

المحور 03: النماذج الخطية للسلالس الزمنية

المحاضرة 05




- قبل الخوض في دراسة الاتجاه الأساسي نحو الزيادة أو النقصان لأية سلسلة زمنية، لابد من التأكد أولاً من وجود إتجاه في السلسلة الزمنية. وحسب طبيعة نمو السلسلة يمكننا أن نميز بين سلاسل زمنية مستقرة وسلاسل زمنية غير مستقرة أي ذات إتجاه.
- والهدف من دراسة هذا النوع من النماذج (النماذج الخطية) هو تطوير نماذج تشرح تحرك السلسلة الزمنية (Y_t مثلاً)
- ، حيث يمكن شرح هذه السلسلة بواسطة قيمها الحالية والماضية. مثلاً $Y_t = \delta + \phi_1 Y_{t-1} + \varepsilon_t$
- قبل الخوض في هذه النماذج نتطرق إلى بعض المصطلحات والمفاهيم الأولية:

I. مفاهيم أولية:

1- مفهوم الاستقرارية (Stationarity):

السلسلة الزمنية المستقرة هي تلك التي تتغير مستوياتها مع الزمن دون أن يتغير المتوسط فيها، وذلك خلال فترة زمنية طويلة نسبياً، أي أن السلسلة لا يوجد فيها إتجاه لا نحو الزيادة ولا نحو النقصان.

- فيما يلي بعض الأشكال البيانية تبين حالات الاستقرار وعدم الاستقرار ونوعه:



- عمليا يمكن أن نكتفي بمفهوم الاستقرار من الرتبة 2 (الاستقرارية الضعيفة Weak Stationary) التي تعطى

بالصيغة التالية:

نقول عن السلسلة الزمنية Y_t مستقرة إذا حققت الشروط التالية:

- 1) $E(Y_t) = E(Y_{t+j}) = \mu$ ثابت
- 2) $V(Y_t) = V(Y_{t+j}) = \sigma^2 = \gamma_0$
- 3) $Cov(Y_t, Y_{t+j}) = Cov(Y_{t+s}, Y_{t+j+s}) = \gamma_j$

ويعني الشرط (1) تذبذب السلسلة حول وسطها يكون ثابت. والشرط (2) يعني ثبات تباين السلسلة عبر الزمن. أما الشرط (3) فيعني التباين المشترك أو الارتباط بين قيمتين لنفس المتغير يساوي إلى قيمة ثابتة غير مرتبطة بالزمن.

2- الشوشرة البيضاء (الضجة البيضاء) :White Noise

متسلسلة الشوشرة البيضاء ε_t عبارة عن متسلسلة من المشاهدات العشوائية غير المترابطة، وأحياناً نفرض أنها متسلسلة من المتغيرات العشوائية التي تكون مستقلة ولها توزيعات متماثلة بمتوسط مساو لـ 0 وتباين ثابت، أي:

- 1) $E(\varepsilon_t) = 0$
- 2) $V(\varepsilon_t) = \sigma^2$
- 3) $Cov(\varepsilon_t, \varepsilon_{t+j}) = 0$

واختصاراً نرمز للشوشرة البيضاء بالرمز $\varepsilon_t \sim WN(0, \sigma^2)$

3- متسلسلة السير العشوائي (Random Walk)

$$Y_1 = \varepsilon_1$$

$$Y_2 = \varepsilon_1 + \varepsilon_2 \Rightarrow Y_2 = Y_1 + \varepsilon_2$$

$$\vdots$$

$$Y_t = \varepsilon_1 + \varepsilon_2 + \dots + \varepsilon_t$$

$$Y_t = Y_{t-1} + \varepsilon_t$$

4- معامل التأخير (Lag operator): إدخال معامل التأخير يبسط التعبير عن مختلف النماذج. ويكتب معامل التأخير بالشكل التالي:

$$Y_{t-1} = LY_t , \quad Y_{t-2} = L^2Y_t , \quad Y_{t-3} = L^3Y_t , \quad Y_{t-4} = L^4Y_t$$

بشكل عام: $Y_{t-k} = L^kY_t$

5- معامل الفروقات الأولى (First Differences): يرمز لها بالرمز Δ .

$$\Delta = (1 - L)$$

- $\Delta Y_t = Y_t - Y_{t-1} = (1 - L)Y_t$
- $\Delta^2 Y_t = (1 - L)^2 Y_t = (1 + L^2 - 2L)Y_t$

يمكن كتابة $\Delta^2 Y_t$ بصيغة أخرى:

- $\Delta^2 Y_t = \Delta(\Delta Y_t)$

6- مفهوك Wald (المصفى الخطى):

في هذه الحالة تكون Y_t معبّر عنها بدلالة الأخطاء ε_t الحالية والسابقة:

$$Y_t = \varepsilon_t + \theta_1\varepsilon_{t-1} + \theta_2\varepsilon_{t-2} + \dots \dots \dots$$

$$= \varepsilon_t + \theta_1L\varepsilon_t + \theta_2L^2\varepsilon_t + \dots \dots \dots$$

$$= (1 + \theta_1L + \theta_2L^2 + \dots \dots \dots) \varepsilon_t$$

$$Y_t = \theta(L)\varepsilon_t , \quad \theta(L) = 1 + \theta_1L + \theta_2L^2 + \dots \dots \dots$$

وتسمى $\theta(L)$ بدلالة التحويل. $\theta(L)$ محدوداً عندما تكون السلسلة الزمنية Y_t مستقرة.

II. نماذج الانحدار الذاتي AR (Autoregressive Models) :

1- الشكل العام:

- نقول عن نموذج أنه يمثل انحدار ذاتي من الرتبة الأولى AR(1) إذا كان من الشكل:

$$AR(1): \quad Y_t = \theta_1 Y_{t-1} + \varepsilon_t$$

- ونقول عن نموذج أنه يمثل انحدار ذاتي من الرتبة الثانية AR(2) إذا كان من الشكل:

$$AR(2): \quad Y_t = \theta_1 Y_{t-1} + \theta_2 Y_{t-2} + \varepsilon_t$$

- ونقول عن نموذج أنه يمثل انحدار ذاتي من الرتبة الثالثة AR(3) إذا كان من الشكل:

$$AR(3): \quad Y_t = \theta_1 Y_{t-1} + \theta_2 Y_{t-2} + \theta_3 Y_{t-3} + \varepsilon_t$$

:

:

:

شكل عام نموذج من الرتبة p :

$$AR(p): \quad Y_t = \theta_1 Y_{t-1} + \theta_2 Y_{t-2} + \theta_3 Y_{t-3} + \dots \dots + \theta_p Y_{t-p} + \varepsilon_t$$

يمكن كتابة نموذج الانحدار الذاتي من الرتبة P باستخدام معامل التأخير L بالشكل التالي:

$$\text{AR}(p): \quad Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \phi_3 Y_{t-3} + \cdots \dots + \phi_p Y_{t-p} + \varepsilon_t$$

$$Y_t - \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \phi_3 Y_{t-3} + \cdots \dots + \phi_p Y_{t-p} = \varepsilon_t$$

$$Y_t - \phi_1 L Y_t + \phi_2 L^2 Y_t + \phi_3 L^3 Y_t + \cdots \dots + \phi_p L^p Y_t = \varepsilon_t$$

$$= (1 - \phi_1 L - \phi_2 L^2 - \phi_3 L^3 - \cdots \dots - \phi_p L^p) Y_t = \varepsilon_t$$

$$\phi(L) Y_t = \varepsilon_t$$

$$\phi(L) = (1 - \phi_1 L - \phi_2 L^2 - \phi_3 L^3 - \cdots \dots - \phi_p L^p)$$

2- الشكل المصففي:

رأينا سابقاً:

$$\phi(L) Y_t = \varepsilon_t \dots \dots \dots (1)$$

$$Y_t = \theta(L) \varepsilon_t \dots \dots \dots (2)$$

من (1) نكتب:

$$Y_t = \phi^{-1}(L) \varepsilon_t$$

$$\phi^{-1}(L) = \theta(L) \quad \text{إذن:}$$

$$\frac{1}{\phi(L)} = \theta(L) \quad \text{وبذلك:}$$

$$\phi(L) \theta(L) = 1 \quad \text{وبالتالي:}$$

$$[1 - \phi_1 L - \phi_2 L^2 - \phi_3 L^3 - \cdots \dots - \phi_p L^p] [1 + \theta_1 L + \theta_2 L^2 + \cdots \dots + \theta_p L^p] = 1$$

3- شرط الاستقرارية:

يتتحقق شرط الاستقرارية في حالة نموذج AR(p) إذا كانت جذور كثير الحدود (L) تقع خارج الدائرة الوحدوية. كما يلي:

• حالة AR(1)

$$Y_t = \phi_1 Y_{t-1} + \varepsilon_t$$

$$(1 - \phi_1 L) Y_t = \varepsilon_t$$

$$\phi(L) = 1 - \phi_1 L \quad \text{بحيث:}$$

$$\phi(L)Y_t = \varepsilon_t$$

$$Y_t = \phi^{-1}(L) \varepsilon_t$$

$$\phi^{-1}(L) = \theta(L)$$

لدينا سابقاً

$$\theta(L) = [1 + \phi_1^1 L + \phi_1^2 L^2 + \dots \dots \dots + \phi_1^p L^p]$$

$$\begin{cases} \theta_3 = \phi_1^3 & , \quad \theta_1 = \phi_1^1 \\ \theta_4 = \phi_1^4 & , \quad \theta_2 = \phi_1^2 \end{cases}$$

شرط الاستقرارية في نموذج AR(1):

$$\phi(L) = 1 - \phi_1 L$$

$$\phi(L) = 0$$

يجب أن تكون :

$$1 - \phi_1 L = 0$$

وبالتالي:

$$L = \frac{1}{\phi_1}$$

أي:

يتحقق شرط الاستقرارية إذا كان:

$$|L| > 1$$

$$\Rightarrow \left| \frac{1}{\phi_1} \right| > 1$$

$$|\phi_1| < 1$$

يعني

• حالة AR(2)