

# PROYECCION DE LA TASA DE DESEMPLEO A TRAVES DE UN MODELO ESTOCASTICO\*

Hermann Von Gersdorff

## EXTRACTO

El trabajo examina la posibilidad de aplicar técnicas de series de tiempo, como el análisis espectral y las autocorrelogramas, para identificar un modelo satisfactorio de la tasa de desempleo en una economía como la chilena que sólo tiene series estacionarias relativamente cortas. El resultado es que es posible obtener un modelo que haga buenas predicciones y que no es conveniente ampliar la base de datos a costa de incluir datos que correspondan a otro proceso estocástico.

## ABSTRACT

The paper tries to use time series analysis applying frequency and time domain techniques to model the unemployment rate, in an economy in which it is only possible to get relatively short stationary time series. The result is that it is possible to get a model that gives good predictions and that it does not seem to be a good solution to lengthen the time series by including additional data, that probably doesn't belong to the same stochastic process under modeling

\*Agradezco los comentarios y sugerencias de Manuel Bengolea y Luis Riveros, los errores que existan son como de costumbre únicamente de mi responsabilidad. El autor es profesor e investigador del Departamento de Economía de la Facultad de Ciencias Económicas y Administrativas.

## PROYECCION DE LA TASA DE DESEMPLEO A TRAVES DE UN MODELO ESTOCASTICO\*

Hermann Von Gersdorff

Una de las variables macroeconómicas que goza de mayor interés es la tasa de desempleo. Justamente debido a este interés, es que existe una polémica respecto a cuál es la mejor medida de la tasa de desempleo. Pese a que no hay una demostración de su superioridad, las cifras de desempleo para el Gran Santiago, publicadas por el Departamento de Economía de la Universidad de Chile, son las que gozan de más prestigio en el ambiente académico. Debido a que estas cifras parecen representar la mejor medida de desempleo y a que su periodicidad trimestral representa un número de datos suficientemente grande se decidió trabajar con esta tasa de desempleo. Otra razón para proyectar esta tasa de desempleo fuera del natural interés para conocer la evolución futura de ésta, radica en el hecho de que existe cierto rezago en la publicación de las cifras de la Universidad de Chile, lo que hace aún mayor la necesidad en el trabajo académico de disponer de una buena estimación de la próxima tasa de desempleo. Como esta variable va a ser proyectada para ser utilizada en otros trabajos, lo ideal es que la proyección no se base en un modelo determinado. La técnica que cumple este requisito y que, además, es capaz de proveer buenas predicciones de corto plazo son los modelos de series de tiempo, que serán los utilizados para proyectar la tasa de desempleo en el Gran Santiago, provista por la Universidad de Chile.

Al examinar visualmente el gráfico de la tasa de desempleo con los datos de junio de 1960 a junio de 1984, se aprecian períodos de tiempo de comportamiento diferente. Cada uno de estos períodos analizados independientemente parece estacionario, pero el conjunto no da una serie estacionaria. Los tres períodos estacionarios parecen ser de marzo de 1960 a septiembre de 1970, de diciembre de 1970 a diciembre de 1973 o marzo de 1974 y el último parte en junio de 1974 (anexo 1).

\**Estudios de Economía*, Segundo semestre, 1984. Publicación N° 129 del Departamento de Economía de la Universidad de Chile.

Estas observaciones se ven reforzadas al examinar el análisis espectral de la serie completa y la del período que se inicia en junio de 1974.<sup>1</sup> (Anexos 2 y 3.) Del espectro de los datos vemos que en ambas series existe una estacionalidad anual, es decir, de cuatro trimestres o períodos. La teoría nos dice que, en el caso de un ciclo determinístico como la estacionalidad, la potencia de la frecuencia debería aumentar proporcionalmente con el número de datos de la muestra.<sup>2</sup> En este caso, la potencia de la serie más corta no cambia, lo que significa que el proceso estacional es diferente para el período de junio de 1974 en adelante porque cambió la varianza de la estacionalidad.<sup>3</sup> El otro período interesante es el de dos trimestres que corresponde a la frecuencia más rápida. Aquí nuevamente la potencia de la serie más corta es parecida a la de la serie más larga, lo que está indicando que la varianza del error del proceso de la serie completa está determinada por la última parte de la serie.

Debido a que se confirma nuestra impresión de que el último período responde a un proceso diferente, conviene comparar los espectros de este período, con el período junio de 1960 a marzo de 1974 (anexo 3). Esta comparación nos confirma la información visual del gráfico de los datos, en que la amplitud de los ciclos es mucho menor en el período 60-70; en el espectro se manifiesta en una potencia mucho menor de las frecuencias relevantes durante este período. Un elemento común, en ambos períodos, está en los ciclos que presenta el espectro. Para la serie de 60-74 se ve un ciclo con una potencia máxima en la periodicidad de 18,6 trimestres, pero la longitud del ciclo puede variar entre 9 y 56 trimestres; en la serie 74-80 este ciclo alcanza su mayor potencia para una periodicidad de 13,3 trimestres y puede ser de 10 a 20 trimestres, es decir, el ciclo ahora es más definido al reducirse la varianza en la periodicidad. El ciclo estacional anual alcanza en ambas series su mayor potencia en un período de cuatro trimestres, pero es mucho más nítido y más claro de que se trata de un proceso determinístico para la serie 74-84, debido a la mayor potencia del período y principalmente por la velocidad con que cae la potencia para los períodos adyacentes.

El resto de las frecuencias parece corresponder a ruidos blancos, a excepción del período de dos trimestres. Esta frecuencia que es la más rápida se destaca en ambas series, pero en la serie 74-84, la potencia de esta frecuencia es mayor, lo que nos indica que la varianza del error para esta serie es mucho mayor.

<sup>1</sup> Pero a que las series son demasiado cortas para *testear* en forma relevante las diferencias entre las principales frecuencias; Granger y Newbold (1977) recomiendan en estos casos comparar la forma general del espectro.

<sup>2</sup> J.M. Gottman, *Time-Series Analysis*, p. 214.

<sup>3</sup> L. Riveros, *Desestacionalización de las series de desocupación. Métodos alternativos. Estudio especial*, Taller de Coyuntura, 1er semestre de 1980.

Pese a las diferencias que existen entre ambas series, según el espectro ambas debieran responder a un proceso generado por lo menos en parte por un AR(2) o un AR(4) con una estacionalidad de un año. Aunque hay que indicar que con el número de datos disponibles es bastante especulativo tratar de reconocer un proceso AR(4) del espectro de los datos.

Un método alternativo de comprobar la estacionalidad de una serie es dividiendo la serie en varias partes y comparar las medias, varianzas y covarianzas.<sup>4</sup> Al hacer esta comparación para las dos series que hemos utilizado, obtenemos:

	Junio 1960 marzo 1974	Junio 1974-- junio 1984
Media	5,73	15,37
Varianza	1,73	19,23
Coefficiente de variación	0,23	0,29

La diferencia de medias y varianzas es significativa lo que permite decir inmediatamente que la serie total no es estacionaria en estas variables. Las covarianzas de ambos periodos son por supuesto también muy diferentes (anexos 4 y 5), pero pese a ser diferentes estas covarianzas se comportan en forma muy parecida, por lo que el correlograma de ambas series tiene una forma similar. La diferencia en las autocorrelaciones tampoco es muy grande. Además, una medida relativa de la dispersión de los datos -- como el coeficiente de variación -- tampoco muestra una diferencia muy grande.

Considerando estos dos últimos factores, pese a que todo indica que la serie completa no es estacionaria ni parece probable convertirla en estacionaria, se intentará, en base a transformaciones y diferenciaciones de los datos, construir una serie estacionaria, para así disponer de una base de datos lo más amplia posible.

Al tomar una primera diferencia con un rezago de un período se obtuvo un proceso cuyo autocorrelograma parecía estacionario. Incluso, sorpresivamente, esta diferenciación resultó en que apareció cierto grado de independencia entre los datos. Esto significa que después de tener la media del proceso queda relativamente poca información que extraer de los datos. En vista de esto se ignoró el cambio en la varianza y se procedió a identificar el proceso. El mejor modelo que se obtuvo fue un ARIMA estacional de la forma  $(0,1,1) \times (1,0,1)^4$ , con residuos que con un 64 por ciento de probabilidad eran independientes y con parámetros muy significativos, pero que no cum-

<sup>4</sup>J.M. Gollman, *Time Series Analysis*, p. 63.

plen las condiciones para un modelo estacionario. El problema de haber ignorado el hecho de que la varianza fue cambiando a lo largo de la serie se ve claro al observar los valores estimados en los períodos finales, en los que los residuos se vuelven muy grandes, ya que el modelo no puede considerar completamente este cambio de varianza.

Una transformación que se usa habitualmente para lograr estacionariedad de media y varianza es tomar el logaritmo natural de la variable y luego tomar la primera diferencia.<sup>5</sup> Es decir, modelar la tasa de variación de la tasa de desempleo. Al hacer esto, obtenemos que la tasa de desempleo transformada de esta manera es casi una variable aleatoria. Este resultado se desprende del autocorrelograma, el cual indica que con una alta probabilidad se trata de un ruido blanco. Esto nos deja con muy poco campo para identificar y estimar un buen modelo para el proceso, sobre todo porque en estos casos la mejor predicción es la media de la serie. Para esta serie en particular, en que la media es muy pequeña con una desviación estándar muy alta, la mejor predicción para el próximo período sería la tasa de desempleo de este período.

Debido a los problema de estacionariedad al utilizar todos los datos disponibles se hace necesario correr el riesgo de utilizar una muestra pequeña. Los principales problemas de una muestra pequeña están en que el autocorrelograma y las correlaciones parciales no nos proveerán de tanta información como normalmente pueden y en que el error estándar va tender a ser relativamente más grande y con esto el estadígrafo de *student T* va a ser más pequeño. Que el *T* tienda a ser más pequeño puede significar que no utilizamos toda la información disponible en los datos porque podemos desprestigiar parámetros que con una muestra más grande serían significativos. En definitiva, esto significa que escogemos el riesgo de estimar un modelo que no incluya todos los parámetros relevantes y con esos no utiliza toda la información disponible, al riesgo de estimar un modelo con más datos, pero que puedan estar dando información falsa sobre el proceso que queremos identificar.

El punto de partida para la serie que utilizaremos se fijó en junio de 1974 de acuerdo a la información que provee el gráfico de las tasas de desempleo. Esta decisión es en cierto modo arbitraria, porque se podrían haber escogido períodos anteriores o posteriores. Aunque hasta no tener un modelo identificado y estimado no se puede saber la importancia que tenga el período con que se inicie la serie. Lo que le da importancia al punto de partida es el hecho de que es una muestra pequeña en la que cada dato tiene alguna importancia.

---

<sup>5</sup> Box y Jenkins, *Time-Series Analysis*, cap.4.

Para identificar el proceso que sigue la tasa de desempleo a partir de junio de 1974 utilizamos nuevamente el análisis espectral de los datos del período (anexo 3). El periodograma muestra en forma muy directa el característico "cerro" de un proceso correspondiente a un AR(2).

Finalmente también se puede reconocer la "aguja" correspondiente a la estacionalidad anual, aunque la estacionalidad es bastante más visible en los datos que generan el periodograma que en el gráfico mismo.

Del análisis espectral de los datos tenemos, por lo tanto, como información para la identificación del proceso, que éste es por lo menos un AR(2) y quizás un AR(4) con una estacionalidad anual.

La presencia de estacionalidad complica la identificación del proceso, debido a que ahora también tenemos que modelar la estacionalidad. Como la muestra es pequeña, tenemos que modelar la estacionalidad en forma simultánea con el resto del modelo para utilizar en forma estadísticamente óptima la información disponible.<sup>6</sup> En muestras más grandes es más permisible modelar secuencialmente los distintos componentes de la variable. El modelo que obtendremos será de la forma multiplicativa  $(p, d, q) \times (P, D, Q)$ <sup>5</sup> en el que las mayúsculas representan los parámetros del modelo para la estacionalidad anual y las diferentes letras representan por supuesto el número de parámetros autorregresivos, de diferencias y de parámetros de media móvil.

Con la información que disponemos hasta ahora, sabemos que  $p$  probablemente es igual a 2,  $d$  es igual a 0 porque no se reconoce una determinada tendencia en el desempleo del período analizado y  $q$ , como vimos, es igual a 4. El resto de la información trataremos de obtenerla del autocorrelograma y de las correlaciones parciales.

Al analizar el autocorrelograma y las correlaciones parciales de la tasa de desempleo (anexo 5), se confirma parte de la información del análisis espectral. Se ve que puede ser un proceso AR(2) en la caída de las autocorrelaciones, las cuales caen muy rápido como para ser por ejemplo un AR(1), además las únicas autocorrelaciones parciales significativas son las primeras 2, pero esta segunda información hay que tomarla con prudencia debido a que quizás con un mayor número de datos podrían aparecer más correlaciones parciales significativas.

Lo que en el correlograma no se reconoce tan claramente, como en el análisis espectral, es la estacionalidad anual. Esta no se reconoce en el autocorrelograma, sólo en las correlaciones parciales se podría adivinar algo la

<sup>6</sup>Box y Jenkins, *Time Series Analysis*, p. 303.

estacionalidad. Sin la información del espectro, diríamos que el modelo es un AR(2) sin estacionalidad. Lo que resulta extraño en estos datos es que el autocorrelograma de las primeras o de las segundas diferencias tampoco muestra la estacionalidad.

Si estimamos el modelo con un AR(2), obtenemos un modelo estacionario, pero cuyo segundo parámetro AR marginalmente no es significativamente diferente de 0. Ambos parámetros AR están muy correlacionados, lo que puede indicar redundancia de uno de estos, además esta correlación puede ser una explicación para el pequeño estadígrafo T del segundo parámetro AR. Sobre todo es importante notar que los residuos del modelo están muy correlacionados. Estas altas autocorrelaciones de los residuos nos están mostrando que no estamos utilizando toda la información disponible en los datos. Esto es especialmente notorio en las autocorrelaciones de 4, 8, 12 y 16 rezagos que nos están indicando que de alguna manera hay que modelar el ciclo anual, pese a que éste no es visible en el autocorrelograma.

Para disminuir la correlación entre los residuos se identificaron diferentes modelos en los que de diferentes maneras se trató de considerar la estacionalidad anual. Pese a que algunos modelos resultaron mejor que otros, ninguno logró eliminar satisfactoriamente la estacionalidad.

Debido a este problema se decidió tomar una primera diferencia cada 4 períodos para ver si de esta manera se eliminaba la estacionalidad. El espectro de los datos diferenciados de esta manera sigue indicando un proceso AR(2) y ya no tiene el ciclo anual. El correlograma no muestra ninguna estacionalidad de 4 períodos que podría haber sido incorporada por una sobre-diferenciación y también muestra un proceso AR(2). (Anexo 6.)

Al tratar de identificar y estimar el modelo nos damos cuenta que la diferenciación de 4 períodos por sí sola no elimina nuestro problema de estacionalidad, por lo que también tenemos que identificar el proceso estacional. Al hacer esto obtenemos el siguiente modelo ARIMA.

$$(2, 0, 0) \times (0, 1, 1)^4$$

con los parámetros:

AR1	=	1,36	(T = 8,79)
AR2	=	-0,53	(T = -3,4 )
SMA1	=	0,75	(T = 5,84)
MEDIA	=	1,17	(T = 2,14)

Este modelo no es el único cuyas estadísticas  $T$  son significativas, lo que muestra que el tamaño de la muestra no es importante en este aspecto, pero considerando otros indicadores basados principalmente en el análisis de los residuos del modelo y además de acuerdo al principio de parsimonia que nos dice que a igual calidad del modelo se escoja aquel con el menor número de parámetros, este modelo parece ser el más adecuado al lograr explicar un 81 por ciento de la varianza de la serie original.

Los residuos del modelo de acuerdo al estadígrafo  $Q$  de Box Pierce<sup>7</sup> son independientes entre sí con una probabilidad de 96 por ciento. El análisis espectral de los residuos también parece indicar que se trata de ruido blanco. El único problema que se ve en el espectro está en el período de 3,6 trimestres, que podría estar mostrando un ciclo determinístico, este posible ciclo no es corregible a través de cambiar el modelo estacional, porque el período de 4 trimestres no tiene una potencia que sea relevante considerar. Para despejar la duda, utilizamos los datos del espectro para *testear* si los datos corresponden a un ruido blanco a través de los estadígrafos Kappa de Fischer y Kolmogorov-Smirnov de Bartlett. Ambos tests con un alto grado de significancia indican que los residuos son independientes. Por esto el problema podría ser de *Aliasing*,<sup>8</sup> es decir, la potencia de esa frecuencia está inflada por un ciclo de mayor frecuencia que la trimestral. Si efectivamente esa fuera la razón, significaría que existe un ciclo de 15 días en el empleo.

Adelantándonos a las predicciones, analizamos si podemos suponer que los residuos se distribuyen normalmente para poder utilizar las estadísticas habituales para determinar los rangos de confianza de nuestras estimaciones. Al hacer este análisis, vemos que los tests indican que los residuos tienen una distribución normal sin problemas de Kurtosis ni de Sesgo significantes.

Al examinar las predicciones del modelo se corrobora la impresión de que el modelo escogido es el más adecuado. Para comparar las predicciones de diferentes modelos utilizaremos un indicador llamado MAPE (Moving average period efficiency) que consiste en una media móvil de los residuos al cuadrado de la predicción. Se utilizó una media móvil de 4 períodos para comparar la calidad o eficiencia de las predicciones durante el año transcurrido (anexo 7). Los diferentes MAPE que se obtuvieron no indicaron que el modelo escogido tuviera para todos los períodos las mejores predicciones, pero sí mostraron que los mejores MAPE en los últimos tres años correspondían al modelo escogido, lo que muestra que el modelo consistentemente durante los últimos cuatro años ha estimado las mejores predicciones. Como nuestro interés está en hacer predicciones sobre el futuro de la tasa de des-

<sup>7</sup>Box y Jenkins, *Time Series Analysis*, p. 291.

<sup>8</sup>C.W.J. Granger y P. Newbold, *Forecasting Economic Time Series*, p. 55 y 56.

empleo, la bondad del ajuste para los últimos períodos promete proveer las mejores predicciones a futuro.

Por supuesto, el verdadero test para el modelo consiste en las predicciones que haga fuera del período muestral. En base a este modelo, la cifra de la Universidad de Chile para la tasa de desempleo en el Gran Santiago, en septiembre de 1984, debiera ser de 17,62 por ciento. La predicción del modelo para la cifra de junio fue de un 20,8 por ciento. Esta predicción no fue muy acertada debido al quiebre en la tendencia que hizo que la tasa de desempleo cayera de un 21,7 por ciento a un 18,4 por ciento, pero ninguna de las predicciones de otros modelos tuvo un porcentaje de error menor que el 13 por ciento del modelo escogido, debido a que tampoco estaban en condiciones de predecir este quiebre en los datos. Las predicciones para marzo de 1984 y diciembre de 1983 hechas fuera del período muestral son 22,4 y 20,2 respectivamente. Si comparamos las predicciones con los datos efectivos que fueron 21,7 y 20,4 podemos decir que hubieran sido muy buenas predicciones, ya que los porcentajes de error fueron sólo 3,2 por ciento y 1 por ciento.

Aquí cabe preguntarse qué utilidad tiene un modelo que no es capaz de predecir los quiebres de tendencia en un país que tiene muchos. La respuesta a esto es que el modelo es capaz de ajustarse rápidamente y por lo tanto sólo ocurren errores de predicción importantes en el período del quiebre. Además, el modelo es la base para otro modelo que permita predecir cuándo ocurrirá el próximo punto de quiebre.

Otro resultado interesante que se obtuvo de realizar estas predicciones es que para hacer predicciones fuera del período muestral hubo que reducir aún más el tamaño de la muestra con que trabajamos. Esta reducción de una muestra que ya podía ser considerada pequeña, no tuvo ningún efecto sobre la calidad de las predicciones y tampoco tuvo gran efecto sobre el valor de los parámetros del modelo. Este carácter robusto del modelo aumentó la confianza que podemos tener en él y reduce las dudas que se puedan tener respecto al tamaño de la muestra.

Un problema con la identificación y estimación del modelo radica en el hecho de que la decisión sobre el comienzo de la serie fue en cierto modo arbitraria. Como la serie es relativamente corta, un cambio en el dato con que comenzaremos la serie podría tener efectos importantes. Para ver la importancia que podría tener este problema iniciaremos la serie con el dato anterior. Utilizamos un sólo dato adicional, porque la arbitrariedad respecto al inicio de la serie se reduce a sólo estos datos. Los datos que están más alejados del dato inicial escogido pertenecen con bastante seguridad a otro proceso estocástico. Los cambios que produzca este dato adicional en los parámetros

y las predicciones del modelo son un buen indicador de cuán serio es el problema mencionado.

El nuevo correlograma y las nuevas correlaciones parciales no presentan cambios significativos respecto a los originales. Por lo tanto, la identificación del modelo es la misma y el modelo parece estable.

Al comparar los nuevos parámetros con los originales tenemos:

Parámetro	Valor nuevo	T	Valor	T
Media	1,32	1,84	1,17	2,14
SMA1	0,58	3,64	0,75	5,84
ARI	1,42	9,79	1,36	8,79
AR2	-0,59	-3,98	-0,53	-3,40

A excepción del parámetro de la media del proceso, todos los parámetros siguen siendo significativos al agregar el dato adicional, pero los nuevos parámetros son diferentes a los originales. Pese a que las diferencias no son grandes, éstas son mayores de lo que se esperaría de agregar un dato. Estas diferencias se pueden deber a problemas del tamaño de la muestra o a que el dato adicional corresponde a otro proceso estocástico. La razón parece estar en que el nuevo dato corresponde a otro proceso estocástico, ya que como vimos anteriormente al eliminar o agregar datos al final de la serie el modelo demostró ser robusto. Un indicio en la misma dirección está en el hecho de que la probabilidad de que los residuos sean independientes cae en relación a la serie original, aunque sigue satisfaciendo cualquier test de independencia. Este cambio nos indica que no estamos utilizando alguna información contenida en los nuevos datos, como podría ser el hecho de que algunos de estos pertenecen a otro proceso.

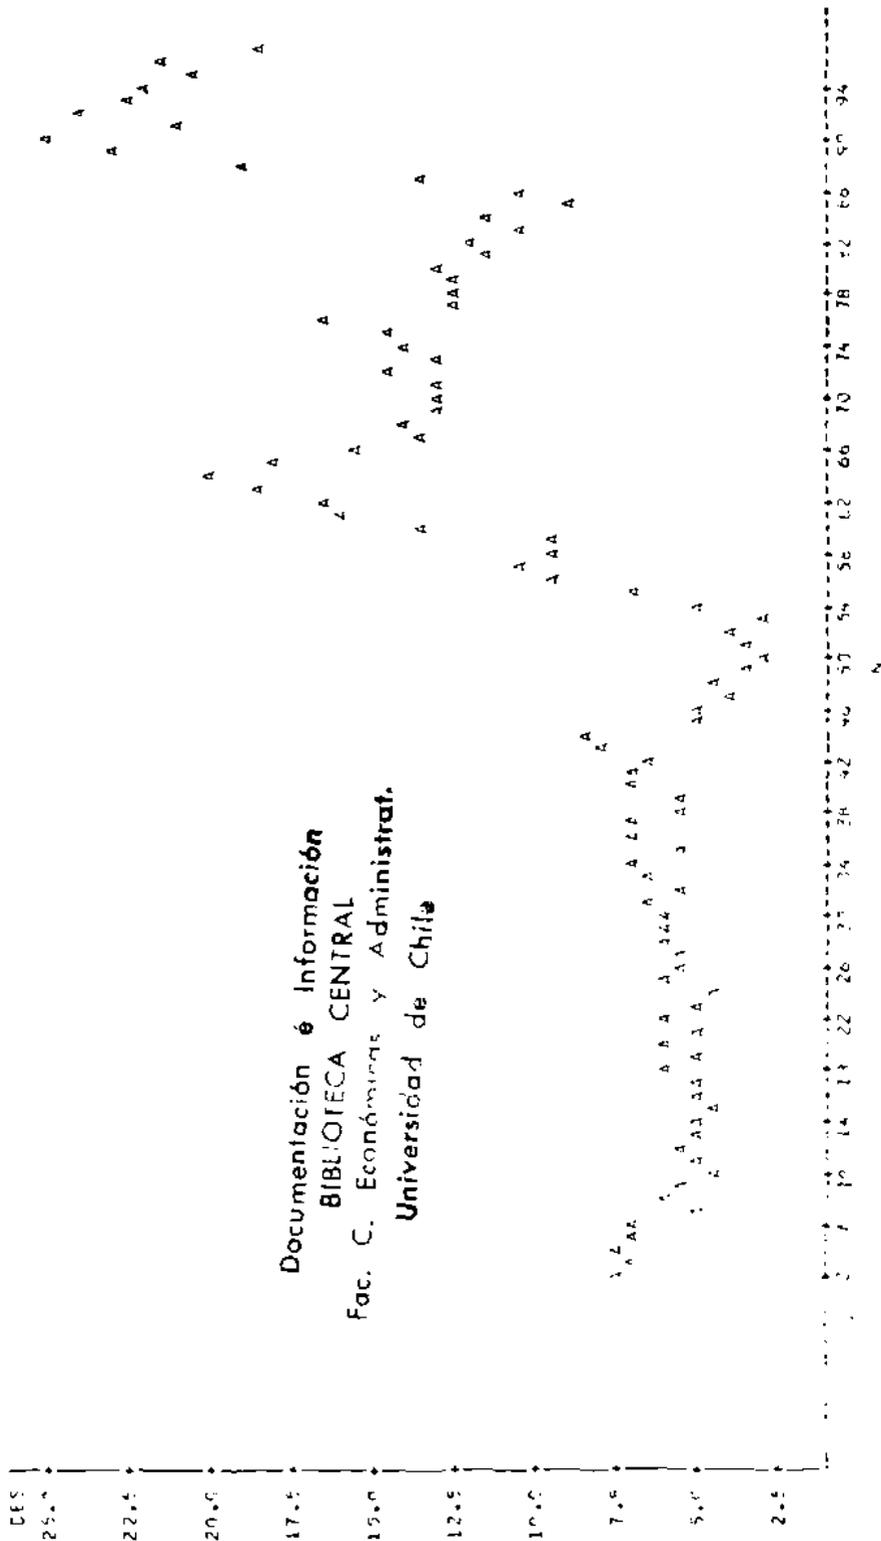
Otra indicación de que el dato adicional pertenece a otro proceso estocástico está en el hecho de que la eficiencia del modelo por período (MAPE) (anexo 2) es mayor para el modelo original durante los últimos tres años de la serie, lo que nos indica que el dato adicional no nos proporciona información útil para hacer proyecciones en los últimos períodos. Esto es confirmado por las predicciones fuera del período muestral del nuevo modelo que son 17,44 por ciento para septiembre de 1984; 20,74 por ciento para junio de 1984; 23 por ciento para marzo de 1984, y 19,3 por ciento para diciembre de 1983, las predicciones del modelo original resultan mejores. Además, este nuevo modelo es menos robusto al ir eliminando datos al final de la muestra.

Otros indicadores, como la suma de los residuos al cuadrado, no muestran diferencias entre los dos modelos.

Estos resultados muestran que más importante que tener un gran número de datos en la muestra, es que la serie que se va a analizar sea efectivamente estacionaria. Vemos que, pese a tener una serie relativamente corta, los resultados obtenidos son significativos y el modelo proporciona un buen ajuste. Al agregar datos que pueden provenir de un proceso estocástico diferente, no ganamos información adicional, e incluso, podemos empeorar las proyecciones de los períodos que nos interesen.

ANEXO I

TASA DE DESEMPLEO GRAN SANTIAGO,  
JUNIO 1960 A JUNIO 1984



## ANEXO 2

ESPECTRO DE LA TASA DE DESEMPLEO.  
SEPTIEMBRE 1960 A JUNIO 1984

Observaciones	Frecuencia	Período	P-01	S-01
1	0,00000	—	18.635,4	130,556
2	0,06545	96,0000	1.640,6	130,556
3	0,13090	48,0000	66,7	5,309
4	0,19635	32,0000	563,7	44,856
5	0,26180	24,0000	326,1	25,953
6	0,32725	19,2000	64,9	5,167
7	0,39270	16,0000	204,7	16,287
8	0,45815	13,7143	54,0	4,296
9	0,52360	12,0000	13,7	1,087
10	0,58905	10,6667	5,2	0,414
11	0,65450	9,6000	7,1	0,569
12	0,71995	8,7273	8,5	0,678
13	0,78540	8,0000	12,7	1,009
14	0,85085	7,3846	7,0	0,561
15	0,91630	6,8571	22,4	1,779
16	0,98175	6,4000	27,3	2,170
17	1,04720	6,0000	3,7	0,293
18	1,11265	5,6471	3,0	0,240
19	1,17810	5,3333	0,7	0,059
20	1,24355	5,0526	1,3	0,103
21	1,30900	4,8000	0,7	0,057
22	1,37445	4,5714	1,4	0,114
23	1,43990	4,3636	4,8	0,381
24	1,50535	4,1739	6,7	0,532
25	1,57080	4,0000	19,1	1,519
26	1,63625	3,8400	0,0	0,000
27	1,70170	3,6923	2,0	0,155
28	1,76715	3,5556	9,4	0,748
29	1,83260	3,4286	1,9	0,149
30	1,89805	3,3103	2,2	0,172
31	1,96350	3,2000	0,2	0,013
32	2,02895	3,0968	1,0	0,076
33	2,09440	3,0000	2,8	0,226
34	2,15984	2,9091	1,1	0,086
35	2,22529	2,8235	1,0	0,082
36	2,29074	2,7429	0,4	0,032
37	2,35619	2,6667	2,2	0,174
38	2,42164	2,5946	0,7	0,054
39	2,48709	2,5263	2,7	0,215
40	2,55254	2,4615	0,7	0,053
41	2,61799	2,4000	1,5	0,118
42	2,68344	2,3415	1,4	0,114
43	2,74889	2,2857	0,2	0,016
44	2,81434	2,2326	0,9	0,072
45	2,87979	2,1818	0,7	0,056
46	2,94524	2,1333	1,6	0,130
47	3,01069	2,0870	0,5	0,040
48	3,07614	2,0426	1,0	0,078
49	3,14159	2,0000	6,5	0,514

## ANEXO 3

ESPECTRO DE LA TASA DE DESEMPLEO.  
JUNIO 1960 A MARZO 1974

Observaciones	Frecuencia	Período	P-01	S. 01
1	0,00000	.	3.673,39	0,08014
2	0,11220	56,0000	1,01	0,08014
3	0,22440	28,0000	20,65	1,64289
4	0,33660	18,6667	26,28	2,09162
5	0,44880	14,0000	17,94	1,42795
6	0,56100	11,2000	4,35	0,34628
7	0,67320	9,3333	0,42	0,03377
8	0,78540	8,0000	0,74	0,05927
9	0,89760	7,0000	3,46	0,27504
10	1,00980	6,2222	3,75	0,29805
11	1,12200	5,6000	0,48	0,03793
12	1,23420	5,0909	0,06	0,00514
13	1,34640	4,6667	0,50	0,03966
14	1,45860	4,3077	2,24	0,17861
15	1,57080	4,0000	3,30	0,26286
16	1,68300	3,7333	1,73	0,13769
17	1,79520	3,5000	1,11	0,08822
18	1,90740	3,2941	0,30	0,02410
19	2,01960	3,1111	1,86	0,14778
20	2,13180	2,9474	0,77	0,06121
21	2,24399	2,8000	1,10	0,08792
22	2,35619	2,6667	0,69	0,05472
23	2,46839	2,5455	0,70	0,05556
24	2,58059	2,4348	0,03	0,00218
25	2,69279	2,3333	0,89	0,07089
26	2,80499	2,2400	0,27	0,02159
27	2,91719	2,1538	0,35	0,02800
28	3,02939	2,0741	0,46	0,03627
29	3,14159	2,0000	2,84	0,22563

**ESPECTRO TASA DE DESEMPLEO.  
SEPTIEMBRE 1974 A JUNIO 1984**

Observaciones	Frecuencia	Período	P-01	S-01
1	0,00000	—	19.388,4	18,6702
2	0,15708	40,0000	234,6	18,6702
3	0,31416	20,0000	154,1	12,2593
4	0,47124	13,3333	210,1	16,7197
5	0,62832	10,0000	26,1	2,0789
6	0,78540	8,0000	26,9	2,1421
7	0,94248	6,6667	44,6	3,5460
8	1,09956	5,7143	5,1	0,4029
9	1,25664	5,0000	2,6	0,2061
10	1,41372	4,4444	4,9	0,3939
11	1,57080	4,0000	19,0	1,5088
12	1,72788	3,6364	9,7	0,7703
13	1,88496	3,3333	3,1	0,2451
14	2,04204	3,0769	1,3	0,1064
15	2,19911	2,8571	0,0	0,0028
16	2,35619	2,6667	0,9	0,0746
17	2,51327	2,5000	1,2	0,0924
18	2,67035	2,3529	0,9	0,0753
19	2,82743	2,2222	1,7	0,1351
20	2,98451	2,1053	1,9	0,1509
21	3,14159	2,0000	6,1	0,4858

ANEXO 4

CORRELOGRAMAS, TASA DE DESEMPLEO,  
JUNIO 1960 A MARZO 1974

MEDIA DE LA SERIE = 5,72696  
DESVIACION ESTANDAR = 1,91518  
NUMERO DE OBSERVACIONES = 56

AUTOCORRELACIONES

LAG	Covarianza	Correlación	-1	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1	STD
0	1.723771	1.000000								.....										0.133631
1	1.009479	0.58379								.....										0.173288
2	0.615923	0.35609								.....										0.133696
3	0.425346	0.24591								.....										0.191616
4	0.208094	0.12031								.....										0.192961
5	-0.147977	-0.08555								.....										0.153631
6	-0.293765	-0.16984								.....										0.196279
7	-0.277063	-0.15729								.....										0.198517
8	-0.321301	-0.18575								.....										0.201597
9	-0.531734	-0.30741								.....										0.204861
10	-0.445618	-0.25763								.....										0.215376
11	-0.273552	-0.13616								.....										0.216937
12	0.007424	0.00433								.....										0.216909
13	-0.117433	-0.06789								.....										0.217288
14	-0.149148	-0.08565								.....										0.217889
15	-0.095337	-0.05494								.....										0.218137
16	-0.179771	-0.10393								.....										0.218102
17	-0.311269	-0.17995								.....										0.221644
18	-0.271725	-0.15709								.....										0.223624
19	-0.128841	-0.08027								.....										0.224138
20	-0.222266	-0.12850								.....										0.225449
21	-0.204175	-0.11805								.....										0.226551
22	-0.0977793	-0.05649								.....										0.226802
23	-0.0359467	-0.02078								.....										0.226836
24	-0.0140364	-0.00811								.....										

Los puntos indican dos errores estándar

CORRELACIONES PARCIALES

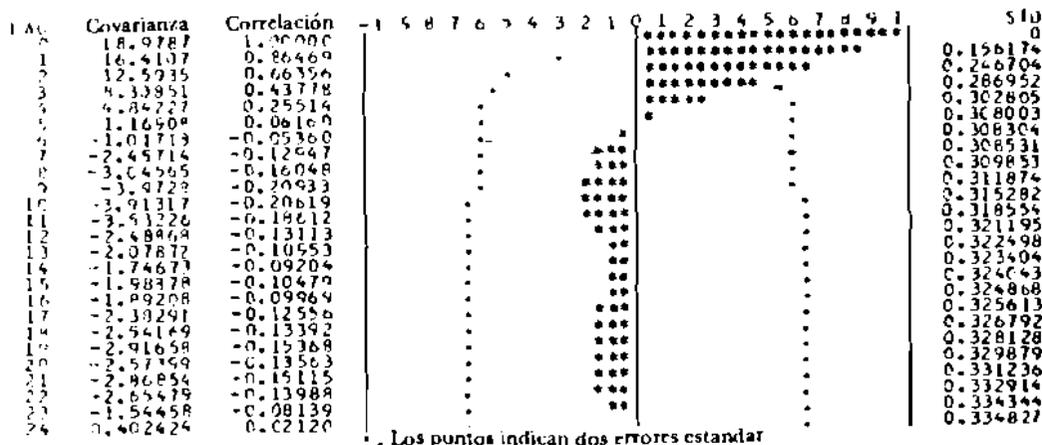
LAG	Correlación	-1	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1
1	0.58379								.....									
2	0.02318								.....									
3	0.04450								.....									
4	-0.06623								.....									
5	-0.21951								.....									
6	-0.05897								.....									
7	0.02063								.....									
8	-0.05876								.....									
9	-0.21112								.....									
10	0.01096								.....									
11	0.07302								.....									
12	-0.16448								.....									
13	-0.19327								.....									
14	-0.14954								.....									
15	-0.06156								.....									
16	-0.07819								.....									
17	-0.06381								.....									
18	-0.06545								.....									
19	-0.00791								.....									
20	-0.13122								.....									
21	0.06410								.....									
22	-0.04013								.....									
23	-0.09016								.....									
24	-0.00145								.....									

ANEXO 5

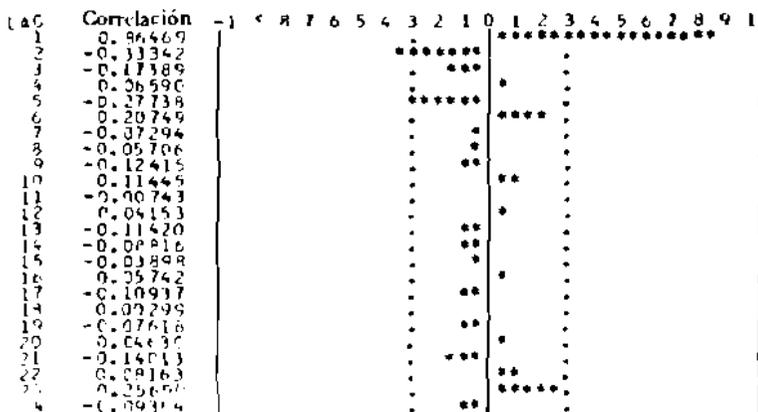
CORRELOGRAMA TASA DESEMPLEO.  
JUNIO 1974 A JUNIO 1984

MEDIA DE LA SERIE = 15,441  
DESVIACION ESTANDAR = 4,35645  
NUMERO DE OBSERVACIONES = 41

AUTOCORRELACIONES



CORRELACIONES PARCIALES

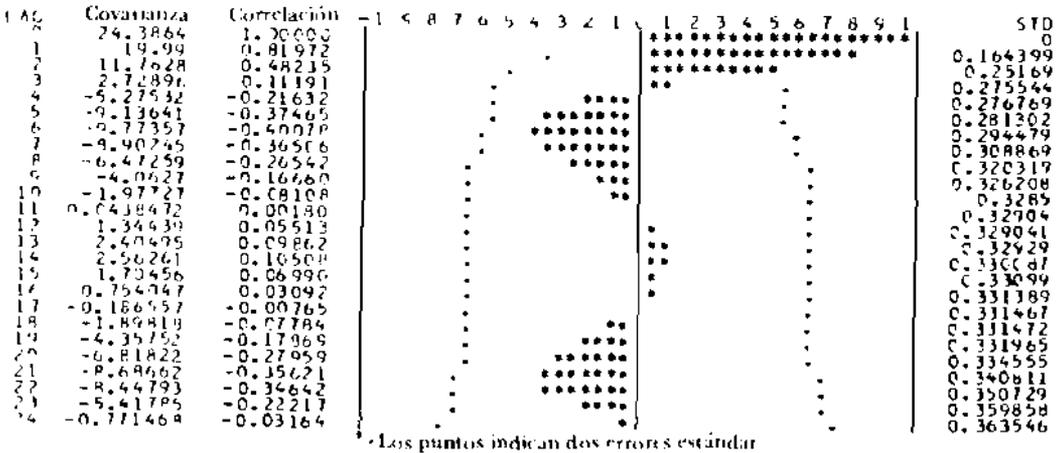


ANEXO 6

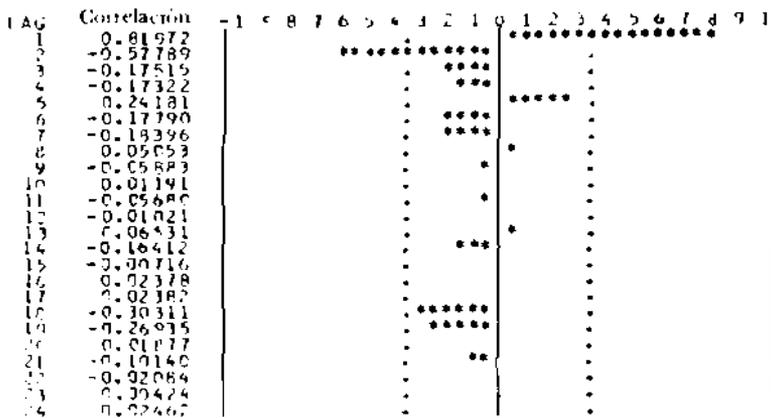
CORRELOGRAMA DE LA TASA DE DESEMPLEO  
JUNIO 1974 A JUNIO 1984

PERIODOS DE DIFERENCIACION 4  
 MEDIA DE LA SERIE 1.07135  
 DESVIACION ESTANDAR 4.93826  
 NUMERO DE OBSERVACIONES 37

AUTOCORRELACIONES



CORRELACIONES PARCIALES



## ANEXO 7

MAPE (2,0,0)x(0,1,1) <sup>4</sup> Datos J74-J84	MAPE (2,0,0)x(0,1,1) <sup>4</sup> Datos M74-J84	MAPE (3,0,1) Datos J74-J84
2,14	2,65	1,18
3,3	3,65	2,15
3,36	3,25	2,21
2,9	3,25	1,73
2,18	2,12	2,29
1,57	1,38	1,66
1,54	1,5	1,71
1,09	1,02	1,44
1,06	1,08	1,4
2,76	2,48	3,21
3,55	3,42	4,49
3,54	3,41	4,5
3,59	2,98	4,39
5,58	4,34	7,63
5,08	3,5	7,28
5,26	3,63	7,27
6,58	4,64	6,52
2,17	1,79	1,44
2,06	1,92	0,46
3,22	2,92	0,79
2,08	1,9	0,94
3,11	2,7	2,2
3,02	1,84	3,11
1,89	1,16	4,06
2,73	2,82	7,9
4,21	5,65	7,57
4,17	5,84	6,59
7,06	8,3,9	7,18
8,56	9,82	9,21
6,13	6,69	8,02
6,08	6,42	8,01
2,92	3,5	6,29
0,17	0,56	1,22
1,53	1,76	2,06

## BIBLIOGRAFIA

- Box, G.E.P. y  
G.M. Jenkins,                      Time Series Analysis, 1976.
- Departamento de Economía      Serie ocupación y desocupación en el Gran  
Universidad de Chile              Santiago.
- Gottman, J.M.,                      Time Series Analysis, 1981.
- Granger, C.W.J. y  
Paul Newbold,                      Forecasting Economic Time Series, 1977.
- Kreyszig, E.,                      Statistische Methoden, 1973.
- L. Riveros,                      Desestacionalización de las series de ocupa-  
ción. Métodos alternativos. Estudio especial,  
Taller de Coyuntura, primer semestre, 1980.