

RAMSÉS H. MENA  
 CLASE 2: ACF Y TRANSFORMACIONES A  
 ESTACIONARIEDAD

**6. Función de autocorrelación (ACF)**

En la Definición 4 se introdujo la definición de la función de autocovarianza, que proporciona una medida de la dependencia subyacente a un modelo dado. Por otro lado, la Definición 5, de un proceso débilmente estacionario, utiliza dicha función.

**Ejemplo 1.** Consideren la serie de la Figura 2 como las mediciones en el tiempo de un fenómeno de interés.




Figura 2: Serie simulada.

Para describir a a dicha serie se propone el siguiente modelo

$$X_t = \phi X_{t-1} + \sqrt{1 - \phi^2} \varepsilon_t, \tag{11}$$

donde  $0 < \phi < 1$  y  $\varepsilon_t \sim N(0, 1)$ .

Una forma de ver como el modelo captura la dinámica de los datos es a través de la función de autocorrelación. Primero, observemos la ACF muestral en la Figura 3, donde se puede apreciar una que la autocorrelación subyacente a los datos tiende a desaparecer conforme el tiempo pasa.

Por otro lado, se puede ver que la ACF correspondiente al modelo (11), está dada por  $\text{Corr}(X_t, X_{t+h}) = \phi^h$ . Si

estimamos el valor de  $\phi$  (e.g. usando máxima verosimilitud), se puede ver que  $\hat{\phi} = 0.49$ . Así pues, se podría decir que el modelo no es “tan malo”, ya que al menos la ACF(1) se ajusta bien.




Figura 3: ACF de la serie en Figura 2. Los primeros cuatro valores son: 1, 0.492, 0.283, 0.231 y 0.073 respectivamente.

**Tarea:** Calcular la ACF del modelo (11).

**7. Transformación del modelo clásico a estacionaridad.**

El Ejemplo 1 muestra una serie “fácil” de analizar, sin embargo las situaciones que se observan de series de datos reales no son tan sencillas.

En la Figura 4 se observa la serie correspondientes al número de pasajeros en en aerolíneas internacionales. Se puede ver claramente que dicha serie exhibe cierta **tendencia** y cierta **estacionalidad** o **ciclicidad**.

Estos datos se podrían ver como la realización de un modelo de la forma

$$X_t = m_t + s_t + Y_t, \tag{12}$$

donde  $m_t$  y  $s_t$  son funciones “deterministas” que representan cierta tendencia y ciclicidad respectivamente y  $Y_t$  denota un “ruido aleatorio” dado a través de un proceso débilmente estacionario (ver Definición 5). De manera ideal el componente de tendencia  $m_t$ , se debe de comportar de una manera “suave” y sin cambios muy “abruptos” mientras que la función de ciclicidad deberá ser una función con periodo conocido  $d$ .

Parte del la tarea inicial de la teoría de series de tiempo es la estimación y extracción de dichos componentes,  $m_t$




Figura 4: Número de pasajeros en aerolíneas internacionales: totales mensuales de enero de 1949 a Diciembre de 1960. Las cifras reportadas están en miles. Fuente: Box and Jenkins (1970).

y  $s_t$ , con la esperanza de que el componente de **residuo** o componente de **ruido**,  $Y_t$ , resulte en una serie de tiempo estacionaria, y así modelar este último mediante alguno de los modelos básicos de series de tiempo.

## 8. Estimación y eliminación de tendencia en ausencia de estacionalidad

En esta sección exploraremos algunas técnicas para remover la tendencia de un modelo sin componente cíclico, es decir de la forma

$$X_t = m_t + Y_t, \quad (13)$$

donde  $\mathbb{E}[Y_t] = 0^1$ .

### 8.1. Estimación de $m_t$ por mínimos cuadrados

Este método consiste en modelar, “ajustar”, una familia de funciones paramétricas, por ejemplo

$$m_t = a_0 + a_1 t + a_2 t^2, \quad (14)$$

a los datos, escogiendo los parámetros ( $a_0, a_1$  y  $a_2$  en el ejemplo arriba) de tal forma que se minimice

$$\sum_t (x_t - m_t)^2. \quad (15)$$

**Ejemplo 2.** Considérese la serie proveniente de la población en EUA durante el periodo de 1970–1980. Ver Figura 5




Figura 5: Población (en millones) de EUA durante los años 1790–1990. Fuente: Brockwell and Davis (2002).

Si suponemos un modelo de la forma (13) y modelamos la tendencia con una función cuadrática de la forma (14), los estimadores resultantes del procedimiento de mínimos cuadrados son  $\hat{a}_0 = 2.097911 \times 10^{10}$ ,  $\hat{a}_1 = -2.334962 \times 10^7$  y  $\hat{a}_2 = 6.498591 \times 10^3$ .

Como consecuencia la idea sería analizar los residuales  $Y_t = X_t - \hat{m}_t$ , claro que no para cualquier serie dicha cantidad resultará en un proceso débilmente estacionario.

### 8.2. Método de diferenciación

Este método consiste en transformar los datos mediante el **operador de diferencias**,  $\nabla$ , definido por

$$\nabla X_t = X_t - X_{t-1}, \quad (16)$$

con la finalidad de que el modelo resultante sea débilmente estacionario. Por ejemplo veamos que sucedería si aplicamos este operador a el modelo con tendencia lineal dado por:

$$X_t = a_0 + a_1 t + Y_t,$$

donde una vez más suponemos que  $Y_t$  es débilmente estacionario y  $\mathbb{E}[Y_t] = 0$ . Tenemos

$$\nabla X_t = a_1 + \nabla Y_t, \quad (17)$$

en donde se verifica que la tendencia ha sido removida.

El operador de diferencias se puede aplicar varias veces, por ejemplo  $\nabla^2 X_t = \nabla(\nabla X_t) = X_t - 2X_{t-1} + X_{t-2}$ .

<sup>1</sup>Si  $\mathbb{E}[Y_t] \neq 0$  entonces podemos reemplazar a  $m_t$  por  $m_t + \mathbb{E}[Y_t]$  y a  $Y_t$  por  $Y_t - \mathbb{E}[Y_t]$ .

**Tarea:** Aplicar el operador de diferencias dos veces al modelo (13) con tendencia dada por (14).

En general una tendencia polinómica de orden  $k$  se puede remover mediante la aplicación del operador de diferencias  $k$  veces.

### 8.3. Suavizamiento con filtros de promedios móviles finito

Sea  $q$  un entero no-negativo y consideremos el **promedio móvil** dado por

$$W_t = \frac{1}{2q+1} \sum_{j=-q}^q X_{t-j} \quad (18)$$

correspondiente al proceso  $\{X_t\}$  definido mediante 13. Entonces para  $q+1 \leq t \leq n-q$ ,

$$W_t = \frac{1}{2q+1} \sum_{j=-q}^q m_{t-j} + \frac{1}{2q+1} \sum_{j=-q}^q Y_{t-j} \approx m_t. \quad (19)$$

La approximation de arriba se vale si asumimos que  $m_t$  es aproximadamente lineal sobre el intervalo  $[t-q, t+q]$  y que el promedio de los errores sobre este intervalo tiende a cero. Entonces los promedios móviles proporcionan el siguiente estimador

$$\hat{m}_t = \frac{1}{2q+1} \sum_{j=-q}^q X_{t-j}, \quad q+1 \leq t \leq n-q. \quad (20)$$

Dado que la serie no se observa para  $t < 0$  o  $t > n$ , entonces no se puede usar (20) para  $t \leq q$  o  $t > n-q$ . Una manera de manipular esto en práctica se puede hacer mediante  $X_t := X_1$  para  $t < 1$  y  $X_t := X_n$  para  $t > n$ .

## 9. Eliminación de tendencia y ciclicidad

Ahora consideremos un modelo dado de la forma (12), es decir

$$X_t = m_t + s_t + Y_t, \quad (21)$$

con  $E[Y_t] = 0$ ,  $s_{t+d} = s_t$  y  $\sum_{j=1}^d s_j = 0$ .

### 9.1. Estimación de la tendencia y ciclicidad

Supongamos que observamos la serie  $\{x_t\}_{t=1}^n$ . Un método para remover ambas, tendencia y ciclicidad, se da mediante la aplicación de un filtro de promedios móviles construido de manera especial para eliminar el componente cíclico. Si el periodo, denotado por  $d$ , es par  $d = 2q$ , entonces se usa

$$\hat{m}_t = (0.5x_{t-q} + x_{t-q+1} + \dots + 0.5x_{t+q})/d, \quad (22)$$

para  $q < t < n - q$ . Por otro lado si el periodo es impar  $d = 2q + 1$ , entonces se utiliza (18).

El segundo paso es estimar el componente de ciclicidad. Para cada  $k = 1, \dots, d$  se calcula el promedio,  $w_k$ , de las desviaciones

$$\{(x_{k+jd} - \hat{m}_{k+jd}), \quad q < k + jd \leq n - q\}.$$

Así pues, el componente de ciclicidad se estima mediante

$$\hat{s}_k = w_k - \frac{1}{d} \sum_{i=1}^d w_i, \quad k = 1, \dots, d, \quad (23)$$

y  $\hat{s}_k = \hat{s}_{k-d}$ ,  $k > d$ .

Entonces los datos sin ciclicidad se pueden estimar mediante

$$d_t = x_t - \hat{s}_t, \quad t = 1, \dots, n. \quad (24)$$

Finalmente se re-estima la tendencia de los datos sin ciclicidad,  $\{d_t\}$  mediante el uso de alguno de los métodos descritos en la clase anterior. Así pues, los residuales se pueden estimar mediante

$$\hat{Y}_t = x_t - \hat{m}_t - \hat{s}_t, \quad t = 1, \dots, n. \quad (25)$$

*Hacer ejemplo con los datos “deaths” usando ITSM: Transform >Classical.*

### 9.2. Método de diferencias

Al igual que en el modelo de sin ciclicidad (13), el método de diferencias se puede adaptar para eliminar o “difuminar” cierta ciclicidad subyacente a los datos. Considérese el **operador de diferencias con rezago- $d$** , definido como

$$\nabla_d X_t := X_t - X_{t-d}. \quad (26)$$

Una aplicación de este operador al modelo dado por (21), obtenemos

$$\nabla_d X_t = m_t - m_{t-d} + Y_t - Y_{t-d}, \quad (27)$$

es decir se descompone en un componente de tendencia ( $m_t - m_{t-d}$ ) y un componente de ruido ( $Y_t - Y_{t-d}$ ). De igual forma, la tendencia se puede eliminar con alguno de los métodos descritos en la Sección 8.

*Hacer ejemplo con los datos “deaths” usando ITSM: Transform >Difference, con lag 12. Para eliminar la tendencia restante se puede aplicar el operador de diferencias una vez más, es decir  $\nabla (\nabla_{12} x_t)$ .*