



Econometría II

**Modelización del número de pasajeros de líneas aéreas,
desde enero de 1949 hasta diciembre de 1960**

Miguel Jerez y Sonia Sotoca

Universidad Complutense de Madrid

Marzo 2002

Índice

Introducción

Identificación

- Tasa log intermensual
- Cambio en la tasa log interanual

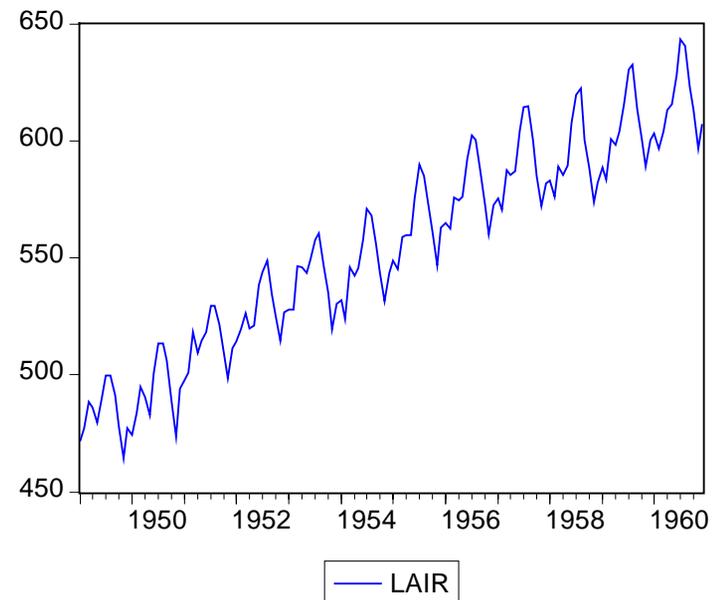
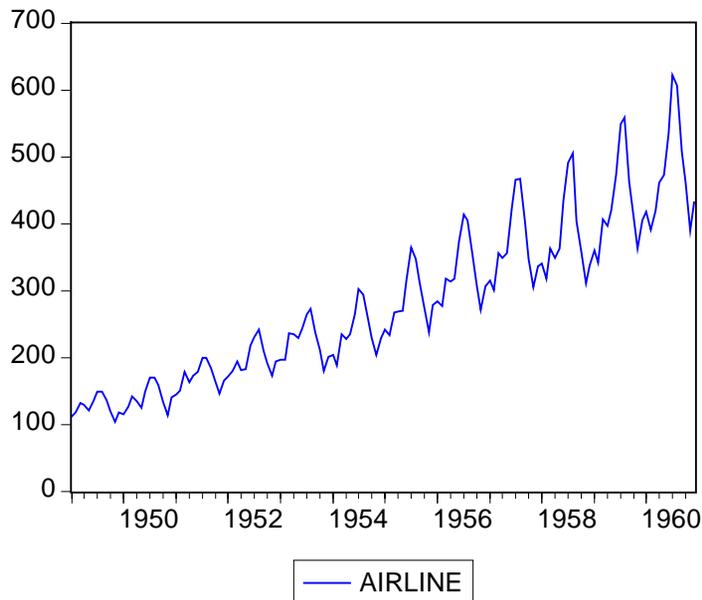
Estimación y diagnóstico

Modelo alternativo

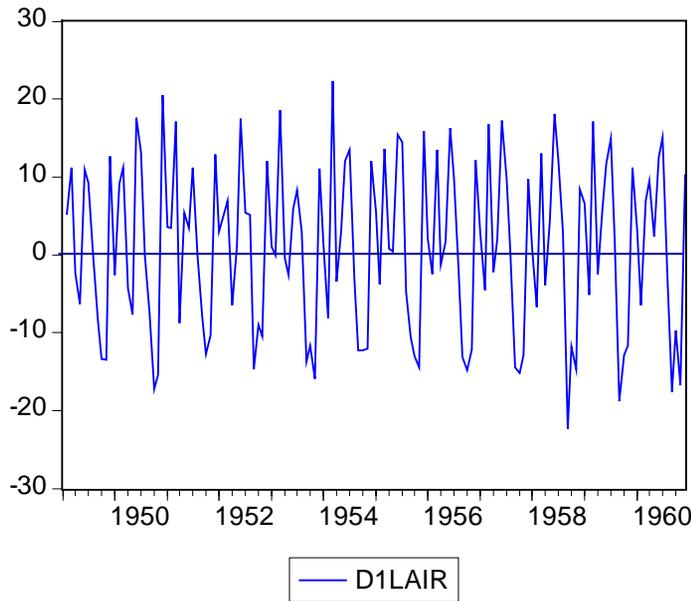
Introducción

Descripción de los datos:

- Número de pasajeros de líneas aéreas, en miles de personas, desde enero de 1949 hasta diciembre de 1960 (144 observaciones).
- Los datos muestran: a) tendencia, b) un ciclo estacional y c) una variabilidad proporcional a la media.
- Esta última característica desaparece al transformar logarítmicamente ($\log x$ 100) los datos.



Identificación (I): Tasa log intermensual



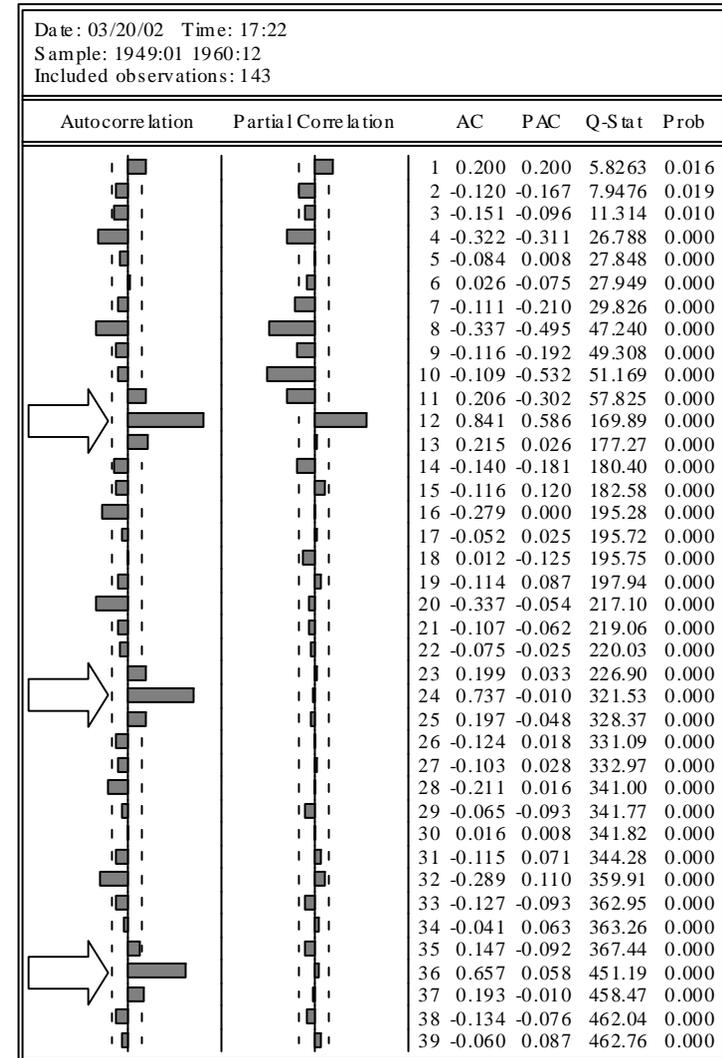
La tasa log intermensual muestra:

- Una pauta periódica en su perfil.
- Autocorrelaciones importantes y persistentes en los retardos múltiples de doce.

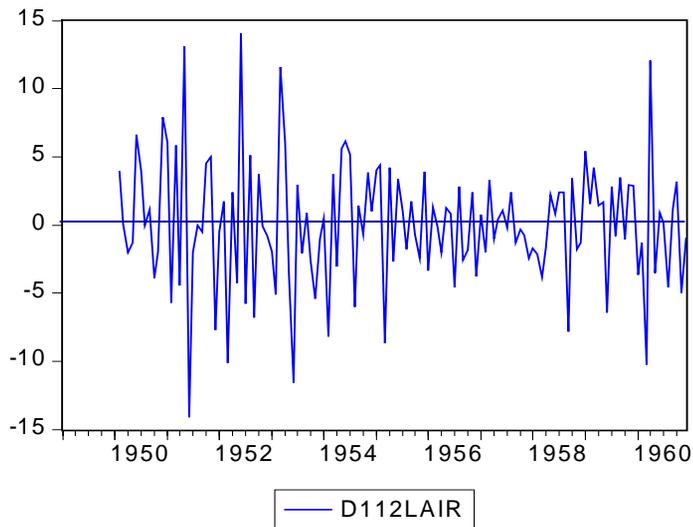
Consecuentemente, se pasa a analizar:

$$z_t = \nabla \nabla_{12} \log(P_t) \times 100$$

Correlogram of D1LAIR

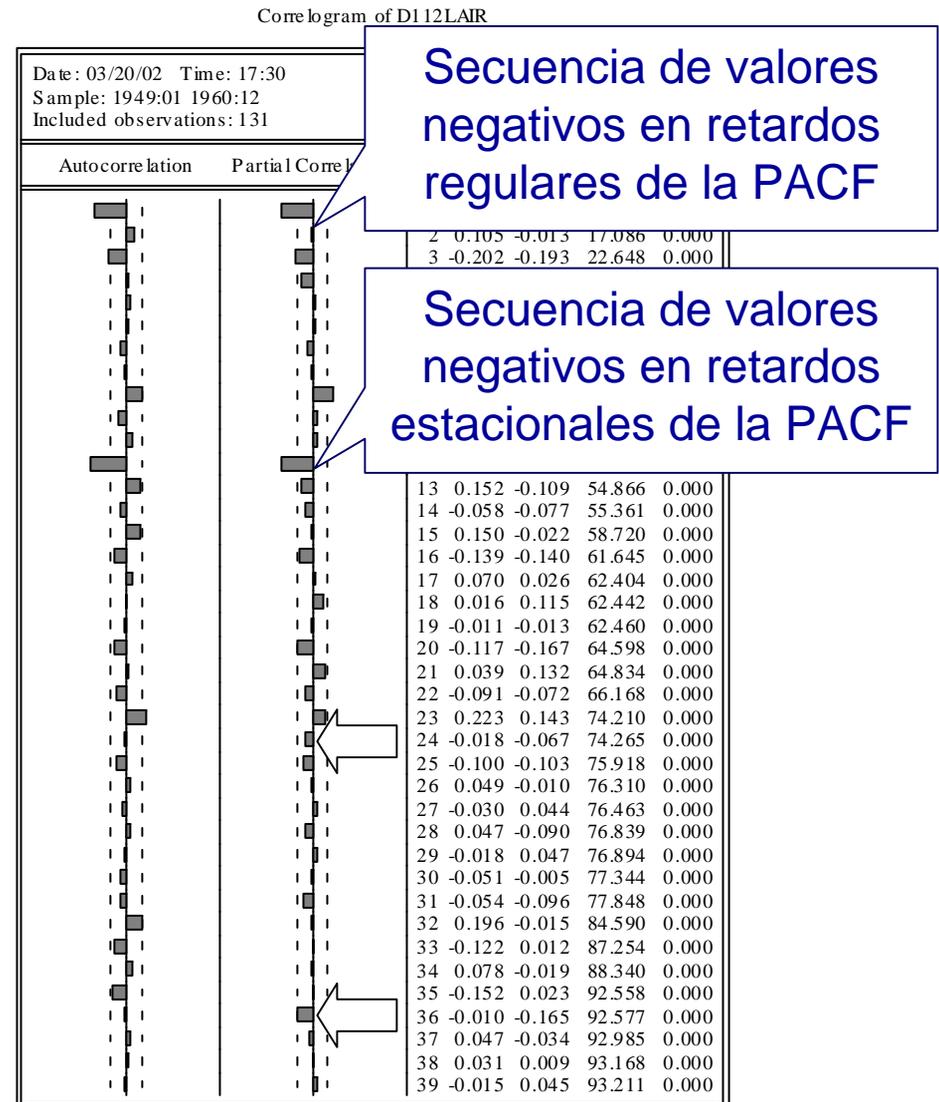


Identificación (II): Cambio en la tasa log interanual



Esta transformación de datos puede interpretarse como “cambio en el mes de la tasa log interanual”. Se observa:

- Posible heterocedasticidad.
- Autocorrelaciones compatibles con una estructura $IMA(1,1) \times IMA(1,1)_{12}$



Estimación y diagnóstico (I)

Dependent Variable: DLOG(AIRLINE,1,12)*100				
Method: Least Squares				
Date: 03/14/02 Time: 11:53				
Sample (adjusted): 1950:02 1960:12				
Included observations: 131 after adjusting endpoints				
Convergence achieved after 12 iterations				
Backcast: 1949:01 1950:01				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(1)	-0.404858	0.080238	-5.045740	0.0000
SMA(12)	-0.631571	0.069842	-9.042835	0.0000
R-squared	0.371098	Mean dependent var	0.029088	
Adjusted R-squared	0.366223	S.D. dependent var	4.584829	
S.E. of regression	3.649988	Akaike info criterion	5.442474	
Sum squared resid	1718.591	Schwarz criterion	5.486370	
Log likelihood	-354.4821	Durbin-Watson stat	1.933721	
Inverted MA Roots	.96	.83 -.48i	.83+.48i	.48+.83i
	.48 -.83i	.40	.00+.96i	-.00 -.96i
	-.48+.83i	-.48 -.83i	-.83 -.48i	-.83+.48i
	-.96			

El modelo estimado es:

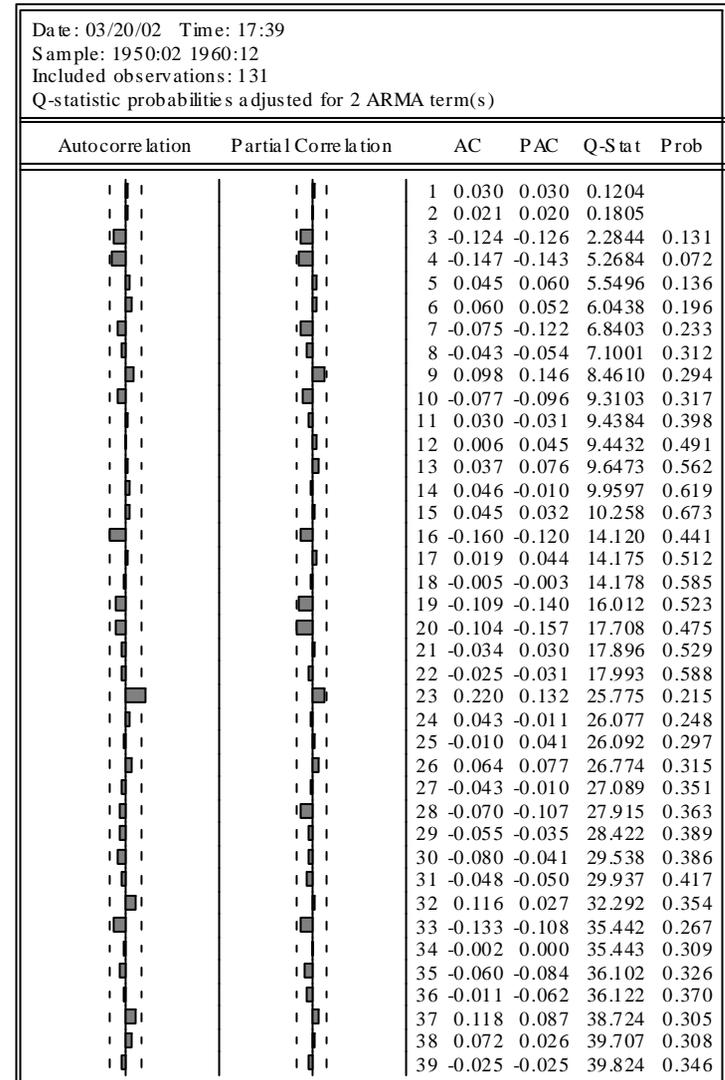
$$\nabla \nabla_{12} \log(P_t) \times 100 = (1 - .40B)(1 - .63B^{12}) \hat{a}_t$$

(.08) (.07)

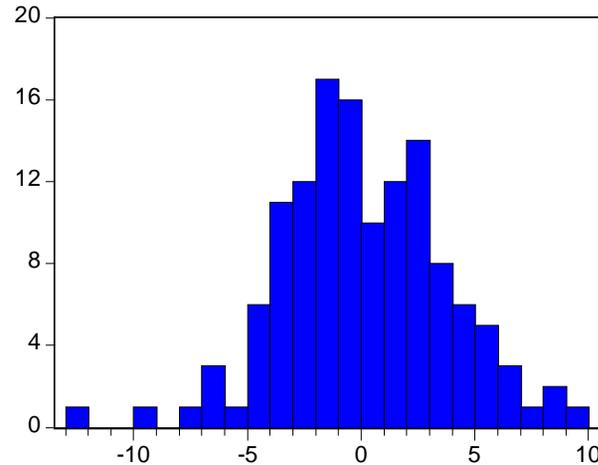
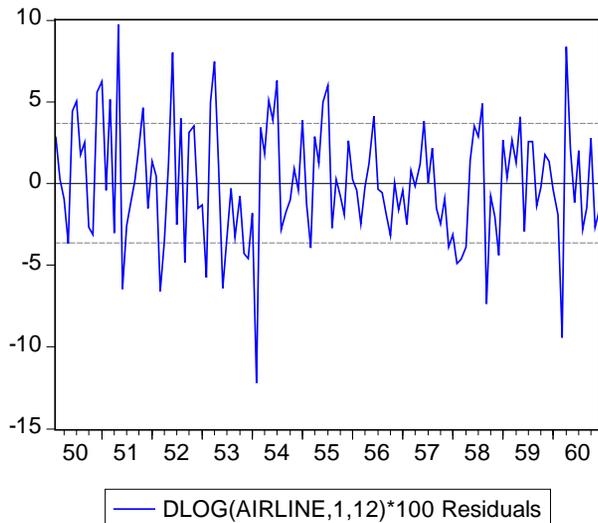
$$\hat{\sigma}_a = 3.65$$

En cuanto a la diagnosis, todos los coeficientes son significativos y las ACFs residuales son compatibles con una estructura de ruido blanco

Correlogram of Residuals



Estimación y diagnóstico (II)



Series: Residuals	
Sample 1950:02 1960:12	
Observations 131	
Mean	0.034246
Median	-0.296196
Maximum	9.740810
Minimum	-12.20319
Std. Dev.	3.635760
Skewness	-0.082867
Kurtosis	3.475030
Jarque-Bera	1.381619
Probability	0.501170

Asimismo se observa:

- Hay algunos residuos atípicamente elevados.
- El contraste de Jarque Bera no rechaza normalidad.

Consecuentemente, el modelo univariante resulta válido en principio. Sin embargo, puede mejorarse añadiendo variables exógenas como:

- Número de días laborables (L_t) y festivos (F_t) en cada mes de la muestra.
- Mes en que ocurre la Semana Santa (S_t).

ya que estos factores pueden perturbar la pauta estacional y explicar parte de los residuos atípicos.

Modelo alternativo (I): Estimación

Dependent Variable: DLOG(AIRLINE,1,12)*100				
Method: Least Squares				
Date: 03/20/02 Time: 18:41				
Sample (adjusted): 1950:02 1960:12				
Included observations: 131 after adjusting endpoints				
Convergence achieved after 13 iterations				
Backcast: 1949:01 1950:01				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(DIAS_LAB,1,12)	3.879607	1.470812	2.637732	0.0094
D(DIAS_FEST,1,12)	4.816347	1.493290	3.225326	0.0016
D(EASTER,1,12)	2.703436	1.020639	2.648768	0.0091
MA(1)	-0.214428	0.087400	-2.453407	0.0155
SMA(12)	-0.606711	0.073008	-8.310191	0.0000
R-squared	0.490330	Mean dependent var		0.029088
Adjusted R-squared	0.474150	S.D. dependent var		4.584829
S.E. of regression	3.324712	Akaike info criterion		5.278064
Sum squared resid	1392.768	Schwarz criterion		5.387804
Log likelihood	-340.7132	Durbin-Watson stat		1.919635
Inverted MA Roots	.96	.83 -.48i	.83+.48i	.48+.83i
	.48 -.83i	.21	.00+.96i	-.00 -.96i
	-.48+.83i	-.48 -.83i	-.83 -.48i	-.83+.48i
	-.96			

El modelo resultante es una regresión con perturbaciones autocorreladas.

Los resultados de la estimación indican que:

- Los coeficientes de las nuevas variables resultan significativos.
- El ajuste ha mejorado. Esta mejora se traduce en: una reducción de a) la desviación típica residual y b) los criterios de información (AIC SBC), así como c) un aumento del R^2 .

En la forma utilizada para estimar, el modelo puede escribirse como:

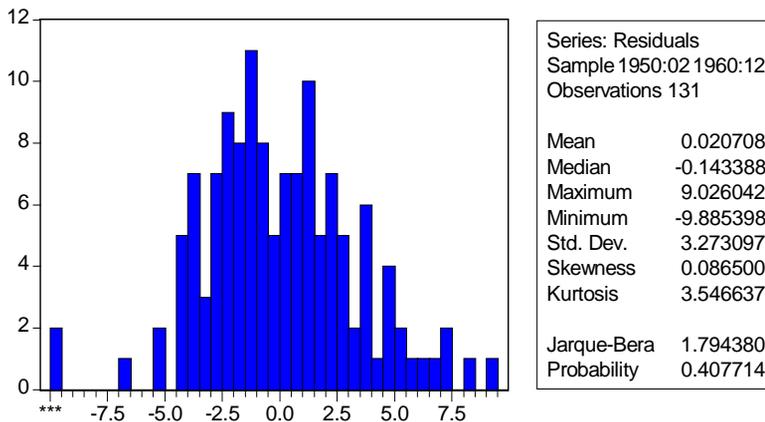
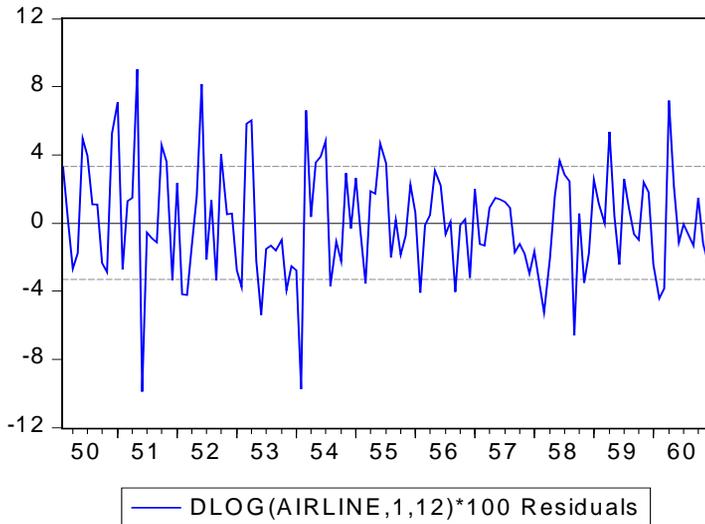
$$\nabla \nabla_{12} \log(P_t) \times 100 = \underset{(1.47)}{3.88} \nabla \nabla_{12} L_t + \underset{(1.49)}{4.82} \nabla \nabla_{12} F_t + \underset{(1.02)}{2.70} \nabla \nabla_{12} S_t + \underset{(1.09)}{(1 - .21B)(1 - .61B^{12})} \hat{a}_t$$

$$\hat{\sigma}_a = 3.32$$

Los diagnósticos residuales no muestran ningún síntoma de mala especificación.

Modelo alternativo (II): Diagnosis residual

Correlogram of Residuals



Date: 04/08/02 Time: 11:18
 Sample: 1950:02 1960:12
 Included observations: 131
 Q-statistic probabilities adjusted for 2 ARMA term(s)

	Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
1	0.034	0.034	0.1587			
2	-0.104	-0.106	1.6326			
3	-0.161	-0.156	5.1793	0.023		
4	-0.073	-0.077	5.9028	0.052		
5	-0.003	-0.034	5.9040	0.116		
6	0.086	0.048	6.9467	0.139		
7	-0.030	-0.062	7.0759	0.215		
8	-0.020	-0.017	7.1322	0.309		
9	-0.001	0.008	7.1323	0.415		
10	0.031	0.023	7.2674	0.508		
11	-0.015	-0.025	7.3021	0.606		
12	-0.046	-0.050	7.6166	0.666		
13	0.062	0.078	8.1893	0.696		
14	-0.015	-0.030	8.2225	0.768		
15	0.065	0.065	8.8522	0.784		
16	-0.100	-0.104	10.368	0.735		
17	0.012	0.041	10.391	0.794		
18	0.014	0.016	10.419	0.844		
19	-0.085	-0.126	11.548	0.827		
20	-0.185	-0.191	16.936	0.528		
21	0.023	0.002	17.018	0.589		
22	0.000	-0.050	17.018	0.652		
23	0.163	0.086	21.309	0.440		
24	0.143	0.114	24.644	0.314		
25	-0.062	-0.036	25.277	0.336		
26	0.021	0.125	25.353	0.387		
27	0.025	0.063	25.457	0.437		
28	-0.089	-0.103	26.784	0.421		
29	-0.072	-0.044	27.659	0.429		
30	-0.064	-0.089	28.357	0.446		
31	-0.007	-0.033	28.365	0.498		
32	0.102	0.043	30.191	0.456		
33	-0.117	-0.178	32.629	0.387		
34	0.014	0.040	32.667	0.434		
35	-0.118	-0.114	35.195	0.365		
36	0.051	-0.029	35.663	0.390		
37	0.092	0.068	37.223	0.367		
38	0.072	0.025	38.197	0.370		
39	0.016	0.030	38.247	0.413		

Modelo alternativo (III): Interpretación

La formulación anterior es conveniente para estimar. Para otros usos, resulta más clara la expresión equivalente:

$$\log(P_t) \times 100 = 3.88 L_t + 4.82 F_t + 2.70 S_t + \frac{(1 - .21B)(1 - .61B^{12})}{(1 - B)(1 - B^{12})} \hat{a}_t$$

En esta notación, los coeficientes de las variables exógenas tienen un significado claro como *semi-elasticidades*:

- si un mes tiene un día laborable más que otro, cabe esperar que el número de pasajeros sea un 3.88% superior
- si un mes tiene un día festivo más que otro, cabe esperar que el número de pasajeros sea un 4.82% superior
- la Semana Santa produce un aumento estimado del 2.7% en el número de pasajeros en comparación con un mes sin Semana Santa.

Las variables exógenas que hemos utilizado en este ejemplo son un ejemplo de lo que en Econometría se conoce como “efectos calendario”. Estos efectos son muy importantes ya que, además de afectar a muchas variables económicas (típicamente las ligadas al calendario laboral o a los hábitos de consumo, como producción o ventas) tienen la ventaja de resultar exactamente predecibles.