

UNIDAD VIII

**Análisis de series temporales como
métodos de predicción**

UNIDAD VIII



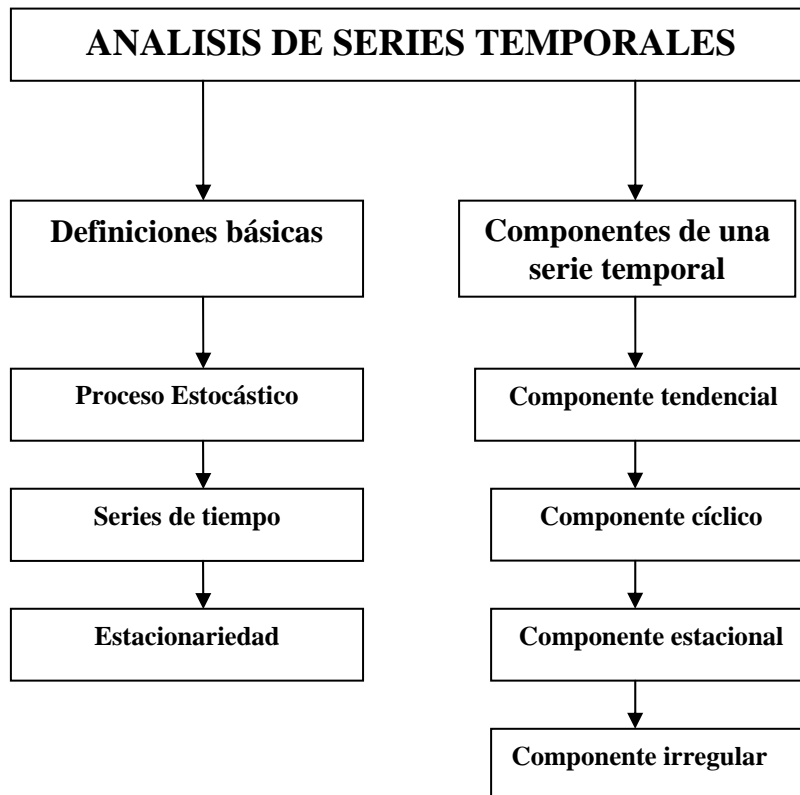
“La estadística demuestra que cuanto más se sabe más suerte se tiene”

Allen L. Webster, 1998

- **¿A qué se denominan series temporales y Procesos Estadísticos?**
- **¿Cuáles son los componentes de una serie temporal?**
- **¿Cómo se representa una serie temporal?**
- **¿Qué son Modelos Autoregresivos y de rezagos distribuidos?**
- **¿Cómo es la metodología de Koyc?**

ANALISIS DE SERIES TEMPORALES COMO METODOS DE PREDICCIÓN

ESQUEMA CONCEPTUAL



COMPETENCIAS A LOGRAR

CONCEPTUAL	PROCEDIMENTAL	ACTITUDINAL
Explica los modos de utilizar los datos de la serie temporales para hacer predicciones.	Aplica la técnica del análisis de series de tiempo para predecir y prever sucesos futuros.	Analiza el empleo de las series temporales para una buena toma de decisiones.

CONCEPTOS –CLAVE

Series, temporales, estocástico, estacionariedad, tendencia, cíclico

LECCIÓN 1

SERIES TEMPORALES Y PROCESOS ESTADÍSTICOS

Toda institución, ya sea la familia, la empresa o el gobierno, tiene que hacer planes para el futuro si ha de sobrevivir y progresar. Hoy en día diversas instituciones requieren conocer el comportamiento futuro de ciertos fenómenos con el fin de planificar, prever o prevenir.

La planificación racional exige prever los sucesos del futuro que probablemente vayan a ocurrir. La previsión, a su vez, se suele basar en lo que ha ocurrido en el pasado. Se tiene pues un nuevo tipo de inferencia estadística que se hace acerca del futuro de alguna variable basándose en **sucesos pasados**. De todas las técnicas conocidas, la más importante para hacer inferencias sobre el futuro con base a lo ocurrido en el pasado, es el análisis de **series de tiempo**.

Dentro de las múltiples aplicaciones podemos destacar los ejemplos siguientes

Series De Tiempo	Ejemplos
1. Series económicas:	<ul style="list-style-type: none">- Precios o producción de un artículo- ventas o existencias- inflación- Producto Bruto Interno, etc.
2. Series Físicas:	<ul style="list-style-type: none">- Meteorología- Cantidad de agua caída- Temperatura máxima diaria- Velocidad del viento (energía eólica)- Energía solar, etc.
3. Geofísica:	<ul style="list-style-type: none">- Series sismológicas
4. Series sociodemográficas:	<ul style="list-style-type: none">- Población, nacimientos, defunciones- migraciones, empleo- Alumnos ,matriculados, consultas médicas
5. Series de marketing:	<ul style="list-style-type: none">- Series de demanda, gastos, ofertas- Gastos de publicidad
6. Series de telecomunicación:	<ul style="list-style-type: none">- Líneas telefónicas fijas, móviles, llamadas telefónicas
7. Series de transporte:	<ul style="list-style-type: none">- Series de tráfico aéreo, transporte de pasajeros terrestre aéreo, terrestre.

En conclusión se puede decir que son innumerables las aplicaciones que se pueden citar, en distintas áreas del conocimiento, tales como, en economía, física, geofísica, química, electricidad, en demografía, en marketing, en telecomunicaciones, en transporte, etc.

1. DEFINICIONES BÁSICAS

- **Proceso estocástico:** Es la secuencia ordenada de variables aleatorias $Y(t)$, es decir, la sucesión de variables aleatorias ordenadas Y_1, Y_2, \dots, Y_T , las cuales constituyen en su conjunto lo que se conoce como una serie temporal.
- **Serie de tiempo:** Es un conjunto de mediciones (datos o números), relativos a un fenómeno (p.ej. precios de la bolsa), tomados a intervalos regulares de tiempo (cada mes, cada semana, cada año, etc.).

La necesidad de estudiar series de tiempo radica a que en muchas áreas del conocimiento las observaciones de interés son obtenidas en instantes sucesivos del tiempo, por ejemplo, a cada hora, durante 24 horas, mensuales, trimestrales, semestrales o bien registradas por algún equipo en forma continua

Notaciones:

- Serie de tiempo $\{Y_{t_1}, Y_{t_2}, \dots, Y_{t_n}\} = \{Y_t : t \in T \subseteq \mathbb{R}\}$ con Y_{t_i} el valor de la variable Y en el instante t_i .
- Cuando $t_{i+1} - t_i = k$ para todo $i = 1, \dots, n-1$, se dice que la serie es equiespaciada, en caso contrario será no equiespaciada.

En adelante se trabajará con series de tiempo discreta, equiespaciadas en cuyo caso asumiremos y sin pérdida de generalidad que:

$$\{Y_{t_1}, Y_{t_2}, \dots, Y_{t_n}\} = \{Y_1, Y_2, \dots, Y_n\}$$

- **Estacionariedad:** Cuando analizamos una serie de tiempo nos referimos a una variable medida en diferentes momentos $\{Y_{t_1}, Y_{t_2}, \dots, Y_{t_n}\}$, por lo cual es de suponer que cada Y_{t_i} pueda tener diferente distribución, por ello la condición de estacionariedad plantea que las variables aleatorias que componen una serie temporal estén idénticamente distribuidas.

Debido a que la condición de estacionariedad es muy estricta para nuestras necesidades prácticas, se define un concepto menos exigente, como es el de estacionariedad en sentido débil o de segundo orden, que plantea la estacionariedad en media y varianza que se definen a continuación:

- **Proceso estacionario en media;** es aquel proceso estocástico $\{Y_T\}$ que tiene media constante, es decir, no depende del tiempo

$$E[Y_t] = \mu \quad \text{para toda } t$$

- **Proceso estacionario en varianza;** es el proceso estocástico $\{Y_T\}$ que tiene media constante, varianza constante, además la covarianza no depende del tiempo sino de la distancia a la que se toman las observaciones:

$$E[Y_t] = \mu \quad \text{para toda } t$$

$$\text{Var}(Y_t) = \sigma^2 \quad \text{para toda } t$$

$$\text{Cov}(Y_t, Y_{t-k}) = \emptyset(k) \quad \text{no depende de } t$$

- **Ruido Blanco**; es un tipo especial de proceso estocástico el cual cumple ciertas condiciones, tales como:

$$E[\mu_t] = 0 \quad \text{media cero.}$$

$$\text{Var}(\mu_t) = \sigma^2 \quad \text{varianza constante.}$$

$$\text{Cov}(\mu_t, \mu_s) = 0 \quad \text{para valores de "t" diferente de "s".}$$

Es decir, se trata de un proceso estocástico que tiene de media cero, varianza constante, donde los diferentes términos no presentan covariación entre sí. Si además cada variable aleatoria está distribuida bajo la normal se le llama un proceso de ruido blanco gaussiano.

LECCIÓN 2

COMPONENTES DE UNA SERIE TEMPORAL

En primer lugar, cuando observamos las series temporales, éstas van a tener en general una característica común: **no permanecen fluctuando de una manera aleatoria alrededor de un valor medio constante a lo largo del tiempo**, es decir, no son series estacionarias. Más bien, las series se caracterizan por seguir uno de los comportamientos siguientes:

- a. No mantienen un valor medio constante, sino que siguen un comportamiento creciente a lo largo del tiempo; es decir, presentan una tendencia creciente (por ejemplo, las series macroeconómicas de Consumo Privado, de Producto Interior Bruto, de IPC, etc.).
- b. Aunque no crezcan de manera definida, mantienen valores sistemáticos por encima del valor medio y a continuación, valores sistemáticos por debajo del valor medio (por ejemplo, valores de bolsa, tipos de interés, etc.)

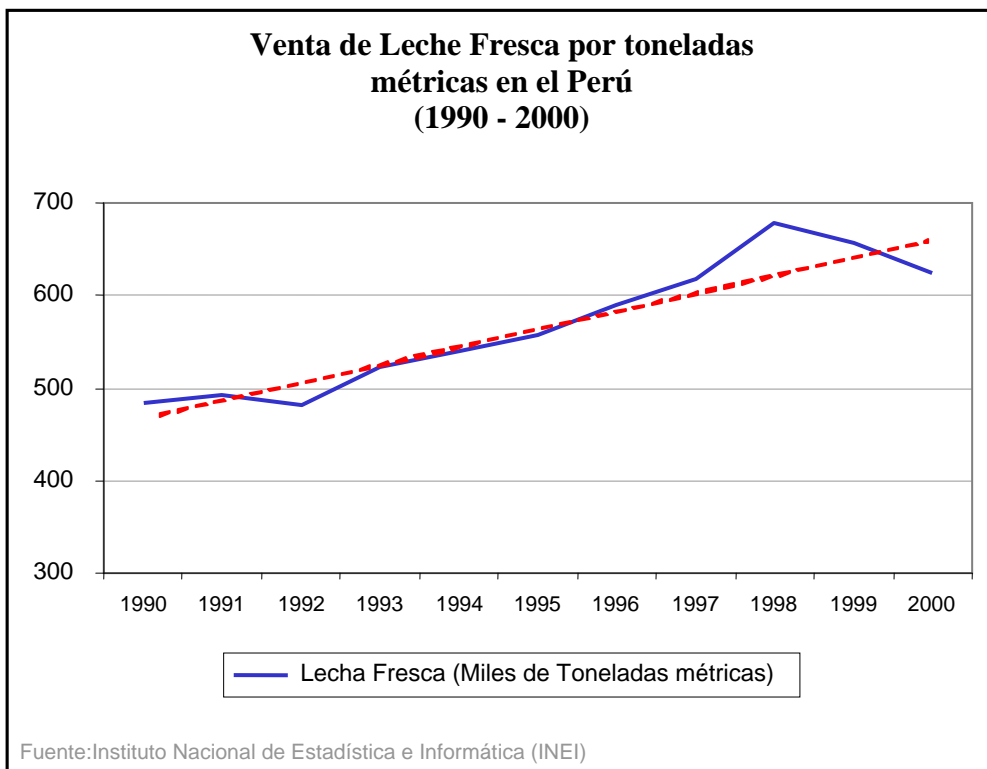
Por tanto, las series mantienen una pauta de comportamiento a medio y largo plazo que no va a poder ser olvidado y que habrá que tener en cuenta. Ahora bien, ¿qué otras características podrían tener las series temporales?

Muchas de estas series suelen tener un comportamiento claro dentro de cada año a lo largo del tiempo. Así, estas series no se comportan de igual manera todos los meses del año. Un ejemplo podría ser la producción industrial es mayor entre setiembre y octubre respecto a los restantes meses del año, el consumo de refrescos aumenta en los meses de verano, etc.


Por último, todas las series temporales, al reflejar un comportamiento humano, muestran un componente puramente aleatorio, no determinista, que no sigue ninguna pauta clara y que hace que cada observación sea diferente a las demás.

Resumiendo, en toda serie temporal existen varios componentes que van a mostrar su evolución a largo, medio, corto y muy corto plazo. De esta manera, podemos dividir una serie temporal en cuatro componentes:

- A. **Componente tendencial:** Movimiento general a largo plazo de la serie, se observa en una serie con un comportamiento determinado ya sea creciente o decreciente.




B. **Componente cíclico:** Oscilaciones que se producen en la serie en períodos superiores a un año; en muchas ocasiones, la serie muestra más de un ciclo, superponiéndose éstos entre sí, lo que hace difícil determinar este componente.

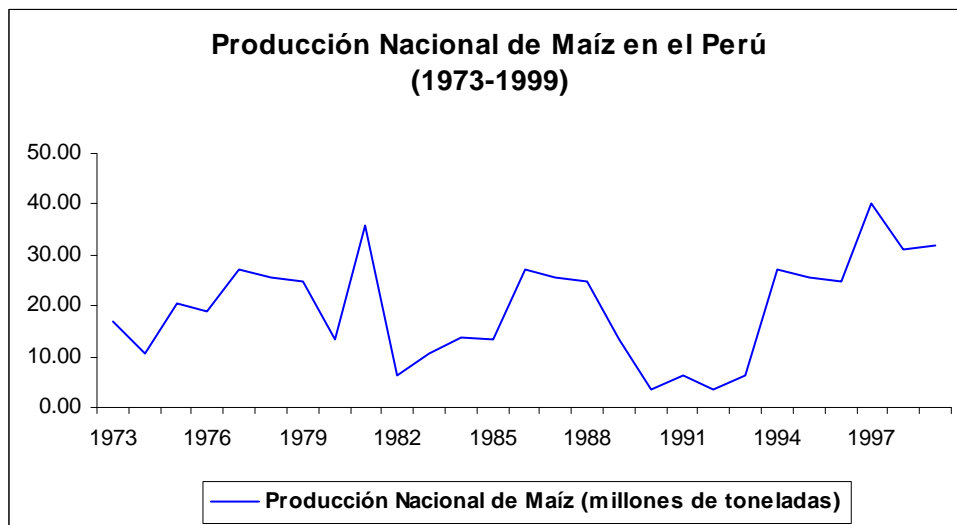


Fuente: INEI Ciclos Económicos.

C. **Componente estacional:** Oscilaciones que se producen en la serie en períodos iguales o inferiores a un año, y que reproducen de manera sistemática y reconocible en los diferentes años.



D. **Componente irregular:** Movimientos con carácter aperiódico, puramente aleatorio, que no se rigen por ningún patrón determinado.



Todos estos componentes son no observables, por lo que habrá que estimarlos en base a una serie de técnicas específicas. En muchas ocasiones, no es fácil determinar cuál es el componente tendencial y cuál es el componente cíclico, por lo que algunos autores estudian estos dos componentes de forma conjunta.

LECCION 3

REPRESENTACIÓN DE UNA SERIE TEMPORAL

En primer lugar se tiene que advertir por lo anteriormente señalado que es necesario descomponer una serie temporal, por una sencilla razón: queremos extraer la información que contiene la serie para utilizar posteriormente esta información (generalmente, para análisis estructural o predicción). Así, si queremos conocer el comportamiento a muy largo plazo de una serie, nos interesa eliminar, extraer los componentes de más corto plazo y quedarnos con el componente tendencial. En cambio, si estamos interesados en conocer la evolución a más corto plazo de la serie, lo que haremos será eliminar el componente tendencial para observar más claramente los componentes cíclico y estacional.

Modelos de descomposición:

Un modelo clásico para una serie de tiempo, supone que una serie $Y(1), \dots, Y(n)$ puede ser expresada como suma o producto de cuatro componentes: tendencia, ciclo, estacionalidad, y un término de error aleatorio.

Existen tres modelos de series de tiempos, que generalmente se aceptan como buenas aproximaciones a las verdaderas relaciones, entre los componentes de los datos observados, estos son:

1. Aditivo: $Y(t) = T(t) + E(t) + C(t) + A(t)$
2. Multiplicativo: $Y(t) = T(t) \times E(t) \times C(t) \times A(t)$
3. Mixto: $Y(t) = T(t) \times E(t) \times C(t) + A(t)$

Donde:

$Y(t)$ serie observada en instante t

$T(t)$ componente de tendencia

$E(t)$ componente estacional

$C(t)$ componente cíclico

$A(t)$ componente aleatoria (irregular)

Una suposición usual es que $A(t)$ sea una componente aleatoria o ruido blanco con media cero y varianza constante.

Un modelo aditivo (1), es adecuado, por ejemplo, cuando $E(t)$ no depende de otras componentes, como $T(t)$, sí por el contrario la estacionalidad varía con la tendencia, el modelo más adecuado es un modelo multiplicativo (2). Es claro que el modelo 2 puede ser transformado en aditivo, tomando logaritmos. El problema que se presenta, es modelar adecuadamente las componentes de la serie.

La figura 2.1 ilustra posibles patrones que podrían seguir series representadas por los modelos (1), (2) y (3).




Figura 2.1

Modelo de tendencia determinista: se presenta cuando la variable crece linealmente respecto del tiempo a una tasa constante:

$$Y_t = \beta_0 + \beta_1 t + \mu_t, \quad t = 1, 2, \dots, T$$

Donde β_0 es una constante, β_1 representa la tasa de crecimiento de Y_t a lo largo del tiempo y μ_t es una variable aleatoria que engloba a los demás componentes de la serie temporal. En este modelo, los parámetros β_0 y β_1 son parámetros desconocidos y los estimamos en base a las técnicas de regresión lineal. Una vez obtenidas las estimaciones de β_0 y β_1 calculamos las estimaciones de los componentes tendencial y no tendencial de la serie:

$$\text{Componente tendencial: } \hat{T}_t = \hat{\beta}_0 + \hat{\beta}_1 t$$

$$\text{Componente no tendencial: } Y_t - \hat{T}_t = \hat{\mu}_t$$

Ejemplos de modelos usuales con tendencia determinista son:

$$Z_t = a_0 + a_1 + \mu_t$$

$$Z_t = a_0 + a_1 t + a_2 t^2 + \dots + a_n t^n + \mu_t$$

En el caso de un polinomio de grado n , los estadísticos: “t-Student” y la “prueba F” son instrumentos para determinar el grado del polinomio, con la prueba “t” se analiza si “ a_n ” es cero en cuyo caso se estima el polinomio de grado $n-1$ y se vuelve a hacer la prueba sobre la significación del parámetro “ a_{n-1} ”. La prueba termina con el primer coeficiente significativo el cual es el grado del polinomio.

No es correcto pensar que toda serie evolutiva, con ajustarle un polinomio y quedarse con los residuos ya se logra una adecuada serie estacionaria en varianza, esto se logra solo con las series estacionarias en tendencia (trend stationary) hay otra familia muy importante la cual se hace estacionaria utilizando diferencias (difference stationary).

Modelo de tendencia cuadrática: se supone que la variable Y_t no crece a una tasa constante a lo largo del tiempo:

$$Y_t = \beta_0 + \beta_1 t + \beta_2 t^2 + \mu_t, \quad t=1,2,\dots,T$$


En este caso, el componente tendencial ya no es una línea recta, sino una curva cóncava o convexa, dependiendo del signo de los parámetros.

Cuando $\beta_2 > 0$ este modelo impone una tendencia convexa, con una tasa de crecimiento para la variable que aumenta según pasa el tiempo (es decir, según pasa el tiempo, la variable crece en mayor magnitud). En cambio, cuando $\beta_2 < 0$, este modelo impone una tendencia cóncava, con una tasa de crecimiento para la variable que disminuye según pasa el tiempo.

Un componente tendencial de este tipo es más realista que un comportamiento tendencial lineal. Así, en muchas ocasiones, observamos que la tendencia de una serie temporal no crece siempre a la misma tasa (como sería el caso de una tendencia lineal), sino que al principio su tasa de crecimiento es mayor que en los últimos años, lo que se representa mejor con una tendencia cuadrática cóncava, ejemplos de este comportamiento son series como el PIB, Consumo Privado, etc.

Ejemplo Ilustrativo: Índice de Volumen Físico mensual de la producción Industria de Bebidas en el Perú entre diciembre de 1993 y junio de 1997.

AÑO \ MES	ENE	FEB	MAR	ABR	MAY	JUN	JUL	AGO	SEP	OCT	NOV	DIC
1993												176.6
1994	190.1	162.3	184.2	165.4	141.6	130.2	148.7	150.7	154.7	165.9	165.0	197.1
1995	187.9	181.0	199.8	161.5	158.0	149.2	157.7	150.4	160.2	151.2	161.4	209.5
1996	192.6	172.7	177.9	160.8	167.4	124.3	141.7	148.6	151.4	157.6	159.5	195.4
1997	194.8	175.0	184.0	180.4	185.5	184.6						



Pronósticos

Proviene del griego prognôstikon. Conjetura acerca de lo que puede suceder.

Denominamos **pronósticos** a las estimaciones de valores futuros de la variable en función del comportamiento pasado de la serie. Este proceso se emplea ampliamente en el campo de la ingeniería y de la economía, incluyendo en esta última rama también la sanidad pública y la vigilancia de la salud. Así por ejemplo, los pronósticos provenientes de modelos basados en la teoría de series temporales, puede servir para una buena planificación de recursos sanitarios, en función de la demanda que se espera en el futuro, prevista por el modelo. Otro de los campos en los que se aplica la predicción mediante series temporales es el de la meteorología o en la predicción de otros fenómenos naturales.

Los pronósticos son una de las herramientas fundamentales para la toma de dediciones dentro de las organizaciones tanto productivas como sin fines de lucro. Algunas de las áreas de la industria en donde se utilizan pronósticos son la planeación y control de inventarios, producción, finanzas, ventas, comercialización, entre muchas otras.

Objetivo de un Pronóstico

Reducir la incertidumbre acerca de lo que puede acontecer en el futuro proporcionando información cercana a la realidad que permita tomar decisiones sobre los cursos de acción a tomar tanto en el presente como en el futuro.

LECCIÓN 4

MODELOS AUTORREGRESIVOS

Los modelos autorregresivos son aquellos en los cuales el Y_t depende de sus valores pasados hasta un cierto periodo y de un error aleatorio el cual es un ruido blanco. Un proceso autorregresivo de orden “p” esta representado por:

$$Y_t = \beta_1 Y_{t-1} + \beta_2 Y_{t-2} + \mu_t$$

El cual es representado por las siglas AR(p).

Si en los modelos autorregresivos se incluyen a las variables dependientes rezagadas como explicativas, la serie tendría la forma siguiente:

$$Y_t = \beta_1 + \beta_2 X_t + \beta_3 Y_{t-1} + \mu_t$$

Los modelos de rezagos distribuidos sólo trabajan con los rezagos de las variables independientes, con lo cual serán de la forma:

$$Y_t = \alpha + \beta_0 X_t + \beta_1 X_{t-1} + \beta_2 X_{t-2} + \beta_3 X_{t-3} + \dots + \mu_t$$

1. SIGNIFICADO DE LOS PARAMETROS

Sea el siguiente modelo de rezagos distribuidos:

$$Y_t = \alpha + \beta_0 X_t + \beta_1 X_{t-1} + \dots + \beta_k X_{t-k} + \mu_t$$

Se tendrá que:

β_0 : Es el multiplicador de corto plazo.

$\beta_1, \beta_2 \dots \beta_k$: Miden el impacto en el valor medio de Y debido a un cambio unitario en X, en varios periodos anteriores de tiempo

$\beta = \sum_{i=0}^k \beta_i = \beta_0 + \beta_1 + \dots + \beta_k$: Es el multiplicador de largo plazo o total, con rezagos distribuidos tal que la suma β exista.

La mediana de rezagos. Es el tiempo transcurrido para que se sienta la primera mitad del cambio total, en la variable dependiente.

Retardo promedio. Es el promedio ponderado de todos los rezagos involucrados, actuando los coeficientes β como ponderaciones.

2. METODOLOGÍA DE KOYCK

Se tiene:

$$Y_t = \alpha + \beta_0 X_t + \beta_1 X_{t-1} + \beta_2 X_{t-2} + \dots + \mu_t \quad (4)$$

Asumiendo que las β tienen igual signo, Koyck supone que éstas disminuyen geométricamente así:

$$\beta_k = \beta_0 \lambda^k \quad k = 0, 1, \dots \text{ y } 0 < \lambda < 1 \quad (5)$$

Donde:

λ : Tasa de disminución o decaimiento del rezago distribuido

$1 - \lambda$: Velocidad del ajuste

Por lo dicho anteriormente, considerar (5) implica afirmar que a medida que se retrocede hacia el pasado, el efecto de ese rezago sobre Y_t se hace progresivamente más pequeño, lo cual es un supuesto bastante factible. Por lo tanto:

$\lambda = 1$ indica una lenta disminución de β_k

$\lambda = 0$ indica que rápidamente declinará β_k

Características:

- Asumiendo que no existen valores negativos para λ , Koyck elimina el cambio de signo para valores de β .
- Al suponer $\lambda < 1$ Koyck le asigna menos importancia a los β lejanos que a los actuales.
- Asegura que el multiplicador a largo plazo es $\sum_{k=0}^{\infty} \beta_k = \beta_0 \left(\frac{1}{1-\lambda} \right)$

Para la estimación del modelo, Koyck propone lo siguiente:

Reemplazando (5) en (4) resulta:

$$Y_t = \alpha + \beta_0 X_t + \beta_0 \lambda X_{t-1} + \beta_0 \lambda^2 X_{t-2} + \dots + \mu_t \quad (6)$$

$$Y_{t-1} = \alpha + \beta_0 X_{t-1} + \beta_0 \lambda X_{t-2} + \beta_0 \lambda^2 X_{t-3} + \dots + \mu_{t-1} \quad (7)$$

$$\lambda Y_{t-1} = \lambda \alpha + \lambda \beta_0 X_{t-1} + \beta_0 \lambda^2 X_{t-2} + \beta_0 \lambda^3 X_{t-3} + \dots + \lambda \mu_{t-1} \quad (8)$$

Restando (6) - (8)

$$Y_t - \lambda Y_{t-1} = \alpha(1-\lambda) + \beta_0 X_t + v_t \quad (9)$$

Reordenando:

$$Y_t = \alpha(1-\lambda) + \beta_0 X_t + \lambda Y_{t-1} + v_t \quad (10)$$

Donde: $v_t = (\mu_t - \lambda \mu_{t-1})$.

Con lo cual en este modelo no existe razón alguna para la presencia de multicolinealidad.

Ejemplo Ilustrativo 1:

Un empresario desea estimar el costo final de elaboración del producto (Y_t), en función del precio de la materia prima utilizada (X_t), aplicar el método de Koych para la estimación del modelo apropiado:

VARIABLE	COEFFICIENT	STD. ERROR	T-STAT.	2-TAIL SIG.
C	-3.4256310	1.8380160	-1.8637656	0.0808
X	1.1724286	0.1577726	7.4311299	0.0000
Y(-1)	0.4113484	0.1046733	3.9298327	0.0012
R-squared	0.993959	Mean of dependent var		78.64663
Adjusted R-squared	0.993203	S.D. of dependent var		28.10132
S.E. of regression	2.316718	Sum of squared resid		85.87489
Log likelihood	-41.29013	F-statistic		1316.189
Durbin-Watson stat	1.470146	Prob(F-statistic)		0.000000

Solución

Haciendo uso de los resultados obtenidos mediante E-Views:
De la tabla anterior tenemos que el modelo sería:

$$\hat{Y} = -3.426 + 1.172X_t + 0.411Y_{t-1}$$

Ajustando al Modelo de Koych que tiene la forma:

$$Y_t = \alpha(1-\lambda) + \beta_0 X_t + \lambda Y_{t-1} + (\mu_t - \lambda \mu_{t-1})$$

Por lo tanto tendremos que $\alpha(1-\hat{\lambda})$ es -3.426, el multiplicador de impacto de Corto Plazo β_0 es 1.172 y la tasa de crecimiento de los valores de los parámetros $\hat{\lambda}$ es 0.411, luego.

$$\alpha = \frac{-3.426}{(1-0.411)} = -5.87$$

Además la velocidad del ajuste $(1-\lambda)$ es 0.589

El multiplicador (de largo Plazo) es:

$$\sum_{k=0}^{\infty} \beta_k = \beta_0 \left(\frac{1}{1-\lambda} \right) = 1.172 \frac{1}{1-0.411} = \frac{1.172}{0.589} = 1.9$$

El modelo original será:

$$\hat{Y}_t = -5.87 + 1.172X_t + 1.172 * (0.411)^1 X_{t-1} + 1.172 * (0.411)^2 X_{t-2} + \dots$$

Ejemplo Ilustrativo 2:

Se piensa que el nivel de inversión de una empresa de calzado (I_t), está en relación con el volumen de ventas y la inversión realizada el año anterior (I_{t-1}), utilice el método de Koych para estimar el modelo.

VARIABLE	COEFFICIENT	STD. ERROR	T-STAT.	2-TAIL SIG.
C	-42.531978	15.038641	-2.8281797	0.0095
V	0.8163127	0.0217806	37.478804	0.0000
I(-1)	0.7425750	0.0024349	304.96817	0.0000
R-squared	0.999963	Mean of dependent var		2623.571
Adjusted R-squared	0.999959	S.D. of dependent var		360.3023
S.E. of regression	2.296862	Sum of squared resid		121.3383
Log likelihood	-56.91872	F-statistic		307579.8
Durbin-Watson stat	0.446756	Prob(F-statistic)		0.000000

Solución

Por lo dicho en el ejercicio anterior, tenemos:

$$\hat{I} = -42.532 + 0.816V_t + 0.742I_{t-1}$$

Además tendremos que $\alpha(1 - \hat{\lambda})$ es -42.532, el multiplicador de impacto de Corto Plazo $\hat{\beta}_0$ es 0.816 y la tasa de crecimiento de los valores de los parámetros $\hat{\lambda}$ es 0.742, luego

$$\alpha = \frac{-42.532}{(1 - 0.742)} = -164.853$$

Además la velocidad del ajuste $(1 - \lambda)$ es 0.258

El multiplicador (de largo Plazo) es:

$$\sum_{k=0}^{\infty} \beta_k = \beta_0 \left(\frac{1}{1 - \lambda} \right) = 0.816 \frac{1}{1 - 0.742} = \frac{0.816}{0.258} = 3.163$$

Finalmente, el modelo original será:

$$\hat{I}_t = -42532 + 0.816V_t - 0.816(0.816)^2 V_{t-1} + \dots$$

LECCIÓN 5

MODELOS CON REZAGOS DISTRIBUIDOS

Siguiendo el teorema de Weierstrass, Almon supone que β_i puede ser aproximado mediante un polinomio en i , la longitud del rezago¹ de un grado apropiado.

Por ejemplo, si el esquema de rezagos es de orden 1 (lineal), el puede ser aproximado mediante $\beta_i = a_0 + a_1i$ (figura 1. a)

Suponiendo una Ley Parabólica, los β_i puede definirse mediante el siguiente polinomio:

$$\beta_i = a_0 + a_1i + a_2i^2 \quad (1)$$

que es un polinomio cuadrático o de segundo grado en i (véase figura 1.b).

Sin embargo si los β sigue el patrón de la figura 1.c. se puede escribir como sigue:

$$\beta_i = a_0 + a_1i + a_2i^2 + a_3i^3$$




Figura 1.a




Figura 1.b




Figura 1.c

Suponiendo un polinomio de grado i -ésimo, es decir una ecuación de grado i -ésimo, cada β_i tendría la siguiente estructura:

$$\beta_i = a_0 + a_1i + a_2i^2 + a_3i^3 + \dots + a_\gamma i^\gamma$$

a. Supongamos que se acepta que los β_i siguen una Ley de segundo grado:

$$\beta_i = a_0 + a_1i + a_2i^2$$

Cuando $i = 0$ $\beta_0 = a_0 + a_1(0) + a_2(0)^2 \Rightarrow \beta_0 = a_0$

Cuando $i = 1$ $\beta_1 = a_0 + a_1(1) + a_2(1)^2 \Rightarrow \beta_1 = a_0 + a_1 + a_2$

¹ En términos generales, el teorema plantea que en un intervalo cerrado finito, cualquier función continua puede ser aproximada uniformemente mediante un polinomio de un grado apropiado.

Cuando $i = 2$ $\beta_2 = a_0 + a_1(2) + a_2(2)^2 \Rightarrow \beta_2 = a_0 + 2a_1 + 4a_2$

Cuando $i = 3$ $\beta_3 = a_0 + a_1(3) + a_2(3)^2 \Rightarrow \beta_3 = a_0 + 3a_1 + 9a_2$

Cuando $i = 4$

$$\beta_4 = a_0 + a_1(4) + a_2(4)^2 \Rightarrow \beta_4 = a_0 + 4a_1 + 16a_2$$

$$\beta_k = a_0 + ka_1 + k^2a_2$$

Reemplazando en la fórmula general:

$$Y_t = \alpha + \sum (a_0 + a_1i + a_2i^2)X_{t-i} + \mu_t$$

$$Y_t = \alpha + a_0 \sum X_{t-i} + a_1 \sum iX_{t-i} + a_2 \sum i^2 X_{t-i} + \mu_t$$

b. **Si fuera Lineal:** $\beta_i = a_0 + a_1i$

Entonces:

$$\beta_0 = a_0$$

$$\beta_1 = a_0 + a_1$$

$$\beta_2 = a_0 + a_1(2) \Rightarrow \beta_2 = a_0 + 2a_1$$

$$\vdots$$

$$\beta_n = a_0 + a_1(n) \Rightarrow \beta_n = a_0 + na_1$$

Reemplazando en la fórmula general:

$$Y_t = \alpha + \sum (a_0 + a_1i)X_{t-i} + \mu_t$$

$$Y_t = \alpha + a_0 \sum X_{t-i} + a_1 \sum iX_{t-i} + \mu_t$$

c. **Si fuera de grado “ γ ”, se tendría:** $\beta_i = a_0 + a_1i + a_2i^2 + \dots + a_\gamma i^\gamma$

Reemplazando en la fórmula general: $Y_t = \alpha + \sum \beta_i X_{t-i} + \mu_t$

$$Y_t = \alpha + \sum_{i=0}^k (a_0 + a_1i + a_2i^2 + \dots + a_\gamma i^\gamma) X_{t-i} + \mu_t$$

$$Y_t = \alpha + a_0 \sum_{i=0}^k X_{t-i} + a_1 \sum_{i=0}^k iX_{t-i} + a_2 \sum_{i=0}^k i^2 X_{t-i} + \dots + a_\gamma \sum_{i=0}^k i^\gamma X_{t-i} + \mu_t$$

$$Y_t = \alpha + a_0 Z_{0t} + a_1 Z_{1t} + \dots + a_\gamma Z_{\gamma t} + \mu_t$$

Donde:

$$\begin{aligned}
Z_{0t} &= \sum_{i=0}^k X_{t-i} \\
Z_{1t} &= \sum_{i=0}^k iX_{t-i} \\
Z_{2t} &= \sum_{i=0}^k i^2X_{t-i} \\
&\vdots \\
Z_{\gamma t} &= \sum_{i=0}^k i^\gamma X_{t-i}
\end{aligned}$$

La aplicación directa en esta última expresión de M.C.O. sobre las variables transformadas, permite el cálculo de a_i y, a partir de las relaciones establecidas, de β_i .

Ejercicio Ilustrativo 1:

Con información del Consumo Privado (CP) y del Producto Bruto Interno (PBI), ambos en valores constantes de 1994 del periodo 1970-2001 se plantea la construcción de un modelo donde “Z”.

a. Supongamos que fuese una ecuación polinómica de segundo grado con 2 rezagos.

$$CP_t = \alpha + \beta_0 PBI_t + \beta_1 PBI_{t-1} + \beta_2 PBI_{t-2} + \mu_t$$

1. Modelo :

$$CP_t = \alpha + \beta_0 PBI_t + \beta_1 PBI_{t-1} + \beta_2 PBI_{t-2} + \mu_t$$

$$CP_t = \alpha + \sum_{i=0}^2 \beta_i PBI_{t-i} + \mu_t$$

2. **Supuesto:** Los β_i pueden ser aproximados mediante un polinomio cuadrático.

$$\beta_i = a_0 + a_1 i + a_2 i^2$$

$$CP_t = \alpha + \sum_{i=0}^2 (a_0 + a_1 i + a_2 i^2) PBI_{t-i} + \mu_t$$

$$CP_t = \alpha + a_0 \sum_{i=0}^2 PBI_{t-i} + a_1 \sum_{i=0}^2 i PBI_{t-i} + a_2 \sum_{i=0}^2 i^2 PBI_{t-i} + \mu_t$$

$$CP_t = \alpha + a_0 Z_{0t} + a_1 Z_{1t} + a_2 Z_{2t} + \mu_t$$

3. Datos Transformados:

$$Z_{0t} = PBI_t + PBI_{t-1} + PBI_{t-2}$$

$$Z_{1t} = 0PBI_{t-0} + 1PBI_{t-1} + 2PBI_{t-2} = PBI_{t-1} + 2PBI_{t-2}$$

$$Z_{2t} = 0PBI_{t-0} + 1^2PBI_{t-1} + 2^2PBI_{t-2} = PBI_{t-1} + 4PBI_{t-2}$$

4. Parámetros estimados:

$$\hat{\beta}_0 = \bar{a}_0$$

$$\hat{\beta}_1 = \bar{a}_0 + \bar{a}_1 + \bar{a}_2$$

$$\hat{\beta}_2 = \bar{a}_0 + 2\bar{a}_1 + 4\bar{a}_2$$

$$\beta_i = a_0 + a_1i + a_2i^2$$

Calculando el modelo en E-views, tenemos las siguientes salidas:

Dependent Variable: CP				
Method: Least Squares				
Date: 09/06/02 Time: 18:12				
Sample(adjusted): 1972 2001				
Included observations: 30 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	7227.737	1909.824	3.784505	0.0008
Z _{0t}	0.588144	0.060757	9.680230	0.0000
Z _{1t}	-0.456263	0.297715	-1.532551	0.1375
Z _{2t}	0.052527	0.148043	0.354808	0.7256
R-squared	0.978526	Mean dependent var	68763.83	
Adjusted R-squared	0.976048	S.D. dependent var	10331.93	
S.E. of regression	1599.017	Akaike info criterion	17.71573	
Sum squared resid	66478265	Schwarz criterion	17.90256	
Log likelihood	-261.7360	F-statistic	394.9164	
Durbin-Watson stat	0.900879	Prob(F-statistic)	0.000000	

El R² es alto, pero los Z_{1t} y CZ_{2t} no son relevantes por que sus parámetros no son significativos. Sus probabilidades asociadas son mayores al nivel de significancia (5%), por lo tanto se acepta la Ho de no significancia de sus parámetros.

$$\hat{CP}_t = 7227.737 + 0.588144ACZ_{0t} - 0.456263ACZ_{1t} + 0.052527ACZ_{2t}$$

b. Trabajando con una ecuación polinómica de tercer grado con 3 rezagos.

$$Y_t = \alpha + \sum \beta_i X_{t-i} + \mu_t$$

Reemplazando en el ejemplo:

$$CP_t = \alpha + a_0 \sum_{i=0}^3 PBI_{t-i} + a_1 \sum_{i=0}^3 iPBI_{t-i} + a_2 \sum_{i=0}^3 i^2 PBI_{t-i} + a_3 \sum_{i=0}^3 i^3 PBI_{t-i}$$

$$Z_{0t} = PBI_t + PBI_{t-1} + PBI_{t-2} + PBI_{t-3} \qquad Z_{0t} = \sum_{i=0}^3 PBI_{t-i}$$

$$Z_{1t} = PBI_{t-1} + 2PBI_{t-2} + 3PBI_{t-3} \qquad Z_{1t} = \sum_{i=0}^3 iPBI_{t-i}$$

$$Z_{2t} = PBI_{t-1} + 4PBI_{t-2} + 9PBI_{t-3} \qquad Z_{2t} = \sum_{i=0}^3 i^2 PBI_{t-i}$$

$$Z_{3t} = PBI_{t-1} + 8PBI_{t-2} + 27PBI_{t-3} \qquad Z_{3t} = \sum_{i=0}^3 i^3 PBI_{t-i}$$

Donde:

$$\beta_i = a_0 + a_1 i + a_2 i^2 + a_3 i^3$$

A continuación, se tiene las series del PBI y Consumo privado y la serie transformada del PBI:

obs	CP	PBI	Z _{0t}	Z _{1t}	Z _{2t}	Z _{3t}
1970	48904.00	62022.00	NA	NA	NA	NA
1971	50372.00	64627.00	NA	NA	NA	NA
1972	51178.00	66501.00	NA	NA	NA	NA
1973	53278.00	70092.00	263242.0	381821.0	883207.0	2258111.0
1974	58435.00	76611.00	277831.0	396975.0	917739.0	2347029.0
1975	59244.00	79215.00	292419.0	416298.0	955488.0	2432874.0
1976	60633.00	80800.00	306718.0	442713.0	1016487.0	2584587.0
1977	60768.00	81123.00	317749.0	469063.0	1087159.0	2783017.0
1978	59131.00	81366.00	322504.0	480368.0	1117258.0	2866328.0
1979	61760.00	86086.00	329375.0	486012.0	1133058.0	2911950.0
1980	64822.00	90562.00	339137.0	492187.0	1141657.0	2927335.0
1981	68283.00	95181.00	353195.0	506832.0	1167200.0	2976132.0
1982	68880.00	94610.00	366439.0	534563.0	1232203.0	3143999.0
1983	62814.00	83446.00	363799.0	556658.0	1290392.0	3301232.0
1984	64029.00	87785.00	361022.0	558209.0	1318515.0	3410213.0
1985	65382.00	90243.00	356084.0	538507.0	1273059.0	3309823.0
1986	75148.00	99267.00	360741.0	516151.0	1192397.0	3045565.0
1987	82526.00	107208.0	384503.0	543108.0	1250304.0	3191406.0
1988	76418.00	97881.00	394599.0	576471.0	1316463.0	3337905.0
1989	63358.00	86429.00	390785.0	610098.0	1420116.0	3635754.0
1990	61814.00	81983.00	373501.0	603815.0	1442825.0	3764093.0
1991	62990.00	83760.00	350053.0	548484.0	1308628.0	3416202.0
1992	62788.00	83401.00	335573.0	507013.0	1189553.0	3073207.0
1993	64935.00	87375.00	336519.0	496870.0	1156288.0	2967022.0
1994	71306.00	98577.00	353113.0	505457.0	1174819.0	3016103.0
1995	78198.00	107039.0	376392.0	523530.0	1198686.0	3049404.0
1996	80584.00	109709.0	402700.0	566318.0	1287722.0	3254780.0
1997	84081.00	117110.0	432435.0	619518.0	1425058.0	3627600.0
1998	83376.00	116485.0	450343.0	657645.0	1519297.0	3884835.0
1999	83056.00	117590.0	460894.0	679832.0	1572306.0	4015508.0
2000	86289.00	121267.0	472452.0	701890.0	1637520.0	4211440.0
2001	87411.00	121490.0	476832.0	705902.0	1639992.0	4207082.0

El modelo planteado sería el siguiente: $CP_t = \alpha + a_0Z_{0t} + a_1Z_{1t} + a_2Z_{2t} + a_3Z_{3t}$

Los resultados son:

Dependent Variable: CP				
Method: Least Squares				
Date: 07/05/02 Time: 18:19				
Sample(adjusted): 1973 2001				
Included observations: 29 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
Z _{0t}	0.589702	0.064874	9.089887	0.0000
Z _{1t}	-0.390550	0.572711	-0.681933	0.5018
Z _{2t}	-0.061712	0.532320	-0.115931	0.9087
Z _{3t}	0.041838	0.117976	0.354633	0.7260
C	7268.342	2180.323	3.333607	0.0028
R-squared	0.976065	Mean dependent var		69370.24
Adjusted R-squared	0.972076	S.D. dependent var		9956.667
S.E. of regression	1663.821	Akaike info criterion		17.82721
Sum squared resid	66439231	Schwarz criterion		18.06295
Log likelihood	-253.4945	F-statistic		244.6760
Durban-Watson stat	0.885465	Prob(F-statistic)		0.000000

Aunque R^2 es bueno Z_{1t} , Z_{2t} y Z_{3t} no son relevantes, sus parámetros no son significativos, ya que sus probabilidades asociadas son mayores al nivel de significancia (5%), por lo tanto se acepta la H_0 de no significancia de sus parámetros.

$$\hat{CP}_t = 7268.342 + 0.589702Z_{0t} - 0.390550Z_{1t} - 0.061712Z_{2t} + 0.041838Z_{3t}$$

$$\beta_0 = a_0 \qquad \beta_0 = 0.589702$$

$$\beta_1 = a_0 + a_1 + a_2 + a_3 \qquad \beta_1 = 0.179278$$

$$\beta_2 = a_0 + 2a_1 + 2^2a_2 + 2^3a_3 \qquad \beta_2 = -0.103542$$

$$\beta_3 = a_0 + 3a_1 + 3^2a_2 + 3^3a_3 \qquad \beta_3 = -0.00773$$

$$Y_t = 7268.342 + 0.589702X_t + 0.179278X_{t-1} - 0.103542X_{t-2} - 0.00773X_{t-3}$$

c. Modelo Lineal y con 2 Rezagos

$$CP_t = \alpha + \sum_{i=1}^2 \beta_i PBI_{t-i} = \alpha + a_0 \sum_{i=1}^2 PBI_{t-i} + a_1 \sum_{i=1}^2 iPBI_{t-i}$$

$$Z_{0t} = PBI_t + PBI_{t-1} + PBI_{t-2} \qquad Z_{0t} = \sum_{i=0}^2 PBI_{t-i}$$

$$Z_{1t} = PBI_{t-1} + 2PBI_{t-2} \qquad Z_{1t} = \sum_{i=0}^2 iPBI_{t-i}$$

$$\beta_i = a_0 + a_1i$$

Calculando el modelo en el e-views, tenemos:

Dependent Variable: CP				
Method: Least Squares				
Date: 09/06/02 Time: 18:14				
Sample(adjusted): 1972 2001				
Included observations: 30 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	7358.531	1843.326	3.991985	0.0005
Z _{0t}	0.570238	0.033282	17.13362	0.0000
Z _{1t}	-0.351296	0.032803	-10.70932	0.0000
R-squared	0.978422	Mean dependent var	68763.83	
Adjusted R-squared	0.976823	S.D. dependent var	10331.93	
S.E. of regression	1572.921	Akaike info criterion	17.65390	
Sum squared resid	66800144	Schwarz criterion	17.79402	
Log likelihood	-261.8084	F-statistic	612.1291	
Durbin-Watson stat	0.949942	Prob(F-statistic)	0.000000	

La bondad de ajuste es alta ($R^2 = 97.8\%$) y los Z_{0t} , y Z_{1t} son relevantes en el modelo. Evaluando sus probabilidades asociadas, estas son inferiores al nivel de significancia del 5%, por lo tanto se rechaza la H_0 de no significancia de los parámetros. Ello aunado a una probabilidad conjunta del modelo (F-statistic) menor a su nivel de significancia, nos indica que el modelo es bueno.

$$\hat{CP}_t = 7358.531 + 0.570238ALZ_{0t} - 0.351296ALZ_{1t}$$

Despejando tenemos:

$$\hat{Y} = 7358.531 + 0.570238X_t + 0.218942X_{t-1} - 0.132351X_{t-2}$$

Ejercicios de Autoconocimiento

¿Por qué debo usar de las series temporales como métodos de predicción?

CRITERIOS	SI	NO	NO SÉ
1. Porque considero que es una técnica importante que ayuda a una buena toma de decisiones empresariales.			
2. Porque me permite detectar un comportamiento particular del caso estudiado.			
3. Por la presencia de un gran número de datos volátiles.			
4. Para hacer estimaciones a largo plazo de la variable.			
5. Para eliminar las fluctuaciones de la serie que no permiten observar su verdadero comportamiento.			
6. Porque poseo una gran cantidad de información acerca de la serie (información de largo plazo)			
7. Para poseer una idea clara acerca del comportamiento general de la variable			
8. Porque hace uso de todos los elementos que constituyen a la serie.			
9. Porque son un medio efectivo de para realizar predicciones.			
10. Para eliminar los picos pronunciados en la gráfica de la serie (aplanar las variaciones considerables en la serie).			

CALIFICACION

Puntuar con un punto cada respuesta “SI”.

Si obtienes de de 1 - 3 puntos tienes pocas expectativas de hacer una buena predicción empresarial usando las series temporales.

Si tienes entre 4 – 7, tienes buenas expectativas de hacer una buena predicción empresarial usando las series temporales.

Y si tienes entre 8 – 10, denotas excelentes expectativas de hacer una buena predicción empresarial usando las series temporales.

RESUMEN

Series de tiempo es un conjunto de mediciones (datos o números), relativos a un fenómeno (p.ej. precios de la bolsa), tomados a intervalos regulares de tiempo (cada mes, cada semana, cada año, etc.).

Proceso estocástico es la secuencia ordenada de variables aleatorias $Y(t)$, es decir, la sucesión de variables aleatorias ordenadas $Y_1, Y_2 \dots Y_T$, las cuales constituyen en su conjunto lo que se conoce como una serie temporal.

Estacionariedad es cuando analizamos una serie de tiempo nos referimos a una variable medida en diferentes momentos $\{Y_{t1}, Y_{t2}, \dots, Y_{tn}\}$, por lo cual es de suponer que cada Y_{ti} pueda tener diferente distribución, por ello la condición de estacionariedad plantea que las variables aleatorias que componen una serie temporal estén idénticamente distribuidas.

Los componentes de una serie temporal, se pueden dividir:

Componente tendencial: Movimiento general a largo plazo de la serie, se observa en una serie con un comportamiento determinado ya sea creciente o decreciente.

Componente cíclico: Oscilaciones que se producen en la serie en períodos superiores a un año; en muchas ocasiones, la serie muestra más de un ciclo, superponiéndose éstos entre sí, lo que hace difícil determinar este componente.

Componente estacional: Oscilaciones que se producen en la serie en períodos iguales o inferiores a un año, y que reproducen de manera sistemática y reconocible en los diferentes años.

Componente irregular: Movimientos con carácter aperiódico, puramente aleatorio, que no se rigen por ningún patrón determinado.

El primer paso para analizar una serie de tiempo es graficarla, esto permite: identificar la tendencia, la estacionalidad, las variaciones irregulares (componente aleatoria).

Un modelo clásico para una serie de tiempo, puede ser expresada como suma o producto de tres componentes: tendencia, estacional y un término de error aleatorio.

Existen tres modelos de series de tiempos, estos son: Aditivo, Multiplicativo y Mixto.

De los modelos más conocidos, se ha tratado con los autoregresivos y lo de rezagos distribuidos, en donde el primero la variable dependiente esta en función de sus valores pasados mientras que el segundo de los rezagos de las variables independientes.

Resumen de fórmulas

- Proceso Estacionario en media : $E[Y_t] = \mu$

- Proceso estacionario en varianza :

$$E[Y_t] = \mu \quad \text{para toda } t$$

$$r(Y_t) = \sigma^2 \quad \text{para toda } t$$

$$\text{Cov}(Y_t, Y_{t-k}) = \emptyset(k) \quad \text{no depende de } t$$

- Ruido Blanco

$$E[\mu_t] = 0 \quad \text{media cero.}$$

$$\text{Var}(\mu_t) = \sigma^2 \quad \text{varianza constante.}$$

$$\text{Cov}(\mu_t, \mu_s) = 0 \quad \text{para } t \text{ diferente de } s.$$

- Modelos de descomposición:

Aditivo: $Y(t) = T(t) + E(t) + C(t) + A(t)$

Multiplicativo: $Y(t) = T(t) \times E(t) \times C(t) \times A(t)$

Mixto: $Y(t) = T(t) \times E(t) \times C(t) + A(t)$

- Modelo de tendencia determinista

$$Y_t = \beta_0 + \beta_1 t + \mu_t \quad , \quad t = 1, 2, \dots, T$$

Componente tendencial: $T_t = \hat{\beta}_0 + \hat{\beta}_1 t$

Componente no tendencial: $Y_t - \hat{T}_t = \hat{\epsilon}_t$

- Modelo de tendencia cuadrática

$$Y_t = \beta_0 + \beta_1 t + \beta_2 t^2 + \mu_t$$

- Los modelos autorregresivos

$$Y_t = \beta_1 + \beta_2 X_t + \beta_3 Y_{t-1} + \mu_t$$

- Modelos de Rezagos Distribuidos

$$Y_t = \alpha + \beta_0 X_t + \beta_1 X_{t-1} + \beta_2 X_{t-2} + \beta_3 X_{t-3} + \dots + \mu_t$$

- Multiplicador de Largo Plazo

$$\beta = \sum_{i=0}^K \beta_i = \beta_0 + \beta_1 + \dots + \beta_K = \beta_0(1/1 - \beta)$$

- Tasa de disminución o decaimiento del rezago distribuido : β
- Velocidad del ajuste : $1 - \beta$

EXPLORACION ON LINE

1. Análisis Clásico de Series Temporales

<http://www.einsteinnet.com/econometria/seriestemp/acseriestemp.htm>

2. “Introducción al análisis clásico de series de tiempo”

<http://ciberconta.unizar.es/LECCION/seriest/000F2.HTM>

LECTURA

MÉTODOS DE PREDICCIÓN

Debido a que siempre ha sido cambiante el mundo en el que operan las organizaciones, siempre ha existido la necesidad de hacer pronósticos.

Una nueva tecnología y nuevas disciplinas aparecieron de la noche a la mañana; la actividad gubernamental se intensificó; la competencia se hizo más cerrada; en casi todas las industrias se implantó el comercio internacional; crecieron y se crearon nuevas agencias de ayuda y servicios.

Con el desarrollo de técnicas de pronóstico más complejas, junto con el advenimiento de las computadoras, los pronósticos recibieron más atención durante los años recientes. Este desarrollo es en especial cierto desde la proliferación de la pequeña computadora personal. Ahora todos los administradores poseen la capacidad de utilizar técnicas de análisis de datos muy complejas para fines de pronóstico, y una comprensión de dichas técnicas es esencial hoy en día para los administradores de empresas.

Hoy en día al crecer la preocupación de los Administradores por el proceso de pronóstico, se continúan desarrollando nuevas técnicas de pronóstico. Esta atención se enfoca de manera particular en los errores, que son parte inherente de cualquier procedimiento de pronóstico, quienes pronostican solo pueden intentar que los inevitables errores sean tan pequeños.

Los métodos de elaboración de pronóstico básicamente se agrupan en métodos cualitativos y métodos cuantitativos. Los métodos cualitativos son altamente subjetivos y de criterio, son importantes cuando no se cuenta con información histórica como por ejemplo en el caso en que se quiere predecir las ventas de un producto nuevo. Los métodos cuantitativos por su parte, se pueden subdividir en series de tiempo y causales. Los causales incluyen la determinación de factores que se relacionan con la variable a predecir. En tanto los métodos de series de tiempo incluyen las proyecciones de valores futuros de una variable, basada completamente en observaciones pasadas. La suposición básica que en el análisis de series de tiempo se fundamenta en el principio de que los factores que han ocasionado patrones de actividad en el pasado y en el presente continuarán haciéndolo, más o menos de la misma forma, en el futuro. Por consiguiente, los principales objetivos del análisis de series de tiempo consisten en identificar y aislar tales factores de influencia con propósitos de hacer predicciones (pronósticos), así como para efectuar una planeación y un control administrativo.

Las técnicas de pronóstico son pues elementos de juicio en el proceso de pronóstico que deben emplearse por quienes toman las decisiones. ¿Quién requiere hacer pronósticos? Casi cualquier organización, grande y pequeña, pública y privada. De los métodos más utilizados y más conocidos para tratar a una serie de tiempo en la actualidad, son aquellos que permiten hacer un análisis detallado de los patrones de demanda en el pasado a lo largo del tiempo y para proyectar estos patrones hacia el futuro (proyección de la demanda).

La necesidad de hacer pronósticos cruza todas las líneas funcionales lo mismo que todo tipo de organizaciones. Se requiere hacer pronósticos en las áreas de finanzas, actividades ligadas al comercio y la producción, tanto en organizaciones gubernamentales como privadas.

Anónimo

ACTIVIDADES

1. ¿Qué movimiento característico se puede asociar a cada una de las situaciones siguientes:
 - a. Un retroceso
 - b. Un incremento de empleo durante los meses de verano
 - c. La demanda continuamente creciente de automóviles pequeños
 - d. Huelga en el sector industrial

Resp : (a) cíclico (b)estacional (c)tendencia largo plazo (d) irregular

2. La tabla mostrada representa el índice bursátil del sector financiero :
 - a. Haga el gráfico de la serie; ¿es estacionaria?
 - b. ¿Que comportamiento particular ha notado?

	1996	1997	1998	1999
Enero	211.46	211.46	100.00	228.90
Febrero	211.46	122.18	100.00	236.00
Marzo	211.46	137.60	100.00	236.00
Abril	211.46	137.98	100.00	236.00
Mayo	211.46	137.98	139.14	236.01
Junio	211.46	137.98	139.14	204.00
Julio	211.46	100.00	139.14	204.00
Agosto	211.46	100.00	138.48	204.02
Septiembre	211.46	100.02	134.10	204.02
Octubre	211.46	100.00	134.10	204.02
Noviembre	211.46	100.00	225.92	204.02
Diciembre	211.46	100.00	225.92	204.00

3. Emplear el esquema de retardos infinitos distribuidos geoméricamente (Koyck) para expresar una ecuación de consumo , para lo cual debe considerar un tasa de decaimiento del retardo geométrico de 0.4 y un multiplicador de impacto de 0.58
4. La tabla siguiente nos representa el consumo de energía eléctrica promedio por hogar (Kw/h) en Lima Metropolitana en los últimos 27 meses. Identificar su comportamiento
 - a. ¿Qué tipo de tendencia posee?
 - b. Una vez reconocida su tendencia, hallar la ecuación estimada que la representa (usando MCO)

CONSUMO DE ENERGÍA		
84.6	107.6	134.3
89.9	120.4	134.7
81.9	109.6	144.8
95.4	110.3	144.4
91.2	118.1	159.2
89.8	116.5	168.2
89.7	110.3	175.2
97.9	118.1	174.5
103.4	116.5	173.7

AUTOEVALUACIÓN

1. Cuál de los cuatro componentes de una serie de tiempo se usará para describir cada una de las situaciones siguientes :
 - a. El aumento de las ventas de helados en los meses de verano.
 - b. Un aumento de la producción de papas en el periodo marzo abril.
 - c. El efecto que las ventas navideñas ejercen sobre una tienda al menudeo.
 - d. El crecimiento y deterioro general de la industria pesquera en el Perú durante los últimos 50 años.
 - I. Componente tendencial
 - II. Componente cíclico
 - III. Componente estacional
 - IV. Componente irregular

2. Establezca la verdad o falsedad de cada una de las siguientes proposiciones:
 - a. Para detectar las estacionalidades necesariamente será necesario considerar periodos inferiores al año en la serie.
 - b. Para que se pueda decir que se esta ante la presencia de un ciclo primero debemos percatarnos que la serie esta dada por valores superiores al año.
 - c. Para modelos con rezagos distribuidos necesariamente deberá identificarse a la variable dependiente e independiente.
 - d. Para determinar una tendencia particular en una serie sólo bastará con graficarla.

3. Identificar cada una de los siguientes modelos para series temporales:
 - a. $Y_t = \beta_1 Y_{t-1} + \beta_2 Y_{t-2} + \mu_t$
 - b. $Y_t = \beta_0 + \beta_1 t + \beta_2 t^2 + \mu_t$
 - c. $Y_t = \beta_1 + \beta_2 X_t + \beta_3 Y_{t-1} + \mu_t$
 - d. $Y_t = \beta_0 + \beta_1 t + \mu_t$

- I. Modelo de tendencia determinista.
- II. Modelo de tendencia cuadrática.
- III. Modelo autorregresivo
- IV. Modelo de rezagos distribuidos

4. Cuando se dice que existe un ruido blanco:

- a. Cuando la media del error aleatorio es cero: $E[\mu_t]$.
- b. Cuando la media y la varianza del error aleatorio son cero:
 $E[\mu_t] = 0, \text{Var}(\mu_t) = 0$.
- c. En el caso que un proceso sea estacionario.
- d. Cuando la media, la varianza y la covarianza para instantes de tiempo diferentes del error aleatorio son cero:
 $E[\mu_t] = 0, \text{Var}(\mu_t) = 0, \text{Cov}(\mu_t, \mu_s) = 0$

RESPUESTAS DE CONTROL

1. a.III, b.I, c.IV, d.II , 2. VVVF, 3. a.IV, b.II, c.III, d.I; 4. d.