.00103604	-0.00109100	-0.00097890	-0.00103195	-0.00100226	-0.00102851
Eficiencia						
R	2.34495600	2.26850400	2.43136800	2.34599300	2.40051300	2.34546600

Observación 6.3.3.

Las muestras de este proceso LSMA(1) fueron simuladas mediante el algoritmo de recursión usando 1000 trayectorias de tamaños $T = 1000$. La tabla 6.6 muestra el estudio de simulación para ilustrar el cálculo de la varianza del LSE y BLUE de β , en donde se compara las varianzas exactas, asintóticas y muestrales estimadas usando el método de Whittle. Además se reporta el radio de eficiencia para cada varianza.

Ejemplo 6.3.4.

En este ejemplo, estudiamos el comportamiento de la varianza del BLUE de β de una regresión lineal con errores LSMA(2), definido por

$$Y_{t,T} = x_1\left(\frac{t}{T}\right)\beta_1 + x_2\left(\frac{t}{T}\right)\beta_2 + \sigma\left(\frac{t}{T}\right)\left[\theta_2\left(\frac{t}{T}\right)\epsilon_{t-2} + \theta_1\left(\frac{t}{T}\right)\epsilon_{t-1} + \epsilon_t\right]$$

donde $\epsilon_t \stackrel{iid}{\sim} N(0, 1)$, $x_1(u) = u$, $x_2(u) = \sin(2\pi u)$, $u \in [0, 1]$ $\theta_1(u) = u - 0.7$, $\theta_2(u) = 0.5u$, $\sigma(u) = 1.025 - 0.5u + 0.5u^2$, $u \in [0, 1]$ y $(\beta_1, \beta_2)' = (0.5, 0.8)$.




Figura 6.19: Función de variación en el tiempo $x_1(u) = u$, $x_2(u) = \sin(2\pi u)$.




Figura 6.20: Funciones de variación en el tiempo $\theta_1(u) = u - 0.7$ y $\theta_2(u) = 0.5u$.




Figura 6.21: Función de variación en el tiempo $\sigma(u) = 1.025 - 0.5u + 0.5u^2$.




Figura 6.22: Simulación de un proceso LSMA(2) con parámetros $\theta_1(u) = u - 0.7$, $\theta_2(u) = 0.5u$ y $\sigma(u) = 1.025 - 0.5u + 0.5u^2$.




Figura 6.23: ACF de un proceso LSMA(2) con parámetros $\theta_1(u) = u - 0.7$, $\theta_2(u) = 0.5u$ y $\sigma(u) = 1.025 - 0.5u + 0.5u^2$.




Figura 6.24: PACF de un proceso LSMA(2) con parámetros $\theta_1(u) = u - 0.7$, $\theta_2(u) = 0.5u$ y $\sigma(u) = 1.025 - 0.5u + 0.5u^2$.




Figura 6.25: Evolución de θ_1 , θ_2 y σ por ventanas.

Tabla 6.7: Estimaciones del LSE y BLUE de β , y estimadores de Whittle de los parámetros $\theta_1(u) = a_0 + a_1u$ $\theta_2(u) = b_0 + b_1u$ y $\sigma(u) = c_0 + c_1u + c_2u^2$ de un proceso LSMA(2). Tamaño muestral $T = 1000$.

Estimación de β						
$\hat{\beta}_{1,T}$	$\hat{\beta}_{2,T}$	$\tilde{\beta}_{1,T,\Theta}$	$\tilde{\beta}_{2,T,\Theta}$	$\tilde{\beta}_{1,T,\hat{\Theta}}$	$\tilde{\beta}_{2,T,\hat{\Theta}}$	
0.4989744	0.8000925	0.4993575	0.7998934	0.4993905	0.7999422	
Estimación de Whittle						
$\hat{a}_0$	$\hat{a}_1$	$\hat{b}_0$	$\hat{b}_1$	$\hat{c}_0$	$\hat{c}_1$	$\hat{c}_2$
-0.67242463	0.97726643	0.02952341	0.46771851	1.05026101	-0.59153125	0.57959710

Tabla 6.8: Comparación de la varianza del LSE y BLUE de β de una regresión lineal con errores LSMA(2) de parámetros $\theta_1(u) = u - 0.7$, $\theta_2(u) = 0.5u$ y $\sigma(u) = 1.025 - 0.5u + 0.5u^2$ usando el estimador de Whittle. Tamaño muestral $T = 1000$.

	Método					
	Exacta	Exacta <i>plug-in</i>	Asintótica	Asintótica <i>plug-in</i>	Muestral	Muestral <i>plug-in</i>
Varianza						
$\hat{\beta}_{1,T}$	0.00555681	0.00580705	0.00556900	0.00582014	0.00526425	0.00526425
$\tilde{\beta}_{1,T,\Theta}$	0.00443541	0.00465052	0.00443671	0.00465266	0.00424483	0.00429117
$\hat{\beta}_{2,T}$	0.00170257	0.00184183	0.00169909	0.00183854	0.00169700	0.00169700
$\tilde{\beta}_{2,T,\Theta}$	0.00119824	0.00136819	0.00119346	0.00136377	0.00122618	0.00124126
Covarianza						
$(\hat{\beta}_{1,T}, \hat{\beta}_{2,T})$	0.00007082	0.00014739	0.00007175	0.00014859	-0.00002111	-0.00002111
$(\tilde{\beta}_{1,T,\Theta}, \tilde{\beta}_{2,T,\Theta})$	-0.00027152	-0.00019119	-0.00027394	-0.00019338	-0.00031400	-0.00032839
Eficiencia						
R	1.80421600	1.69689400	1.81171000	1.70261600	1.74940500	1.71176400

Observación 6.3.4.

Las muestras de este proceso LSMA(2) fueron simuladas mediante el algoritmo de recursión usando 1000 trayectorias de tamaños $T = 1000$. La tabla 6.8 muestra el estudio de simulación para ilustrar el cálculo de la varianza del LSE y BLUE de β , en donde se compara las varianzas exactas, asintóticas y muestrales estimadas usando el método de Whittle. Además se reporta el radio de eficiencia para cada varianza.

Ejemplo 6.3.5.

En este ejemplo, estudiamos el comportamiento de la varianza del BLUE de β de una regresión lineal con errores LSMA(2), definido por

$$Y_{t,T} = x_1\left(\frac{t}{T}\right)\beta_1 + x_2\left(\frac{t}{T}\right)\beta_2 + \sigma\left(\frac{t}{T}\right)\left[\theta_2\left(\frac{t}{T}\right)\epsilon_{t-2} + \theta_1\left(\frac{t}{T}\right)\epsilon_{t-1} + \epsilon_t\right]$$

donde $\epsilon_t \stackrel{iid}{\sim} N(0, 1)$, $x_1(u) = u$, $x_2(u) = \sin(2\pi u)$, $u \in [0, 1]$ $\theta_1(u) = u - 0.5$, $\theta_2(u) = 0.5 - 0.5u$, $\sigma(u) = 1.25 - u + u^2$, $u \in [0, 1]$ y $(\beta_1, \beta_2)' = (0.5, 0.8)$.




Figura 6.26: Función de variación en el tiempo $x_1(u) = 1$, $x_2(u) = u$.




Figura 6.27: Funciones de variación en el tiempo $\theta_1(u) = u - 0.5$ y $\theta_2(u) = 0.5 - 0.5u$.




Figura 6.28: Función de variación en el tiempo $\sigma(u) = 1.25 - u + u^2$.




Figura 6.29: Simulación de un proceso LSMA(2) con parámetros $\theta_1(u) = u - 0.5$, $\theta_2(u) = 0.5 - 0.5u$ y $\sigma(u) = 1.25 - u + u^2$.




Figura 6.30: ACF de un proceso LSMA(2) con parámetros $\theta_1(u) = u - 0.5$, $\theta_2(u) = 0.5 - 0.5u$ y $\sigma(u) = 1.25 - u + u^2$.




Figura 6.31: PACF de un proceso LSMA(2) con parámetros $\theta_1(u) = u - 0.5$, $\theta_2(u) = 0.5 - 0.5u$ y $\sigma(u) = 1.25 - u + u^2$.




Figura 6.32: Evolución de θ_1 , θ_2 y σ por ventanas.

Tabla 6.9: Estimaciones del LSE y BLUE de β , y estimadores de Whittle de los parámetros $\theta_1(u) = a_0 + a_1u$ $\theta_2(u) = b_0 + b_1u$ y $\sigma(u) = c_0 + c_1u + c_2u^2$ de un proceso LSMA(2). Tamaño muestral $T = 1000$.

Estimación de β						
$\hat{\beta}_{1,T}$	$\hat{\beta}_{2,T}$	$\tilde{\beta}_{1,T,\Theta}$	$\tilde{\beta}_{2,T,\Theta}$	$\tilde{\beta}_{1,T,\hat{\Theta}}$	$\tilde{\beta}_{2,T,\hat{\Theta}}$	
0.4983587	0.7986588	0.4977910	0.7989960	0.4977062	0.7989289	
Estimación de Whittle						
$\hat{a}_0$	$\hat{a}_1$	$\hat{b}_0$	$\hat{b}_1$	$\hat{c}_0$	$\hat{c}_1$	$\hat{c}_2$
-0.2499242	1.0125645	0.5013871	-0.5088787	1.2510435	-1.0322133	1.0504564

Tabla 6.10: Comparación de la varianza del LSE y BLUE de β de una regresión lineal con errores LSMA(2) de parámetros $\theta_1(u) = u - 0.5$, $\theta_2(u) = 0.5 - 0.5u$ y $\sigma(u) = 1.25 - u + u^2$ usando el estimador de Whittle. Tamaño muestral $T = 1000$.

	Método					
	Exacta	Exacta <i>plug-in</i>	Asintótica	Asintótica <i>plug-in</i>	Muestral	Muestral <i>plug-in</i>
Varianza						
$\hat{\beta}_{1,T}$	0.01062031	0.01086776	0.01064428	0.01089164	0.01045466	0.01045466
$\tilde{\beta}_{1,T,\Theta}$	0.00995891	0.01005023	0.00997982	0.01007096	0.00979010	0.00986010
$\hat{\beta}_{2,T}$	0.00553284	0.00556790	0.00553494	0.00556991	0.00512561	0.00512561
$\tilde{\beta}_{2,T,\Theta}$	0.00543459	0.00543239	0.00543657	0.00543440	0.00510590	0.00512479
Covarianza						
$(\hat{\beta}_{1,T}, \hat{\beta}_{2,T})$	0.00219734	0.00218796	0.00220293	0.00219335	0.00188314	0.00188314
$(\tilde{\beta}_{1,T,\Theta}, \tilde{\beta}_{2,T,\Theta})$	0.00204191	0.00199739	0.00204643	0.00200181	0.00177126	0.00178653
Eficiencia						
R	1.07965400	1.10237200	1.07977900	1.10245300	1.06809700	1.057057

Observación 6.3.5.

Las muestras de este proceso LSMA(2) fueron simuladas mediante el algoritmo de recursión usando 1000 trayectorias de tamaños $T = 1000$. La tabla 6.10 muestra el estudio de simulación para ilustrar el cálculo de la varianza del LSE y BLUE de β , en donde se compara las varianzas exactas, asintóticas y muestrales estimadas usando el método de Whittle. Además se reporta el radio de eficiencia para cada varianza.

Capítulo 7

Aplicaciones

En este capítulo se presentará un estudio de comparación de la varianza ajustada exácta y la varianza ajustada asintótica del LSE y BLUE de β (μ para $X = (1, 1, \dots, 1)'$) mediante la eficiencia relativa, para el modelo

$$Y_{t,T} = X'(\frac{t}{T})\beta + \sigma(\frac{t}{T}) \sum_{j=0}^q \theta_j(\frac{t}{T}) \epsilon_{t-j}, \quad t = 1, \dots, T.$$

ajustado a series reales.

El método que utilizaremos será el siguiente: Primero modelar la tendencia de la serie mediante una regresión polinómica ajustando el vector de parámetros β utilizando el LSE, después de esto, obtenemos una nueva serie $Y_{1,t,T}$ definida por

$$Y_{1,t,T} = Y_{t,T} - X'(\frac{t}{T})\hat{\beta}_T.$$

A la cual ajustamos un modelo LSMA(q) utilizando el estimador de Whittle. Con esto obtenemos los parámetros del modelo LSMA(q) con los cuales estimamos el BLUE

de β , el cual lo llamamos BLUE plug-in. Luego podemos repetir el proceso y con esto obtener un mejor ajuste de la tendencia.

7.1. Anillos de Árbol

El área de la dendrocronología estudia el ancho de los anillos de crecimiento de un árbol. La motivación principal para trabajar con este tipo de datos, es que son un muy buen proxies para la reconstrucción del clima en el pasado, el presente y el futuro, ver Tan et al. (2003).

Las figuras 7.1 y 7.2 muestran respectivamente, la serie y la ACF del ancho anual de anillos de árboles de *Juniperus occidentalis* (Western Juniper) medidos en Idaho, EE. UU., desde el año 1492 al 1984. Estos datos, están disponibles en el National Climatic Data Center, y son reportados por Holmes R. L. and Earle (1985).

La ACF muestra tres autocorrelaciones significativas, por lo que el modelo de MA estacionario puede ser apropiado para los datos. Sin embargo, una mirada más cercana a la autocorrelación sugiere que la estructura de dependencia está cambiando con el tiempo, esto también lo podemos apreciar en la gráfica del periodograma suavizado (Fig. 7.3). Para explicar este cambio, se propone un modelo LSMA(q) a los datos.




Figura 7.1: Datos anillos de árbol.




Figura 7.2: ACF.




Figura 7.3: Periodograma suavizado.




Figura 7.4: Ajuste splines.

Ahora mediante un ajuste de splines suavizados (Fig. 7.4), vemos la evolución de los parámetros en el tiempo. En primera instancia se ajustó una recta para $\theta_1(u), \sigma(u)$ y un polinomio cuadrático para $\theta_2(u)$. Pero para $\theta_2(u) = b_0 + b_1u + b_2u^2$, las constantes estimadas b_1 y b_2 resultaron ser no significativas. Por ende se evaluó las siguientes estructura; una recta para $\theta_1(u), \sigma(u)$ y una constante para $\theta_2(u)$, es decir,

$$\theta_1(u) = a_0 + a_1u, \quad \theta_2(u) = b_0, \quad \sigma(u) = c_0$$

Obteniendo los siguientes resultados:

Tabla 7.1: Tabla resumen ajuste.

Parámetro	Estimación	SD	z-value	p-value
a_0	0.4202	0.0969	4.3361	0.0000
a_1	-0.3881	0.1891	-2.0521	0.0402
b_0	0.1613	0.0440	3.6677	0.0002
c_0	0.2968	0.0084	35.2201	0.0000
c_1	-0.0601	0.0154	-3.9018	0.0001

De la tabla 7.1 se observa que todos los parámetro son significativos al 5 % de significancia. Finalmente, se presenta un análisis residual para el modelo LSMA(2)




Figura 7.5: Análisis de residuos.




Figura 7.6: Ajuste.

ajustado. Se presentan los residuos estandarizados del modelo, ACF y PACF de los residuos y el Test de Ljung-Box (Fig. 7.5). Vemos que no se observan autocorrelaciones significativas o autocorrelaciones parciales en los paneles. Además, las estadísticas de Ljung-Box para probar el test de la blancura de los residuos indica que la hipótesis del ruido blanco no se rechaza considerado el nivel de significancia del 5 %. Este conjunto de datos de la vida real nos sirve como ilustración de una serie de tiempo con una estructura de dependencia que varía en el tiempo que no está adecuadamente adaptada por un modelo estacionario.

Una vez obtenido el modelo ajustado, procedemos a analizar la eficiencia relativa del LSE de μ versus el BLUE Plug-in. Para esto, notamos que

$$\hat{\theta}_1(u) + \hat{\theta}_2(u) = \hat{a}_0 + \hat{a}_1 u + \hat{b}_0 = 0.5815 - 0.3881u.$$

Luego del capítulo 5, vemos las figuras 5.1 y 5.2, en donde ubicamos el punto $(a, b) = (0.5815, -0.3881)$ sobre una zona de eficiencia relativa cercana a uno, pues se encuentra alejada de las asíntotas de la superficie $R(\theta(a, b))$.

Esto lo vemos numéricamente en la tabla 7.2, en donde comparamos las varianzas y observamos que la varianza teórica y asintótica del LSE es aproximadamente un 9 % y 20 % mayor respecto a la varianza teórica y asintótica del BLUE, respectivamente.

Tabla 7.2: Radio de Eficiencia: Varianza LSE v/s varianza BLUE Plug-in de μ de un proceso LSMA(2)

	Método	
	Exacta <i>plug-in</i>	Asintótica <i>plug-in</i>
Varianza		
$\hat{\mu}_T$	0.0002858931	0.00028665
$\tilde{\mu}_{T,\Theta}$	0.0002625421	0.00023838
Eficiencia		
R	1.088942	1.202518

Capítulo 8

Conclusiones y Trabajos Futuros

Conclusiones

La idea de este trabajo es ver de forma teórica la eficiencia del LSE versus el BLUE para la media constante μ de un proceso LSMA(q) y también para el vector de parámetros β de una regresión lineal con errores LSMA(q). Por el *Capítulo 5*, se concluye que para la media constante μ de un proceso LSMA(1) hay ciertas regiones en donde la eficiencia relativa se hace tan grande como sea deseable, ya que en ese caso particular vimos curvas de nivel y una superficie para el radio de eficiencia $R(\theta)$ cuando $\theta(u)$ era una función lineal, es decir, $\theta(u) = a + bu$. En este mismo capítulo vimos que en la regresión lineal con errores LSMA(1), también tenemos el caso donde el LSE es poco eficiente respecto al BLUE de β . Es por esto que concluimos que la

eficiencia asintótica del LSE se pierde en los procesos localmente estacionarios.

Además se tiene que el BLUE para la media de un proceso LSMA(q) es consistente y asintóticamente normal, así como también se tiene que el BLUE del vector de parámetros β de una regresión lineal con errores LSMA(q) es consistente y asintóticamente normal.

Trabajos Futuros

A continuación daremos un listado de los trabajos futuros de esta tesis:

1. Extender los resultados conjeturados en el *Capítulo 4*.
2. Estudiar la eficiencia relativa para μ y β cuando se estiman los parámetros del proceso LSMA(q) probando otros estimadores distintos al estimador de Whittle.
3. Extender los resultados a los procesos localmente estacionarios de larga memoria.

Apéndice A

Apéndice

Demostraciones a los *Teoremas, Lemas y Proposiciones* de la tesis.

Teoremas

Teorema 3.1.

Sea $\{Y_{t,T}\}_t$ un proceso que satisface la definición 3.3 y los supuestos S3.1 – S3.6. Sea

$\tilde{\beta}_{T,\Theta}$ el BLUE de β . Entonces

$$TVar(\tilde{\beta}_{T,\Theta}) \sim V = \left[\int_0^1 \frac{X(u)X'(u)}{\sigma(u)^2 \left[\sum_{j=0}^q \theta_j(u) \right]^2} du \right]^{-1}.$$

En términos de la densidad espectral se tiene que

$$TVar(\tilde{\beta}_{T,\Theta}) \sim V = 2\pi \left[\int_0^1 \frac{X(u)X'(u)}{f(u,0)} du \right]^{-1}.$$

Donde $a_T \sim b_T$ significa que $a_T/b_T \rightarrow 1$ cuando $T \rightarrow \infty$.

Demostración.

El BLUE de β está dado por

$$\tilde{\beta}_{T,\Theta} = \left(X_T' \Gamma^{-1} X_T \right)^{-1} X_T' \Gamma^{-1} Y_T.$$

$$\text{Definamos } C_T' = \begin{bmatrix} c_1\left(\frac{1}{T}\right) & c_1\left(\frac{2}{T}\right) & \cdots & c_1\left(\frac{T}{T}\right) \\ c_2\left(\frac{1}{T}\right) & c_2\left(\frac{2}{T}\right) & \cdots & c_2\left(\frac{T}{T}\right) \\ \vdots & \vdots & & \vdots \\ c_k\left(\frac{1}{T}\right) & c_k\left(\frac{2}{T}\right) & \cdots & c_k\left(\frac{T}{T}\right) \end{bmatrix} = \left(X_T' \Gamma^{-1} X_T \right)^{-1} X_T' \Gamma^{-1},$$

Así tenemos que

$$\begin{aligned} Var(\tilde{\beta}_{T,\Theta}) &= Var(C_T' Y_T) \\ &= C_T' Var(Y_T) C_T \\ &= C_T' \Gamma C_T. \end{aligned} \tag{A.1}$$

$$Y \text{ además } C_T' X_T = I_k. \tag{A.2}$$

Con esto buscamos una matriz C_T que "minimice" (A.1) sujeto a la condición (A.2). Además notamos que esta matriz depende de los parámetros $\theta_1(u), \dots, \theta_q(u)$,

por esto, es que suponemos que $C_T = C_T(\theta(u))$ donde cada componente está en $C^2([0, 1])$ con derivadas acotadas.

Del cálculo diferencial matricial, ver Magnus and Neudecker (1999) para más detalles, definimos la siguiente función objetivo a minimizar

$$L(C_T, \Lambda) = \frac{1}{2} \text{tr}(C_T' \Gamma C_T) - \text{tr}(\Lambda'(C_T' X_T - I_2)), \quad \Lambda \in M_{k \times k}(\mathbb{R})$$

La que optimizaremos usando el método de los multiplicadores de Lagrange. En efecto tenemos que

$$\begin{aligned} \Gamma C_T &= X_T \Lambda' \\ C_T' X_T &= I_k \end{aligned}$$

De esto obtenemos que

$$\Gamma C_T = X_T (C_T' \Gamma C_T) = X_T V_T$$

Donde $V_T \in M_{k \times k}(\mathbb{R})$ simétrica tal que $\text{Var}(\tilde{\beta}_{T,\Theta}) = V_T = (v_{i,j})_{i,j=1,\dots,k}$. Así obtenemos las siguientes ecuaciones

$$\begin{aligned}
\sum_{i=1}^k x_i\left(\frac{t}{T}\right) v_{li} &= \sigma\left(\frac{t}{T}\right) \sigma\left(\frac{t-q}{T}\right) \theta_q\left(\frac{t}{T}\right) c_l\left(\frac{t-q}{T}\right) + \sigma\left(\frac{t+q}{T}\right) \sigma\left(\frac{t}{T}\right) \theta_q\left(\frac{t+q}{T}\right) c_l\left(\frac{t+q}{T}\right) + \\
&\quad \sigma\left(\frac{t}{T}\right) \sigma\left(\frac{t-(q-1)}{T}\right) \left[\sum_{j=0}^1 \theta_{j+q-1}\left(\frac{t}{T}\right) \theta_j\left(\frac{t-(q-1)}{T}\right) \right] c_l\left(\frac{t-(q-1)}{T}\right) + \\
&\quad \sigma\left(\frac{t+(q-1)}{T}\right) \sigma\left(\frac{t}{T}\right) \left[\sum_{j=0}^1 \theta_{j+q-1}\left(\frac{t+(q-1)}{T}\right) \theta_j\left(\frac{t}{T}\right) \right] c_l\left(\frac{t+(q-1)}{T}\right) + \\
&\quad \sigma\left(\frac{t}{T}\right) \sigma\left(\frac{t-(q-2)}{T}\right) \left[\sum_{j=0}^2 \theta_{j+q-2}\left(\frac{t}{T}\right) \theta_j\left(\frac{t-(q-2)}{T}\right) \right] c_l\left(\frac{t-(q-2)}{T}\right) + \\
&\quad \sigma\left(\frac{t+(q-2)}{T}\right) \sigma\left(\frac{t}{T}\right) \left[\sum_{j=0}^2 \theta_{j+q-2}\left(\frac{t+(q-2)}{T}\right) \theta_j\left(\frac{t}{T}\right) \right] c_l\left(\frac{t+(q-2)}{T}\right) + \cdots + \\
&\quad \sigma\left(\frac{t}{T}\right) \sigma\left(\frac{t-1}{T}\right) \left[\sum_{j=0}^{q-1} \theta_{j+1}\left(\frac{t}{T}\right) \theta_j\left(\frac{t-1}{T}\right) \right] c_l\left(\frac{t-1}{T}\right) + \\
&\quad \sigma\left(\frac{t+1}{T}\right) \sigma\left(\frac{t}{T}\right) \left[\sum_{j=0}^{q-1} \theta_{j+1}\left(\frac{t+1}{T}\right) \theta_j\left(\frac{t}{T}\right) \right] c_l\left(\frac{t+1}{T}\right) + \\
&\quad \sigma\left(\frac{t}{T}\right)^2 \left[\sum_{j=0}^q \theta_j\left(\frac{t}{T}\right)^2 \right] c_l\left(\frac{t}{T}\right) \tag{A.3}
\end{aligned}$$

Para $l \in \{1, \dots, k\}$, $t \in \{q+1, \dots, T-q\}$. Donde $c_i\left(\frac{t}{T}\right)$ es la componente t -ésima de la columna i de la matriz C_T , $i = 1, 2$.

Primero notamos que para $z \in \mathbb{Z}$, $l \in \{1, \dots, k\}$ y $j \in \{1, \dots, q\}$

$$\sigma\left(\frac{t+z}{T}\right) = \sigma\left(\frac{t}{T}\right) + \sigma'\left(\frac{t}{T}\right) \frac{z}{T} + O\left(\frac{1}{T^2}\right)$$

$$\theta_j\left(\frac{t+z}{T}\right) = \theta_j\left(\frac{t}{T}\right) + \theta_j'\left(\frac{t}{T}\right) \frac{z}{T} + O\left(\frac{1}{T^2}\right)$$

$$c_l\left(\frac{t+z}{T}\right) = c_l\left(\frac{t}{T}\right) + c_l'\left(\frac{t}{T}\right) \frac{z}{T} + O\left(\frac{1}{T^2}\right)$$

Por otro lado

$$\begin{aligned}\sum_{j=0}^{q-h} \theta_{j+h}\left(\frac{t}{T}\right) \theta_j\left(\frac{t-h}{T}\right) &= \sum_{j=0}^{q-h} \theta_{j+h}\left(\frac{t}{T}\right) \theta_j\left(\frac{t}{T}\right) - \theta_{j+h}\left(\frac{t}{T}\right) \theta'_j\left(\frac{t}{T}\right) \frac{h}{T} + O\left(\frac{1}{T^2}\right) \\ \sum_{j=0}^{q-h} \theta_{j+h}\left(\frac{t+h}{T}\right) \theta_j\left(\frac{t}{T}\right) &= \sum_{j=0}^{q-h} \theta_{j+h}\left(\frac{t}{T}\right) \theta_j\left(\frac{t}{T}\right) + \theta'_{j+h}\left(\frac{t}{T}\right) \theta_j\left(\frac{t}{T}\right) \frac{h}{T} + O\left(\frac{1}{T^2}\right)\end{aligned}$$

Ahora

$$\begin{aligned}
& \sigma\left(\frac{t-h}{T}\right) \left[\sum_{j=0}^{q-h} \theta_{j+h}\left(\frac{t}{T}\right) \theta_j\left(\frac{t-h}{T}\right) \right] c_l\left(\frac{t-h}{T}\right) + \sigma\left(\frac{t+h}{T}\right) \left[\sum_{j=0}^{q-h} \theta_{j+h}\left(\frac{t+h}{T}\right) \theta_j\left(\frac{t}{T}\right) \right] c_l\left(\frac{t+h}{T}\right) \\
&= \left[\sum_{j=0}^{q-h} \theta_{j+h}\left(\frac{t}{T}\right) \theta_j\left(\frac{t}{T}\right) \right] \left(\sigma\left(\frac{t-h}{T}\right) c_l\left(\frac{t-h}{T}\right) + \sigma\left(\frac{t+h}{T}\right) c_l\left(\frac{t+h}{T}\right) \right) - \\
& \sigma\left(\frac{t-h}{T}\right) \left[\sum_{j=0}^{q-h} \theta_{j+h}\left(\frac{t}{T}\right) \theta'_j\left(\frac{t}{T}\right) \right] c_l\left(\frac{t-h}{T}\right) \frac{h}{T} + \\
& \sigma\left(\frac{t+h}{T}\right) \left[\sum_{j=0}^{q-h} \theta'_{j+h}\left(\frac{t}{T}\right) \theta_j\left(\frac{t}{T}\right) \right] c_l\left(\frac{t+h}{T}\right) \frac{h}{T} + O\left(\frac{1}{T^2}\right) \\
&= 2\sigma\left(\frac{t}{T}\right) \left[\sum_{j=0}^{q-h} \theta_{j+h}\left(\frac{t}{T}\right) \theta_j\left(\frac{t}{T}\right) \right] c_l\left(\frac{t}{T}\right) - \sigma\left(\frac{t-h}{T}\right) \left[\sum_{j=0}^{q-h} \theta_{j+h}\left(\frac{t}{T}\right) \theta'_j\left(\frac{t}{T}\right) \right] c_l\left(\frac{t-h}{T}\right) \frac{h}{T} + \\
& \sigma\left(\frac{t+h}{T}\right) \left[\sum_{j=0}^{q-h} \theta'_{j+h}\left(\frac{t}{T}\right) \theta_j\left(\frac{t}{T}\right) \right] c_l\left(\frac{t+h}{T}\right) \frac{h}{T} + O\left(\frac{1}{T^2}\right) \\
&= 2\sigma\left(\frac{t}{T}\right) \left[\sum_{j=0}^{q-h} \theta_{j+h}\left(\frac{t}{T}\right) \theta_j\left(\frac{t}{T}\right) \right] c_l\left(\frac{t}{T}\right) - \sigma\left(\frac{t}{T}\right) \left[\sum_{j=0}^{q-h} \theta_{j+h}\left(\frac{t}{T}\right) \theta'_j\left(\frac{t}{T}\right) \right] c_l\left(\frac{t}{T}\right) \frac{h}{T} + \\
& \sigma\left(\frac{t}{T}\right) \left[\sum_{j=0}^{q-h} \theta'_{j+h}\left(\frac{t}{T}\right) \theta_j\left(\frac{t}{T}\right) \right] c_l\left(\frac{t}{T}\right) \frac{h}{T} + O\left(\frac{1}{T^2}\right) \\
&= 2\sigma\left(\frac{t}{T}\right) \left[\sum_{j=0}^{q-h} \theta_{j+h}\left(\frac{t}{T}\right) \theta_j\left(\frac{t}{T}\right) \right] c_l\left(\frac{t}{T}\right) + \\
& \sigma\left(\frac{t}{T}\right) \left[\sum_{j=0}^{q-h} \theta'_{j+h}\left(\frac{t}{T}\right) \theta_j\left(\frac{t}{T}\right) - \theta_{j+h}\left(\frac{t}{T}\right) \theta'_j\left(\frac{t}{T}\right) \right] c_l\left(\frac{t}{T}\right) \frac{h}{T} + O\left(\frac{1}{T^2}\right) \\
&= 2\sigma\left(\frac{t}{T}\right) \left[\sum_{j=0}^{q-h} \theta_{j+h}\left(\frac{t}{T}\right) \theta_j\left(\frac{t}{T}\right) \right] c_l\left(\frac{t}{T}\right) + \sigma\left(\frac{t}{T}\right) \Delta_h\left(\frac{t}{T}\right) c_l\left(\frac{t}{T}\right) \frac{1}{T} + O\left(\frac{1}{T^2}\right)
\end{aligned}$$

Donde

$$\Delta_h\left(\frac{t}{T}\right) = h \left[\sum_{j=0}^{q-h} \theta'_{j+h}\left(\frac{t}{T}\right) \theta_j\left(\frac{t}{T}\right) - \theta_{j+h}\left(\frac{t}{T}\right) \theta'_j\left(\frac{t}{T}\right) \right].$$

Usando lo anterior en la ecuación (A.3) para $h \in \{1, \dots, q\}$ se tiene

$$\begin{aligned}
\sum_{i=1}^k x_i\left(\frac{t}{T}\right) v_{li} &= 2\sigma\left(\frac{t}{T}\right)^2 \theta_q\left(\frac{t}{T}\right) c_l\left(\frac{t}{T}\right) + \sigma\left(\frac{t}{T}\right)^2 \Delta_q\left(\frac{t}{T}\right) c_l\left(\frac{t}{T}\right) \frac{1}{T} + \\
& 2\sigma\left(\frac{t}{T}\right)^2 \left[\sum_{j=0}^1 \theta_{j+q-1}\left(\frac{t}{T}\right) \theta_j\left(\frac{t}{T}\right) \right] c_l\left(\frac{t}{T}\right) + \sigma\left(\frac{t}{T}\right)^2 \Delta_{q-1}\left(\frac{t}{T}\right) c_l\left(\frac{t}{T}\right) \frac{1}{T} + \\
& 2\sigma\left(\frac{t}{T}\right)^2 \left[\sum_{j=0}^2 \theta_{j+q-2}\left(\frac{t}{T}\right) \theta_j\left(\frac{t}{T}\right) \right] c_l\left(\frac{t}{T}\right) + \sigma\left(\frac{t}{T}\right)^2 \Delta_{q-2}\left(\frac{t}{T}\right) c_l\left(\frac{t}{T}\right) \frac{1}{T} + \cdots + \\
& 2\sigma\left(\frac{t}{T}\right)^2 \left[\sum_{j=0}^{q-1} \theta_{j+1}\left(\frac{t}{T}\right) \theta_j\left(\frac{t}{T}\right) \right] c_l\left(\frac{t}{T}\right) + \sigma\left(\frac{t}{T}\right)^2 \Delta_1\left(\frac{t}{T}\right) c_l\left(\frac{t}{T}\right) \frac{1}{T} + \\
& \sigma\left(\frac{t}{T}\right)^2 \left[\sum_{j=0}^q \theta_j\left(\frac{t}{T}\right)^2 \right] c_l\left(\frac{t}{T}\right) + O\left(\frac{1}{T^2}\right)
\end{aligned}$$

$l \in \{1, \dots, k\}$. Por tanto

$$\begin{aligned}
\sum_{i=1}^k x_i\left(\frac{t}{T}\right) v_{li} &= \sigma\left(\frac{t}{T}\right)^2 \left[\sum_{j=0}^q \theta_j\left(\frac{t}{T}\right) \right]^2 c_l\left(\frac{t}{T}\right) + \sigma\left(\frac{t}{T}\right)^2 \sum_{j=0}^{q-1} \Delta_{q-j}\left(\frac{t}{T}\right) c_l\left(\frac{t}{T}\right) \frac{1}{T} + O\left(\frac{1}{T^2}\right) \\
&= \sigma\left(\frac{t}{T}\right)^2 \left(\left[\sum_{j=0}^q \theta_j\left(\frac{t}{T}\right) \right]^2 + \sum_{j=0}^{q-1} \Delta_{q-j}\left(\frac{t}{T}\right) \frac{1}{T} \right) c_l\left(\frac{t}{T}\right) + O\left(\frac{1}{T^2}\right) \quad (\text{A.4})
\end{aligned}$$

$l \in \{1, \dots, k\}$.

Ahora como las raíces del polinomio $p(z) = 1 + \theta_1(u)z + \theta_2(u)z^2 + \cdots + \theta_q(u)z^q$ están fuera del disco unitario para todo $u \in [0, 1]$ existe $\delta > 0$ tal que $(1 + \theta_1(u) + \theta_2(u) + \cdots + \theta_q(u))^2 \geq \delta > 0$.

Por otro lado, para $\epsilon = \delta/2$ existe T_0 tal que

$$\frac{\left| \sum_{j=0}^{q-1} \Delta_{q-j}\left(\frac{t}{T}\right) \right|}{T} < \epsilon, \quad \text{si } T > T_0$$

Luego

$$0 < \delta - \epsilon < \left[\sum_{j=0}^q \theta_j\left(\frac{t}{T}\right) \right]^2 + \sum_{j=0}^{q-1} \Delta_{q-j}\left(\frac{t}{T}\right) \frac{1}{T} < k + \epsilon$$

Donde

$$k = \max_{u \in [0,1]} \left[\sum_{j=0}^q \theta_j(u) \right]^2$$

Así, de las ecuaciones (A.4) tenemos

$$\frac{\sum_{i=1}^k x_i\left(\frac{t}{T}\right) v_{li}}{\sigma\left(\frac{t}{T}\right)^2 \left(\left[\sum_{j=0}^q \theta_j\left(\frac{t}{T}\right) \right]^2 + \sum_{j=0}^{q-1} \Delta_{q-j}\left(\frac{t}{T}\right) \frac{1}{T} \right)} = c_l\left(\frac{t}{T}\right) + \frac{1}{\sigma\left(\frac{t}{T}\right)^2 \left(\left[\sum_{j=0}^q \theta_j\left(\frac{t}{T}\right) \right]^2 + \sum_{j=0}^{q-1} \Delta_{q-j}\left(\frac{t}{T}\right) \frac{1}{T} \right)} O\left(\frac{1}{T^2}\right)$$

Para $l \in \{1, \dots, k\}$, o mejor

$$\frac{\sum_{i=1}^k x_i\left(\frac{t}{T}\right) v_{li}}{\sigma\left(\frac{t}{T}\right)^2 \left(\left[\sum_{j=0}^q \theta_j\left(\frac{t}{T}\right) \right]^2 + \sum_{j=0}^{q-1} \Delta_{q-j}\left(\frac{t}{T}\right) \frac{1}{T} \right)} = c_l\left(\frac{t}{T}\right) + O\left(\frac{1}{T^2}\right)$$

$l \in \{1, \dots, k\}$. Luego tenemos el siguiente sistema

$$c_l\left(\frac{t}{T}\right)x_r\left(\frac{t}{T}\right) = \frac{x_r\left(\frac{t}{T}\right) \sum_{i=1}^k x_i\left(\frac{t}{T}\right)v_{li}}{\sigma\left(\frac{t}{T}\right)^2 \left(\left[\sum_{j=0}^q \theta_j\left(\frac{t}{T}\right) \right]^2 + \sum_{j=0}^{q-1} \Delta_{q-j}\left(\frac{t}{T}\right)\frac{1}{T} \right)} + O\left(\frac{1}{T^2}\right) \quad (\text{A.5})$$

Donde $l, r \in \{1, \dots, k\}$. Pero $C'_T X_T = I_k$ entonces

$$\sum_{t=1}^T c_l\left(\frac{t}{T}\right)x_r\left(\frac{t}{T}\right) = \begin{cases} 1, & l = r \\ 0, & l \neq r \end{cases}$$

Luego al aplicar $\sum_{t=1}^T$ al sistema de ecuaciones (A.5) obtenemos

$$\sum_{t=1}^T \frac{x_r\left(\frac{t}{T}\right) \sum_{i=1}^k x_i\left(\frac{t}{T}\right)v_{li}}{\sigma\left(\frac{t}{T}\right)^2 \left(\left[\sum_{j=0}^q \theta_j\left(\frac{t}{T}\right) \right]^2 + \sum_{j=0}^{q-1} \Delta_{q-j}\left(\frac{t}{T}\right)\frac{1}{T} \right)} + O\left(\frac{1}{T}\right) = \begin{cases} 1, & l = r \\ 0, & l \neq r \end{cases} \quad (\text{A.6})$$

Ahora para $T > T_0$

$$\begin{aligned} \frac{1}{\left[\sum_{j=0}^q \theta_j\left(\frac{t}{T}\right) \right]^2 + \sum_{j=0}^{q-1} \Delta_{q-j}\left(\frac{t}{T}\right)\frac{1}{T}} &= \frac{1}{\left[\sum_{j=0}^q \theta_j\left(\frac{t}{T}\right) \right]^2} \left(1 - \frac{\sum_{j=0}^{q-1} \Delta_{q-j}\left(\frac{t}{T}\right)}{\left[\sum_{j=0}^q \theta_j\left(\frac{t}{T}\right) \right]^2 T} + O\left(\frac{1}{T^2}\right) \right) \\ &= \frac{1}{\left[\sum_{j=0}^q \theta_j\left(\frac{t}{T}\right) \right]^2} + O\left(\frac{1}{T}\right) \end{aligned}$$

Por tanto

$$\begin{aligned} \sum_{t=1}^T \frac{x_r\left(\frac{t}{T}\right) \sum_{i=1}^k x_i\left(\frac{t}{T}\right)}{\sigma\left(\frac{t}{T}\right)^2 \left(\left[\sum_{j=0}^q \theta_j\left(\frac{t}{T}\right) \right]^2 + \sum_{j=0}^{q-1} \Delta_{q-j}\left(\frac{t}{T}\right) \frac{1}{T} \right)} \frac{1}{T} &= \sum_{t=1}^T \frac{x_r\left(\frac{t}{T}\right) \sum_{i=1}^k x_i\left(\frac{t}{T}\right)}{\sigma\left(\frac{t}{T}\right)^2 \left[\sum_{j=0}^q \theta_j\left(\frac{t}{T}\right) \right]^2} \frac{1}{T} + O\left(\frac{1}{T}\right) \\ &\xrightarrow{T \rightarrow \infty} \int_0^1 \frac{x_r(u) \sum_{i=1}^k x_i(u)}{\sigma(u)^2 \left[\sum_{j=0}^q \theta_j(u) \right]^2} du \end{aligned}$$

Luego del sistema de ecuaciones (A.6) se tiene

$$TVar(\tilde{\beta}_{T,\Theta})\Omega \rightarrow I_k$$

Cuando $T \rightarrow \infty$.

$$\Omega = \int_0^1 \frac{X'(u)X(u)}{\sigma(u)^2 \left[\sum_{j=0}^q \theta_j(u) \right]^2} du.$$

Así tenemos que

$$TVar(\tilde{\beta}_{T,\Theta}) \rightarrow \Omega^{-1}.$$

Cuando $T \rightarrow \infty$. □

Teorema 3.2.

Sea $\{Y_{t,T}\}_t$ un proceso que satisface la definición 3.3 y los supuestos S3.1 – S3.6. Sea $\tilde{\beta}_{T,\Theta}$ el BLUE de β . Entonces $\tilde{\beta}_{T,\Theta}$ es un estimador consistente, es decir,

$$\tilde{\beta}_{T,\Theta} \xrightarrow{\mathbb{P}} \beta.$$

Cuando $T \rightarrow \infty$.

Demostración.

Sea α un vector fijo en $\mathbb{R}^k$ y sea $\epsilon > 0$, entonces

$$\begin{aligned}
\mathbb{P}(\alpha'|\tilde{\beta}_{T,\Theta} - \beta| > \epsilon) &\leq \frac{1}{\epsilon^2} \text{Var}(\alpha' \tilde{\beta}_{T,\Theta}) \\
&\leq \frac{1}{\epsilon^2} \alpha' \text{Var}(\tilde{\beta}_{T,\Theta}) \alpha \\
&\leq \frac{1}{\epsilon^2 T} \alpha' \left[\int_0^1 \frac{X(u)X'(u)}{\sigma(u)^2 \left[\sum_{j=0}^q \theta_j(u) \right]^2} du \right]^{-1} \alpha + O\left(\frac{1}{T}\right) \rightarrow 0
\end{aligned}$$

Cuando $T \rightarrow \infty$. □

Teorema 3.3.

Sea $\{Y_{t,T}\}_t$ un proceso que satisface la definición 3.3 y los supuestos S3.1-S3.6, donde $\{\epsilon_t\}_t$ es una secuencia de errores independientes e idénticamente distribuidas tal que $\mathbb{E}(\epsilon_t) = 0$, $\text{Var}(\epsilon_t) = 1$ y el n -ésimo cumulante $\kappa_n < \infty$ para todo $n \geq 3$. Sea $\tilde{\beta}_{T,\Theta}$ el BLUE de β . Entonces

$$\sqrt{T}(\tilde{\beta}_{T,\Theta} - \beta) \xrightarrow{D} N(0, V)$$

cuando $T \rightarrow \infty$, donde V está dado por (3.8).

Demostración.

Por Teorema, basta probar que para todo $\lambda \in \mathbb{R}^p$

$$\sqrt{T}(\lambda' \tilde{\beta}_{T,\Theta} - \lambda' \beta) \xrightarrow{D} N(0, v)$$

Para algún $v \in \mathbb{R}^+$. Al igual que antes, la demostración es una consecuencia del *Teorema de los Cumulantes*. (ver Jammalamadaka et al. (2006) para más detalles)

Por el *Lema 1.1.3* tenemos que

$$\tilde{\beta}_{T,\Theta} = S_T = C'_T Y_T = \left(\beta_1 + \sum_{k=1-q}^T a_{1,k,T} \epsilon_k, \dots, \beta_p + \sum_{k=1-q}^T a_{p,k,T} \epsilon_k \right)'$$

Donde

$$C'_T = \begin{bmatrix} c_{1,1} & c_{1,2} & \cdots & c_{1,T} \\ c_{2,1} & c_{2,2} & \cdots & c_{2,T} \\ \vdots & \vdots & & \vdots \\ c_{p,1} & c_{p,2} & \cdots & c_{p,T} \end{bmatrix} \in M_{p,T}(\mathbb{R}).$$

Donde $M_{p,T}(\mathbb{R})$ es el espacio de las matrices de $p \times T$ con coeficientes reales y

$$a_{l,k,T} = \sum_{t=\max\{1,k\}}^{\min\{T,k+q\}} c_{l,t} \sigma\left(\frac{t}{T}\right) \theta_{t-k}\left(\frac{t}{T}\right).$$

Para todo $l \in \{1, \dots, p\}$.

Similar a la demostración del *Teorema 3.3*, el supuesto *S3.6* implica que

$$|a_{l,k,T}| \leq C. \tag{A.7}$$

Para todo $l \in \{1, \dots, p\}$. Luego calculamos los primeros 2 cumulantes de $\lambda' \tilde{\beta}_{T,\Theta} = \lambda' S_T$, en efecto,

$$\begin{aligned}
Cum_1(\lambda' S_T) &= Cum \left(\sum_{l=1}^p \left(\lambda_l \beta_l + \lambda_l \sum_{k=1-q}^T a_{l,k,T} \epsilon_k \right) \right) \\
&= \mathbb{E} \left(\sum_{l=1}^p \left(\lambda_l \beta_l + \lambda_l \sum_{k=1-q}^T a_{l,k,T} \epsilon_k \right) \right) \\
&= \sum_{l=1}^p \left(\lambda_l \beta_l + \lambda_l \sum_{k=1-q}^T a_{l,k,T} \mathbb{E}(\epsilon_k) \right) \\
&= \sum_{l=1}^p \lambda_l \beta_l \\
&= \lambda' \beta.
\end{aligned}$$

$$\begin{aligned}
Cum_2(\lambda' S_T) &= Cum \left(\sum_{l_1=1}^p \left(\lambda_{l_1} \beta_{l_1} + \lambda_{l_1} \sum_{k_1=1-q}^T a_{l_1,k_1,T} \epsilon_{k_1} \right), \sum_{l_2=1}^p \left(\lambda_{l_2} \beta_{l_2} + \lambda_{l_2} \sum_{k_2=1-q}^T a_{l_2,k_2,T} \epsilon_{k_2} \right) \right) \\
&= Cov \left(\sum_{l_1=1}^p \left(\lambda_{l_1} \beta_{l_1} + \lambda_{l_1} \sum_{k_1=1-q}^T a_{l_1,k_1,T} \epsilon_{k_1} \right), \sum_{l_2=1}^p \left(\lambda_{l_2} \beta_{l_2} + \lambda_{l_2} \sum_{k_2=1-q}^T a_{l_2,k_2,T} \epsilon_{k_2} \right) \right) \\
&= \sum_{l_1=1}^p \sum_{l_2=1}^p \sum_{k_1=1-q}^T \sum_{k_2=1-q}^T \lambda_{l_1} a_{l_1,k_1,T} \lambda_{l_2} a_{l_2,k_2,T} Cov(\epsilon_{k_1}, \epsilon_{k_2}) \\
&= \sum_{l_1=1}^p \sum_{l_2=1}^p \sum_{k=1-q}^T \lambda_{l_1} \lambda_{l_2} a_{l_1,k,T} a_{l_2,k,T} \\
&= \lambda' Var(\tilde{\beta}_{T,\Theta}) \lambda.
\end{aligned}$$

Ahora calculamos el cumulante n -ésimo para $n \geq 3$, en efecto

$$\begin{aligned}
Cum_n(\lambda' S_T) &= Cum \left(\sum_{l_1=1}^p \lambda_{l_1} \left(\beta_{l_1} + \sum_{k_1=1-q}^T a_{l_1, k_1, T} \epsilon_{k_1} \right), \dots, \sum_{l_n=1}^p \lambda_{l_n} \left(\beta_{l_n} + \sum_{k_n=1-q}^T a_{l_n, k_n, T} \epsilon_{k_n} \right) \right) \\
&= \sum_{l_1=1}^p \cdots \sum_{l_n=1}^p \sum_{k_1=1-q}^T \cdots \sum_{k_n=1-q}^T \lambda_{l_1} a_{l_1, k_1, T} \cdots \lambda_{l_n} a_{l_n, k_n, T} Cum(\epsilon_{k_1}, \dots, \epsilon_{k_n}) \\
&= \sum_{l_1=1}^p \cdots \sum_{l_n=1}^p \sum_{k=1-q}^T \lambda_{l_1} a_{l_1, k, T} \cdots \lambda_{l_n} a_{l_n, k, T} \kappa_n \\
&= \kappa_n \sum_{l_1=1}^p \cdots \sum_{l_n=1}^p \sum_{k=1-q}^T \lambda_{l_1} a_{l_1, k, T} \cdots \lambda_{l_n} a_{l_n, k, T}
\end{aligned}$$

Se sabe del *Teorema 3.1* que

$$T\lambda'Var(\tilde{\beta}_{T,\Theta})\lambda \rightarrow V$$

cuando $T \rightarrow \infty$, donde $V \in \mathbb{R}^+$. Luego por (A.7) se tiene que

$$\begin{aligned}
|Cum_n(S_T)| &\leq |\kappa_n| \sum_{l_1=1}^p \cdots \sum_{l_n=1}^p \sum_{k=1-q}^T \left| \lambda_{l_1} a_{l_1, k, T} \cdots \lambda_{l_n} a_{l_n, k, T} \right| \\
&\leq |\kappa_n| C_1 (Cp)^{(n-2)} \sum_{l_1=1}^p \sum_{l_2=1}^p \sum_{k=1-q}^T \lambda_{l_1} \lambda_{l_2} a_{l_1, k, T} a_{l_2, k, T} \\
&\leq |\kappa_n| C_1 (Cp)^{(n-2)} \lambda'Var(\tilde{\beta}_{T,\Theta})\lambda \\
&\leq \frac{|\kappa_n| C_1 (Cp)^{(n-2)}}{T} \left(T\lambda'Var(\tilde{\beta}_{T,\Theta})\lambda \right) \rightarrow 0
\end{aligned}$$

Cuando $T \rightarrow \infty$. Donde $C_1 = \max_{l_3, \dots, l_n} \{|\lambda_{l_3} \cdots \lambda_{l_n}|\}$.

Luego tenemos que

$$\sqrt{T}(\lambda' \tilde{\beta}_{T,\Theta} - \lambda' \beta) \xrightarrow{\mathcal{D}} N(0, v).$$

Cuando $T \rightarrow \infty$, donde $v = \lambda'V\lambda$ y V está dado por (3.8). Y por tanto

$$\sqrt{T}(\tilde{\beta}_{T,\Theta} - \beta) \xrightarrow{\mathcal{D}} N(0, V).$$

Cuando $T \rightarrow \infty$, donde V está dado por (3.8).

□

Lemas

Lema 1.1.3.

Sea $\{Y_{t,T}\}_t$ un proceso definido por

$$Y_{t,T} = \sum_{i=1}^p x_i\left(\frac{t}{T}\right) \beta_i + \sigma\left(\frac{t}{T}\right) \sum_{j=0}^q \psi_j\left(\frac{t}{T}\right) \epsilon_{t-j},$$

Donde $\epsilon_t \sim RB(0, 1)$, $x_i(\cdot), \sigma(\cdot) \in C^2([0, 1])$ con derivadas acotadas para todo $i = 1, \dots, p$ tal que $\sigma(u) > 0$ para todo $u \in [0, 1]$ y los coeficientes $\psi_j(u) \in C^2([0, 1])$.

Sea

$$C'_T = \begin{bmatrix} c_{1,1} & c_{1,2} & \cdots & c_{1,T} \\ c_{2,1} & c_{2,2} & \cdots & c_{2,T} \\ \vdots & \vdots & & \vdots \\ c_{p,1} & c_{p,2} & \cdots & c_{p,T} \end{bmatrix}.$$

Definimos

$$C'_T Y_T = S_T = (S_{1,T}, S_{2,T}, \dots, S_{p,T})' = \left(\sum_{t=1}^T c_{1,t} Y_{t,T}, \sum_{t=1}^T c_{2,t} Y_{t,T}, \dots, \sum_{t=1}^T c_{p,t} Y_{t,T} \right)'$$

Tal que $\mathbb{E}(S_T) = (\beta_1, \beta_2, \dots, \beta_p)'$. Entonces

$$S_T = \left(\beta_1 + \sum_{k=1-q}^T a_{1,k,T} \epsilon_k, \beta_2 + \sum_{k=1-q}^T a_{2,k,T} \epsilon_k, \dots, \beta_p + \sum_{k=1-q}^T a_{p,k,T} \epsilon_k \right)'.$$

Donde

$$a_{l,k,T} = \sum_{t=\max\{1,k\}}^{\min\{T,k+q\}} c_{l,t}\sigma\left(\frac{t}{T}\right)\psi_{t-k}\left(\frac{t}{T}\right).$$

Para todo $l \in \{1, \dots, p\}$.

Demostración.

Sea $l \in \{1, \dots, p\}$.

$$\begin{aligned} c_{l,1}Y_{1,T} &= \sum_{i=1}^p x_i\left(\frac{1}{T}\right)c_{l,1}\beta_i + c_{l,1}\sigma\left(\frac{1}{T}\right)\sum_{j=0}^q \psi_j\left(\frac{1}{T}\right)\epsilon_{1-j} \\ c_{l,2}Y_{2,T} &= \sum_{i=1}^p x_i\left(\frac{2}{T}\right)c_{l,2}\beta_i + c_{l,2}\sigma\left(\frac{2}{T}\right)\sum_{j=0}^q \psi_j\left(\frac{2}{T}\right)\epsilon_{2-j} \\ &\vdots \\ c_{l,T}Y_{T,T} &= \sum_{i=1}^p x_i\left(\frac{T}{T}\right)c_{l,T}\beta_i + c_{l,T}\sigma\left(\frac{T}{T}\right)\sum_{j=0}^q \psi_j\left(\frac{T}{T}\right)\epsilon_{T-j} \end{aligned}$$

Así obtenemos que

$$\begin{aligned} S_{l,T} &= \sum_{t=1}^T \sum_{i=1}^p x_i\left(\frac{t}{T}\right)c_{l,t}\beta_i + \sum_{t=1}^T \sum_{j=0}^q c_{l,t}\sigma\left(\frac{t}{T}\right)\psi_j\left(\frac{t}{T}\right)\epsilon_{t-j} \\ &\stackrel{t-j=k}{=} \sum_{t=1}^T \sum_{i=1}^p x_i\left(\frac{t}{T}\right)c_{l,t}\beta_i + \sum_{t=1}^T \sum_{k=t}^{t-q} c_{l,t}\sigma\left(\frac{t}{T}\right)\psi_{t-k}\left(\frac{t}{T}\right)\epsilon_k \\ &= \sum_{t=1}^T \sum_{i=1}^p x_i\left(\frac{t}{T}\right)c_{l,t}\beta_i + \sum_{k=1-q}^1 \sum_{t=1}^{k+q} c_{l,t}\sigma\left(\frac{t}{T}\right)\psi_{t-k}\left(\frac{t}{T}\right)\epsilon_k + \sum_{k=2}^{T-q} \sum_{t=k}^{k+q} c_{l,t}\sigma\left(\frac{t}{T}\right)\psi_{t-k}\left(\frac{t}{T}\right)\epsilon_k \\ &\quad + \sum_{k=T-q+1}^T \sum_{t=k}^T c_{l,t}\sigma\left(\frac{t}{T}\right)\psi_{t-k}\left(\frac{t}{T}\right)\epsilon_k \\ &= \sum_{t=1}^T \sum_{i=1}^p x_i\left(\frac{t}{T}\right)c_{l,t}\beta_i + \sum_{k=1-q}^T \sum_{t=\max\{1,k\}}^{\min\{T,k+q\}} c_{l,t}\sigma\left(\frac{t}{T}\right)\psi_{t-k}\left(\frac{t}{T}\right)\epsilon_k \\ &= \sum_{t=1}^T \sum_{i=1}^p x_i\left(\frac{t}{T}\right)c_{l,t}\beta_i + \sum_{k=1-q}^T a_{l,k,T}\epsilon_k. \end{aligned}$$

Por otro lado la condición $\mathbb{E}(S_T) = (\beta_1, \beta_2, \dots, \beta_p)'$ implica que $\mathbb{E}(S_{l,T}) = \beta_l$, para todo $l \in \{1, \dots, p\}$. Luego

$$\sum_{t=1}^T x_i\left(\frac{t}{T}\right) c_{l,t} = \begin{cases} 1, & i = l \\ 0, & i \neq l \end{cases}$$

Por tanto tenemos que

$$S_{l,T} = \beta_l + \sum_{k=1-q}^T a_{l,k,T} \epsilon_k.$$

Luego se tiene que

$$S_T = \left(\beta_1 + \sum_{k=1-q}^T a_{1,k,T} \epsilon_k, \beta_2 + \sum_{k=1-q}^T a_{2,k,T} \epsilon_k, \dots, \beta_p + \sum_{k=1-q}^T a_{p,k,T} \epsilon_k \right)'.$$

Donde

$$a_{l,k,T} = \sum_{t=\max\{1,k\}}^{\min\{T,k+q\}} c_{l,t} \sigma\left(\frac{t}{T}\right) \psi_{t-k}\left(\frac{t}{T}\right).$$

Para todo $l \in \{1, \dots, p\}$. □

Proposiciones

Proposición 2.2.1.

Sea el proceso de medias móviles de orden q definido por

$$Y_{t,T} = \mu\left(\frac{t}{T}\right) + \sigma\left(\frac{t}{T}\right) \sum_{j=0}^q \theta_j\left(\frac{t}{T}\right) \epsilon_{t-j}$$

para $t = 1, \dots, T$, donde $\mu(\cdot)$, $\sigma(\cdot)$ son funciones continuas y $\sigma(u) > 0$ para todo $u \in [0, 1]$, $\theta_0(u) \equiv 1$ y $\{\epsilon_t\}_t$ es una secuencia de ruido blanco de media cero y varianza uno. ($\epsilon_t \sim RB(0, 1)$). Entonces

$$1) \quad \mathbb{E}(Y_{t,T}) = \mu\left(\frac{t}{T}\right).$$

$$2) \quad \text{Var}(Y_{t,T}) = \sigma\left(\frac{t}{T}\right)^2 \sum_{j=0}^q \theta_j\left(\frac{t}{T}\right)^2.$$

$$3) \quad \text{Cov}(Y_{t,T}, Y_{s,T}) = \begin{cases} \sigma\left(\frac{t}{T}\right)\sigma\left(\frac{s}{T}\right) \sum_{j=0}^q \theta_{t-s+j}\left(\frac{t}{T}\right)\theta_j\left(\frac{s}{T}\right) & , \quad 0 < t - s \leq q \\ 0 & , \quad t - s > q \end{cases}$$

para $t, s = 1, \dots, T$, $t > s$ y $\theta_j(u) = 0$ si $j > q$.

Demostración.

La esperanza del proceso está dada por

$$\begin{aligned}
\mathbb{E}(Y_{t,T}) &= \mathbb{E}\left(\mu\left(\frac{t}{T}\right) + \sigma\left(\frac{t}{T}\right) \sum_{j=0}^q \theta_j\left(\frac{t}{T}\right) \epsilon_{t-j}\right) \\
&= \mu\left(\frac{t}{T}\right) + \sigma\left(\frac{t}{T}\right) \sum_{j=0}^q \theta_j\left(\frac{t}{T}\right) \mathbb{E}(\epsilon_{t-j}) \\
&= \mu\left(\frac{t}{T}\right).
\end{aligned}$$

Pues $\epsilon_t \sim RB(0, 1)$.

La varianza del proceso está dada por

$$\begin{aligned}
Var(Y_{t,T}) &= Var\left(\mu\left(\frac{t}{T}\right) + \sigma\left(\frac{t}{T}\right) \sum_{j=0}^q \theta_j\left(\frac{t}{T}\right) \epsilon_{t-j}\right) \\
&= \sigma\left(\frac{t}{T}\right)^2 \sum_{j=0}^q \theta_j\left(\frac{t}{T}\right)^2 Var(\epsilon_{t-j}) \\
&= \sigma\left(\frac{t}{T}\right)^2 \sum_{j=0}^q \theta_j\left(\frac{t}{T}\right)^2.
\end{aligned}$$

Ya que $\epsilon_t \sim RB(0, 1)$.

Sea $t > s$, luego la covarianza del proceso está dada por

$$\begin{aligned}
Cov(Y_{t,T}, Y_{s,T}) &= Cov\left(\mu\left(\frac{t}{T}\right) + \sigma\left(\frac{t}{T}\right) \sum_{j=0}^q \theta_j\left(\frac{t}{T}\right) \epsilon_{t-j}, \mu\left(\frac{s}{T}\right) + \sigma\left(\frac{s}{T}\right) \sum_{i=0}^q \theta_i\left(\frac{s}{T}\right) \epsilon_{s-i}\right) \\
&= \sigma\left(\frac{t}{T}\right) \sigma\left(\frac{s}{T}\right) \sum_{j=0}^q \sum_{i=0}^q \theta_j\left(\frac{t}{T}\right) \theta_i\left(\frac{s}{T}\right) Cov(\epsilon_{t-j}, \epsilon_{s-i}) \\
&= \sigma\left(\frac{t}{T}\right) \sigma\left(\frac{s}{T}\right) \sum_{i=0}^q \theta_{t-s+i}\left(\frac{t}{T}\right) \theta_i\left(\frac{s}{T}\right)
\end{aligned}$$

Ya que $\epsilon_t \sim RB(0, 1)$ y $\theta_j(u) = 0$ si $j > q$.

Luego

$$Cov(Y_{t,T}, Y_{s,T}) = \begin{cases} \sigma\left(\frac{t}{T}\right)\sigma\left(\frac{s}{T}\right) \sum_{i=0}^q \theta_{t-s+i}\left(\frac{t}{T}\right)\theta_i\left(\frac{s}{T}\right) & , \quad 0 < t - s \leq q \\ 0 & , \quad t - s > q \end{cases}$$

Donde $\theta_j(u) = 0$ si $j > q$.

O equivalentemente

$$Cov(Y_{t,T}, Y_{s,T}) = \sigma\left(\frac{t}{T}\right)\sigma\left(\frac{s}{T}\right) \sum_{i=0}^{q-(t-s)} \theta_{t-s+i}\left(\frac{t}{T}\right)\theta_i\left(\frac{s}{T}\right)$$

Donde $t > s$. □

Proposición 2.4.1.

Para un proceso LSMA(1) con media constante μ y $\sigma(u)^2 = 1$, definido por

$$Y_{t,T} = \mu + \theta\left(\frac{t}{T}\right)\epsilon_{t-1} + \epsilon_t,$$

se tiene que

$$\gamma(u, k) = \begin{cases} 1 + \theta(u)^2 & , \quad k = 0 \\ \theta(u) & , \quad |k| = 1. \end{cases}$$

Demostración.

La densidad espectral de este proceso está dada por

$$f(u, \lambda) = \frac{1}{2\pi} \left(1 + 2 \cos(\lambda) \theta(u) + \theta(u)^2 \right), \quad u \in [0, 1], \quad \lambda \in [-\pi, \pi].$$

Luego obtenemos que

$$\begin{aligned}
\gamma(u, k) &= \int_{-\pi}^{\pi} f(u, \lambda) e^{i\lambda k} d\lambda \\
&= \int_{-\pi}^{\pi} \frac{1}{2\pi} \left(1 + 2 \cos(\lambda) \theta(u) + \theta(u)^2 \right) e^{i\lambda k} d\lambda \\
&= \frac{1}{\pi} \int_0^{\pi} \left(1 + 2 \cos(\lambda) \theta(u) + \theta(u)^2 \right) \cos(\lambda k) d\lambda \\
&= \frac{1}{\pi} \left(\int_0^{\pi} [1 + \theta(u)^2] \cos(\lambda k) d\lambda + \int_0^{\pi} 2\theta(u) \cos(\lambda) \cos(\lambda k) d\lambda \right) \\
&= \frac{1}{\pi} \left([1 + \theta(u)^2] \frac{\sin(\pi k)}{k} - 2\theta(u) k \frac{\sin(\pi k)}{k^2 - 1} \right) \\
&= \begin{cases} 1 + \theta(u)^2 & , k = 0 \\ \theta(u) & , |k| = 1. \end{cases}
\end{aligned}$$

□

Proposición 3.2.1.

Sea $\{Y_{t,T}\}_t$ un proceso que satisface la definición 2.3 y cumple con los supuestos S3.1-S3.6. Entonces la matriz

$$\Gamma = \left\{ \int_{[-\pi, \pi]} e^{i\lambda(r-s)} A_{r,T}^0(\lambda) \overline{A_{s,T}^0(\lambda)} d\lambda \right\}_{r,s=1,\dots,T}$$

es invertible.

Demostración.

Sea $\alpha \in \mathbb{R}^T$ tal que α es distinto del vector nulo. Probaremos que $\alpha' \Gamma \alpha > 0$. Por contradicción. Supongamos que $\alpha' \Gamma \alpha = 0$. Luego

$$\begin{aligned}
\alpha' \Gamma \alpha &= \sum_{r=1}^T \sum_{s=1}^T \alpha_r \Gamma_{r,s} \alpha_s \\
&= \sum_{r=1}^T \sum_{s=1}^T \alpha_r \alpha_s \int_{[-\pi, \pi]} e^{i\lambda(r-s)} A_{r,T}^0(\lambda) \overline{A_{s,T}^0(\lambda)} d\lambda \\
&= \int_{[-\pi, \pi]} \sum_{r=1}^T \sum_{s=1}^T \alpha_r \alpha_s e^{i\lambda(r-s)} A_{r,T}^0(\lambda) \overline{A_{s,T}^0(\lambda)} d\lambda \\
&= \int_{[-\pi, \pi]} \left| \sum_{r=1}^T e^{i\lambda r} A_{r,T}^0(\lambda) \alpha_r \right|^2 d\lambda
\end{aligned}$$

Esto implica que

$$\left| \sum_{r=1}^T e^{i\lambda r} A_{r,T}^0(\lambda) \alpha_r \right|^2 = 0$$

y por ende

$$\sum_{r=1}^T e^{i\lambda r} A_{r,T}^0(\lambda) \alpha_r = 0$$

Notamos que esta última ecuación, es una combinación lineal del conjunto $U = \{e^{i\lambda}, e^{i\lambda^2}, \dots, e^{i\lambda^T}\}$ el cual es un subconjunto de $B = \{e^{i\lambda n} : n \in \mathbb{Z}\}$ el que a su vez es una base ortonormal del espacio $L^2([-\pi, \pi])$. Por tanto el conjunto U es linealmente independiente, lo que implica que

$$A_{r,T}^0(\lambda) \alpha_r = 0$$

para todo $r = 1, \dots, T$. Pero

$$A_{r,T}^0(\lambda) = \sigma\left(\frac{r}{T}\right) \sum_{j=0}^q \theta_j\left(\frac{r}{T}\right) e^{-i\lambda j} \neq 0$$

ya que por el supuesto S3.2 $\sum_{j=0}^q \theta_j\left(\frac{r}{T}\right) e^{-i\lambda j} \neq 0$ pues $z = e^{-i\lambda}$ está en el círculo unitario, es decir $|z| = 1$. Y por otro lado el supuesto S3.3 implica que $\sigma(\cdot) > 0$

Por tanto $\alpha_r = 0$ para todo $r = 1, \dots, T$. Lo que contradice el supuesto que el vector α no es nulo. □

Proposición 5.1.1.

Sea $\{Y_{t,T}\}_t$ un proceso que satisface la definición 2.3, sea $\hat{\mu}_T$ el LSE de μ dado por

$$\hat{\mu}_T = \frac{\sum_{t=1}^T y_{t,T}}{T},$$

Entonces la varianza de $\hat{\mu}_T$ satisface que

$$TVar(\hat{\mu}_T) \sim \int_0^1 \sigma(u)^2 [1 + \theta(u)]^2 du.$$

Donde $a_T \sim b_T$ significa que $a_T/b_T \rightarrow 1$ cuando $T \rightarrow \infty$.

Demostración.

$$\begin{aligned}
Var(\hat{\mu}_T) &= \frac{1}{T^2} \sum_{t=1}^T \sum_{s=1}^T Cov(y_{t,T}, y_{s,T}) \\
&= \frac{1}{T^2} \left(\sum_{t=1}^T Cov(y_{t,T}, y_{t,T}) + 2 \sum_{t=2}^T Cov(y_{t,T}, y_{t-1,T}) \right) \\
&= \frac{1}{T^2} \left(\sum_{t=1}^T \sigma\left(\frac{t}{T}\right)^2 [1 + \theta\left(\frac{t}{T}\right)^2] + 2 \sum_{t=2}^T \sigma\left(\frac{t}{T}\right) \sigma\left(\frac{t-1}{T}\right) \theta\left(\frac{t}{T}\right) \right) \\
&= \frac{1}{T^2} \left(\sum_{t=1}^T \sigma\left(\frac{t}{T}\right)^2 [1 + \theta\left(\frac{t}{T}\right)^2] \right. \\
&\quad \left. + 2 \sum_{t=2}^T \left[\sigma\left(\frac{t}{T}\right)^2 \theta\left(\frac{t}{T}\right) - \sigma\left(\frac{t}{T}\right) \sigma'\left(\frac{t}{T}\right) \frac{1}{T} \theta\left(\frac{t}{T}\right) + \sigma\left(\frac{t}{T}\right) \theta\left(\frac{t}{T}\right) O\left(\frac{1}{T^2}\right) \right] \right) \\
&= \frac{1}{T^2} \left(\sum_{t=1}^T \sigma\left(\frac{t}{T}\right)^2 [1 + 2\theta\left(\frac{t}{T}\right) + \theta\left(\frac{t}{T}\right)^2] \right. \\
&\quad \left. - 2\sigma\left(\frac{1}{T}\right)^2 \theta\left(\frac{1}{T}\right) - 2 \sum_{t=2}^T \left[\sigma\left(\frac{t}{T}\right) \sigma'\left(\frac{t}{T}\right) \frac{1}{T} \theta\left(\frac{t}{T}\right) - \sigma\left(\frac{t}{T}\right) \theta\left(\frac{t}{T}\right) O\left(\frac{1}{T^2}\right) \right] \right) \\
&= \frac{1}{T^2} \left(\sum_{t=1}^T \sigma\left(\frac{t}{T}\right)^2 [1 + \theta\left(\frac{t}{T}\right)]^2 + \Delta_T \right)
\end{aligned}$$

Analizamos Δ_T

$$\begin{aligned}
|\Delta_T| &\leq |2\sigma\left(\frac{1}{T}\right)^2 \theta\left(\frac{1}{T}\right)| + 2 \sum_{t=1}^T |\sigma\left(\frac{t}{T}\right) \sigma'\left(\frac{t}{T}\right) \frac{1}{T} \theta\left(\frac{t}{T}\right)| + 2 \sum_{t=1}^T |\sigma\left(\frac{t}{T}\right) \theta\left(\frac{t}{T}\right) O\left(\frac{1}{T^2}\right)| \\
&\leq k_1 + k_2 + k_3 O\left(\frac{1}{T}\right) \leq k_1 + k_2 + \frac{k_4}{T}
\end{aligned}$$

Donde

$$k_1 = |2\sigma\left(\frac{1}{T}\right)^2 \theta\left(\frac{1}{T}\right)|$$

$$k_2 = \max_{u \in [0,1]} |2\sigma(u)^2 \sigma'(u) \theta(u)|$$

$$k_3 = \max_{u \in [0,1]} |2\sigma(u)^2 \theta(u)|$$

Luego

$$\frac{|\Delta_T|}{T} \xrightarrow{T \rightarrow \infty} 0$$

Por tanto

$$\begin{aligned} TVar(\hat{\mu}_T) &= \sum_{t=1}^T \sigma\left(\frac{t}{T}\right)^2 [1 + \theta\left(\frac{t}{T}\right)]^2 \frac{1}{T} + \frac{\Delta_T}{T} \\ &\xrightarrow{T \rightarrow \infty} \int_0^1 \sigma(u)^2 [1 + \theta(u)]^2 du. \end{aligned}$$

□

Proposición 5.2.1.

Sea

$$Y_{t,T} = x_1\left(\frac{t}{T}\right)\beta_1 + x_2\left(\frac{t}{T}\right)\beta_2 + \sigma\left(\frac{t}{T}\right)[\epsilon_t + \theta\left(\frac{t}{T}\right)\epsilon_{t-1}], \quad t = 1, \dots, T.$$

Tal que $x_1(\cdot), x_2(\cdot) \in C^2([0, 1])$, $\theta(\cdot) \in C^2([0, 1])$ con derivadas acotadas y $|\theta(u)| < 1$ para todo $u \in [0, 1]$, $\beta = (\beta_1, \beta_2)'$ y $\epsilon_t \sim RB(0, 1)$.

Sea $\hat{\beta}_T$ el estimador LSE de β definido por

$$\hat{\beta}_T = \left(X_T' X_T\right)^{-1} X_T' Y_T$$

Donde X_T es la matriz de diseño de la regresión dada por

$$X_T = \begin{bmatrix} x_1\left(\frac{1}{T}\right) & x_2\left(\frac{1}{T}\right) \\ x_1\left(\frac{2}{T}\right) & x_2\left(\frac{2}{T}\right) \\ \vdots & \vdots \\ x_1\left(\frac{T}{T}\right) & x_2\left(\frac{T}{T}\right) \end{bmatrix},$$

$$e Y_T = (Y_{1,T}, Y_{2,T}, \dots, Y_{T,T})'.$$

Entonces

$$TVar(\hat{\beta}_T) \rightarrow \Sigma^{-1}\Omega\Sigma^{-1}.$$

Cuando $T \rightarrow \infty$. Donde

$$\Omega = \int_0^1 \sigma(u)^2 [1 + \theta(u)]^2 \begin{bmatrix} x_1(u)^2 & x_1(u)x_2(u) \\ x_2(u)x_1(u) & x_2(u)^2 \end{bmatrix} du$$

y

$$\Sigma = \int_0^1 \begin{bmatrix} x_1(u)^2 & x_1(u)x_2(u) \\ x_2(u)x_1(u) & x_2(u)^2 \end{bmatrix} du.$$

Demostración.

El LSE de β está dado por

$$\hat{\beta}_T = \left(X_T' X_T \right)^{-1} X_T' Y_T = D_T' Y_T$$

Así tenemos que

$$\begin{aligned} Var(\hat{\beta}_T) &= Var(D_T' Y_T) \\ &= D_T' Var(Y_T) D_T \\ &= D_T' \Gamma D_T. \\ &= \left(X_T' X_T \right)^{-1} X_T' \Gamma X_T \left(X_T' X_T \right)^{-1}. \end{aligned} \tag{A.8}$$

Sea $\Gamma X_T = C_T$, Donde

$$C_T = \begin{bmatrix} c_1\left(\frac{1}{T}\right) & c_2\left(\frac{1}{T}\right) \\ c_1\left(\frac{2}{T}\right) & c_2\left(\frac{2}{T}\right) \\ \vdots & \vdots \\ c_1\left(\frac{T}{T}\right) & c_2\left(\frac{T}{T}\right) \end{bmatrix}$$

Con esto obtenemos las siguientes ecuaciones

$$c_1\left(\frac{t}{T}\right) = \tag{A.9}$$

$$\sigma\left(\frac{t}{T}\right)^2 \left[1 + \theta\left(\frac{t}{T}\right)^2\right] x_1\left(\frac{t}{T}\right) + \sigma\left(\frac{t}{T}\right)\sigma\left(\frac{t-1}{T}\right)\theta\left(\frac{t}{T}\right)x_1\left(\frac{t-1}{T}\right) + \sigma\left(\frac{t+1}{T}\right)\sigma\left(\frac{t}{T}\right)\theta\left(\frac{t+1}{T}\right)x_1\left(\frac{t+1}{T}\right)$$

$$c_2\left(\frac{t}{T}\right) = \tag{A.10}$$

$$\sigma\left(\frac{t}{T}\right)^2 \left[1 + \theta\left(\frac{t}{T}\right)^2\right] x_2\left(\frac{t}{T}\right) + \sigma\left(\frac{t}{T}\right)\sigma\left(\frac{t-1}{T}\right)\theta\left(\frac{t}{T}\right)x_2\left(\frac{t-1}{T}\right) + \sigma\left(\frac{t+1}{T}\right)\sigma\left(\frac{t}{T}\right)\theta\left(\frac{t+1}{T}\right)x_2\left(\frac{t+1}{T}\right)$$

Para $t \in \{3, \dots, T-2\}$. Tomando la ecuación (A.9) vemos lo siguiente

$$\begin{aligned} \sigma\left(\frac{t-1}{T}\right)\theta\left(\frac{t}{T}\right)x_1\left(\frac{t-1}{T}\right) &= \left[\sigma\left(\frac{t}{T}\right) - \sigma'\left(\frac{t}{T}\right)\frac{1}{T} + O\left(\frac{1}{T^2}\right)\right]\theta\left(\frac{t}{T}\right)\left[x_1\left(\frac{t}{T}\right) - x_1'\left(\frac{t}{T}\right)\frac{1}{T} + O\left(\frac{1}{T^2}\right)\right] \\ &= \sigma\left(\frac{t}{T}\right)\theta\left(\frac{t}{T}\right)x_1\left(\frac{t}{T}\right) - \sigma\left(\frac{t}{T}\right)\theta\left(\frac{t}{T}\right)x_1'\left(\frac{t}{T}\right)\frac{1}{T} - \sigma'\left(\frac{t}{T}\right)\theta\left(\frac{t}{T}\right)x_1\left(\frac{t}{T}\right)\frac{1}{T} + O\left(\frac{1}{T^2}\right) \end{aligned}$$

y

$$\begin{aligned}
& \sigma\left(\frac{t+1}{T}\right)\theta\left(\frac{t+1}{T}\right)x_1\left(\frac{t+1}{T}\right) \\
&= \left[\sigma\left(\frac{t}{T}\right) + \sigma'\left(\frac{t}{T}\right)\frac{1}{T} + O\left(\frac{1}{T^2}\right)\right] \left[\theta\left(\frac{t}{T}\right) + \theta'\left(\frac{t}{T}\right)\frac{1}{T} + O\left(\frac{1}{T^2}\right)\right] \left[x_1\left(\frac{t}{T}\right) + x_1'\left(\frac{t}{T}\right)\frac{1}{T} + O\left(\frac{1}{T^2}\right)\right] \\
&= \sigma\left(\frac{t}{T}\right)\theta\left(\frac{t}{T}\right)x_1\left(\frac{t}{T}\right) + \sigma\left(\frac{t}{T}\right)\theta\left(\frac{t}{T}\right)x_1'\left(\frac{t}{T}\right)\frac{1}{T} + \sigma\left(\frac{t}{T}\right)\theta'\left(\frac{t}{T}\right)x_1\left(\frac{t}{T}\right)\frac{1}{T} + \sigma'\left(\frac{t}{T}\right)\theta\left(\frac{t}{T}\right)x_1\left(\frac{t}{T}\right)\frac{1}{T} + O\left(\frac{1}{T^2}\right)
\end{aligned}$$

Luego

$$\begin{aligned}
& \sigma\left(\frac{t-1}{T}\right)\theta\left(\frac{t}{T}\right)x_1\left(\frac{t-1}{T}\right) + \sigma\left(\frac{t+1}{T}\right)\theta\left(\frac{t+1}{T}\right)x_1\left(\frac{t+1}{T}\right) \\
&= 2\sigma\left(\frac{t}{T}\right)\theta\left(\frac{t}{T}\right)x_1\left(\frac{t}{T}\right) + \sigma\left(\frac{t}{T}\right)\theta'\left(\frac{t}{T}\right)x_1\left(\frac{t}{T}\right)\frac{1}{T} + O\left(\frac{1}{T^2}\right)
\end{aligned}$$

Usando lo anterior en la ecuación (A.9) vemos que

$$\begin{aligned}
& \sigma\left(\frac{t}{T}\right)^2 \left[1 + \theta\left(\frac{t}{T}\right)^2\right] x_1\left(\frac{t}{T}\right) + \sigma\left(\frac{t}{T}\right)\sigma\left(\frac{t-1}{T}\right)\theta\left(\frac{t}{T}\right)x_1\left(\frac{t-1}{T}\right) + \sigma\left(\frac{t+1}{T}\right)\sigma\left(\frac{t}{T}\right)\theta\left(\frac{t+1}{T}\right)x_1\left(\frac{t+1}{T}\right) = \\
& \sigma\left(\frac{t}{T}\right)^2 \left[1 + \theta\left(\frac{t}{T}\right)^2\right] x_1\left(\frac{t}{T}\right) + 2\sigma\left(\frac{t}{T}\right)^2\theta\left(\frac{t}{T}\right)x_1\left(\frac{t}{T}\right) + \sigma\left(\frac{t}{T}\right)^2\theta'\left(\frac{t}{T}\right)x_1\left(\frac{t}{T}\right)\frac{1}{T} + O\left(\frac{1}{T^2}\right) = \\
& \sigma\left(\frac{t}{T}\right)^2 \left[1 + \theta\left(\frac{t}{T}\right)\right]^2 x_1\left(\frac{t}{T}\right) + \sigma\left(\frac{t}{T}\right)^2\theta'\left(\frac{t}{T}\right)x_1\left(\frac{t}{T}\right)\frac{1}{T} + O\left(\frac{1}{T^2}\right)
\end{aligned}$$

Por tanto

$$\sigma\left(\frac{t}{T}\right)^2 \left(\left[1 + \theta\left(\frac{t}{T}\right)\right]^2 + \theta'\left(\frac{t}{T}\right)\frac{1}{T} \right) x_1\left(\frac{t}{T}\right) + O\left(\frac{1}{T^2}\right) = c_1\left(\frac{t}{T}\right) \quad (\text{A.11})$$

Analogamente, tomando la ecuación (A.10) tenemos que

$$\sigma\left(\frac{t}{T}\right)^2 \left(\left[1 + \theta\left(\frac{t}{T}\right)\right]^2 + \theta'\left(\frac{t}{T}\right)\frac{1}{T} \right) x_2\left(\frac{t}{T}\right) + O\left(\frac{1}{T^2}\right) = c_2\left(\frac{t}{T}\right) \quad (\text{A.12})$$

Luego

$$X_T' \Gamma X_T = \begin{bmatrix} a & b \\ b & c \end{bmatrix}$$

Ahora

$$\begin{aligned} a &= \sum_{t=1}^T \sigma\left(\frac{t}{T}\right)^2 \left(\left[1 + \theta\left(\frac{t}{T}\right)\right]^2 + \theta'\left(\frac{t}{T}\right)\frac{1}{T} \right) x_1\left(\frac{t}{T}\right)^2 \frac{1}{T} + O\left(\frac{1}{T}\right) \\ &= \sum_{t=1}^T \sigma\left(\frac{t}{T}\right)^2 \left[1 + \theta\left(\frac{t}{T}\right)\right]^2 x_1\left(\frac{t}{T}\right)^2 \frac{1}{T} + \sum_{t=1}^T \sigma\left(\frac{t}{T}\right)^2 \theta'\left(\frac{t}{T}\right) x_1\left(\frac{t}{T}\right)^2 \frac{1}{T^2} + O\left(\frac{1}{T}\right) \\ &= \sum_{t=1}^T \sigma\left(\frac{t}{T}\right)^2 \left[1 + \theta\left(\frac{t}{T}\right)\right]^2 x_1\left(\frac{t}{T}\right)^2 \frac{1}{T} + O\left(\frac{1}{T}\right) \\ &\xrightarrow{T \rightarrow \infty} \int_0^1 \sigma(u)^2 [1 + \theta(u)]^2 x_1(u)^2 du \end{aligned}$$

Análogamente

$$\begin{aligned} b &= \sum_{t=1}^T \sigma\left(\frac{t}{T}\right)^2 \left(\left[1 + \theta\left(\frac{t}{T}\right)\right]^2 + \theta'\left(\frac{t}{T}\right)\frac{1}{T} \right) x_1\left(\frac{t}{T}\right) x_2\left(\frac{t}{T}\right) \frac{1}{T} + O\left(\frac{1}{T}\right) \\ &\xrightarrow{T \rightarrow \infty} \int_0^1 \sigma(u)^2 [1 + \theta(u)]^2 x_1(u) x_2(u) du \end{aligned}$$

$$\begin{aligned}
c &= \sum_{t=1}^T \sigma\left(\frac{t}{T}\right)^2 \left(\left[1 + \theta\left(\frac{t}{T}\right)\right]^2 + \theta'\left(\frac{t}{T}\right)\frac{1}{T} \right) x_2\left(\frac{t}{T}\right)^2 \frac{1}{T} + O\left(\frac{1}{T}\right) \\
&\xrightarrow{T \rightarrow \infty} \int_0^1 \sigma(u)^2 [1 + \theta(u)]^2 x_2(u)^2 du
\end{aligned}$$

Así tenemos que

$$\frac{1}{T} X'_T \Gamma X_T \rightarrow \int_0^1 \sigma(u)^2 [1 + \theta(u)]^2 \begin{bmatrix} x_1(u)^2 & x_1(u)x_2(u) \\ x_2(u)x_1(u) & x_2(u)^2 \end{bmatrix} du = \Omega.$$

Cuando $T \rightarrow \infty$. De igual forma tenemos

$$\begin{aligned}
\frac{1}{T} X'_T X_T &= \begin{bmatrix} \sum_{t=1}^T x_1\left(\frac{t}{T}\right)^2 \frac{1}{T} & \sum_{t=1}^T x_1\left(\frac{t}{T}\right)x_2\left(\frac{t}{T}\right)\frac{1}{T} \\ \sum_{t=1}^T x_1\left(\frac{t}{T}\right)x_2\left(\frac{t}{T}\right)\frac{1}{T} & \sum_{t=1}^T x_2\left(\frac{t}{T}\right)^2 \frac{1}{T} \end{bmatrix} \\
&\rightarrow \int_0^1 \begin{bmatrix} x_1(u)^2 & x_1(u)x_2(u) \\ x_2(u)x_1(u) & x_2(u)^2 \end{bmatrix} du = \Sigma.
\end{aligned}$$

Cuando $T \rightarrow \infty$. Por tanto

$$TVar(\hat{\beta}_T) \rightarrow \Sigma^{-1} \Omega \Sigma^{-1}.$$

Cuando $T \rightarrow \infty$. □

Bibliografía

- Adenstedt, R. K. (1974). On large-sample estimation for the mean of a stationary random sequence. *Ann. Statist.*, 2(6):1095–1107. 4
- Beran, J. (2009). On parameter estimation for locally stationary long-memory processes. *J. Statist. Plann. Inference*, 139(3):900–915. 3
- Brillinger, D. (1981). *Time Series: Data Analysis and Theory*. Holden Day, San Francisco. Society for Industrial and Applied Mathematics.
- Brockwell, P. and Davis, R. (1991). *Time Series: Theory and Methods: Theory and Methods*. Springer series in statistics. Springer-Verlag. 10
- Dahlhaus, R. (1996a). Maximum likelihood estimation and model selection for locally stationary processes. *J. Nonparametr. Statist.*, 6(2-3):171–191. 3, 5, 14
- Dahlhaus, R. (1996b). On the Kullback-Leibler information divergence of locally stationary processes. *Stochastic Process. Appl.*, 62(1):139–168. 3, 5, 7, 9, 17, 94

- Dahlhaus, R. (1997). Fitting time series models to nonstationary processes. *Ann. Statist.*, 25(1):1–37. 2, 3, 5, 91, 93, 94
- Dahlhaus, R. (2000). A likelihood approximation for locally stationary processes. *Ann. Statist.*, 28(6):1762–1794. 3
- Dahlhaus, R. and Giraitis, L. (1998). On the optimal segment length for parameter estimates for locally stationary time series. *Journal of Time Series Analysis*, 19(6):629–655. 3
- Dahlhaus, R. and Polonik, W. (2006). Nonparametric quasi-maximum likelihood estimation for Gaussian locally stationary processes. *Ann. Statist.*, 34(6):2790–2824. 3
- Dahlhaus, R. and Polonik, W. (2009). Empirical spectral processes for locally stationary time series. *Bernoulli*, 15(1):1–39.
- Dahlhaus, R., Rao, S. S., et al. (2006). Statistical inference for time-varying arch processes. *The Annals of Statistics*, 34(3):1075–1114.
- Ferreira, G., Olea, R., and Palma, W. (2013). Statistical analysis of locally stationary processes. *Chilean Journal of Statistics*, 4(2):133–149. 10, 14
- Gastinel, N. (1966). *Analyse numérique linéaire*. Number 9. Hermann. 21

- Genton, M. G. and Perrin, O. (2004). On a time deformation reducing nonstationary stochastic processes to local stationarity. *J. Appl. Probab.*, 41(1):236–249. 3
- Gradshteyn, I. S. and Ryzhik, I. (2000). Table of integrals, series, and products. translated from the russian. translation edited and with a preface by alan jeffrey and daniel zwillinger. 25, 26
- Granger, C. W. and Joyeux, R. (1980). An introduction to long-memory time series models and fractional differencing. *Journal of time series analysis*, 1(1):15–29.
- Grenander, U. and Rosenblatt, M. (1957). *Statistical Analysis of Stationary Time Series*. Wiley publication in mathematical statistics. Wiley. 4, 68
- Holmes R. L., R. K. Adams, V. C. K. and Earle, C. J. (1985). Juniperus occidentalis hook tree ring data, idaho, usa. world data center for paleoclimatology and noaa paleoclimatology program. 129
- Hosking, J. R. (1981). Fractional differencing. *Biometrika*, 68(1):165–176.
- Jammalamadaka, S. R., Rao, T. S., and Terdik, G. (2006). Higher order cumulants of random vectors and applications to statistical inference and time series. *Sankhyā: The Indian Journal of Statistics*, pages 326–356. 149
- Jensen, M. J. and Whitcher, B. (2000). Time-varying long-memory in volatility: Detection and estimation with wavelets. 3

- Magnus, J. and Neudecker, H. (1999). *Matrix Differential Calculus with Applications in Statistics and Econometrics*. Wiley Series in Probability and Statistics: Texts and References Section. Wiley. 140
- Palma, W. (2007). *Long-Memory Time Series: Theory and Methods*. Wiley Series in Probability and Statistics. Wiley. 4
- Palma, W. (2010). On the sample mean of locally stationary long-memory processes. *Journal of Statistical Planning and Inference*, 140(12):3764–3774. 15, 16
- Palma, W. and Olea, R. (2010). An efficient estimator for locally stationary Gaussian long-memory processes. *Ann. Statist.*, 38(5):2958–2997. 3
- Palma, W., Olea, R., and Ferreira, G. (2013). Estimation and forecasting of locally stationary processes. *Journal of Forecasting*, 32(1):86–96. 10, 14
- Priestley, M. B. (1965). Evolutionary spectra and non-stationary processes. *Journal of the Royal Statistical Society. Series B (Methodological)*, pages 204–237. 3
- Silverman, R. et al. (1957). Locally stationary random processes. *Information Theory, IRE Transactions on*, 3(3):182–187. 3
- Tan, M., Liu, T., Hou, J., Qin, X., Zhang, H., and Li, T. (2003). Cyclic rapid warming on centennial-scale revealed by a 2650-year stalagmite record of warm season temperature. *Geophysical Research Letters*, 30(12). 129

Whittle, P. (1953). Estimation and information in stationary time series. *Arkiv för matematik*, 2(5):423–434. 91

Zygmund, A. (1959). Trigonometrical series. vol. 2. *Cambridge, England*.