

وتبرير ذلك ، هو أنه إذا كانت طريقة التنبؤ تسير بشكل صحيح فإن عدد الأخطاء السالبة سيساوي تقربياً عدد الموجبة وستكون الأخطاء عددياً متقاربة في القيمة. في هذه الحالة يتوقع أن تكون قيمة البسط صفرأ. وعليه فإن القيمة الكبيرة لـ TS تعني أن طريقة التنبؤ - ومن خلاها α - أدت لأخطاء تنبؤ معظمها سالب أو معظمها موجب. يعني آخر القيم التنبؤية معظمها أكبر من القيم الفعلية أو معظمها أصغر منها. ولهذا فإن القيم الكبيرة لـ TS تدفعنا للشك بأن طريقة التنبؤ وبالتالي اختيار α لم تعد سليمة. ويحدد الكبر حسب حد ضبط معين k . وعادة تؤخذ k بين 4 و 6.

مثال (٤ , ٤)

في مثال (٢ , ٤) نجد من العمود الأخير بمجدول (٢ , ٤) :

$$\sum_{t=1}^{12} e_t = -1.00 + (-.98) + \dots + 3.70 = 17.56$$

$$\frac{\sum_{t=1}^{12} |e_t|}{12} = [|1 - 1| + |-0.98| + \dots + |3.70|] / 12 = \frac{25.44}{12} = 2.12$$

وبالتالي تكون إشارة التتبع :

$$TS = \frac{17.56}{2.12} = 8.28$$

وهي كبيرة مما يعني أن طريقة التنبؤ لم تعد تعطي نتائج صحيحة بمواصلة استخدام نفس قيمة α .

يفضل كثير من العاملين في مجال التنبؤ استخدام ثابت تمهيد يتغير تلقائياً مع الزمن بهدف جعل طريقة التنبؤ أكثر تكيفاً مع التغيرات التي تطرأ على السلسلة . وهناك عده طرق لتحقيق ذلك تسمى طرق السيطرة التكيفية adaptive control procedures . من هذه الطرق طريقة تشاو (Chow ١٩٦٥) تتطلب هذه الطريقة باختصار ما يلى : إذا كان ثابت التمهيد هو α يستحدث ثابتي تمهيد

آخرين $\alpha + \delta$ و $\alpha - \delta$ (يقترح تشاو أن تكون $\delta = 0.05$). بعد ذلك يطبق التمهيد الأسى على السلسلة الزمنية باستخدام كل من الثوابت الثلاثة على حده. وفي كل حالة بحسب المتوسط المطلق لأنحرافات أخطاء التنبؤ حتى الزمن t . فإذا كان هذا المقدار أقل في الحالة α يستمر استخدامها عدا ذلك يستخدم الثابت من الاثنين الآخرين الذي يعطى أقل متوسط مطلق لأنحرافات أخطاء التنبؤ.

٢،٥،٤ التمهيد الأسى المزدوج هولت Holt's double-exponential smoothing

هذه الطريقة مناسبة في الحالة التي تكون فيها السلسلة الزمنية خاضعة لاتجاه عام. ويتم التنبؤ فيها باستخدام ثابتي تمهيد α و γ لهذا تسمى أحياناً طريقة هولت ذات المعلمين Holt's two-parameter method.

وتتركز الطريقة على المعادلات الثلاث التالية:

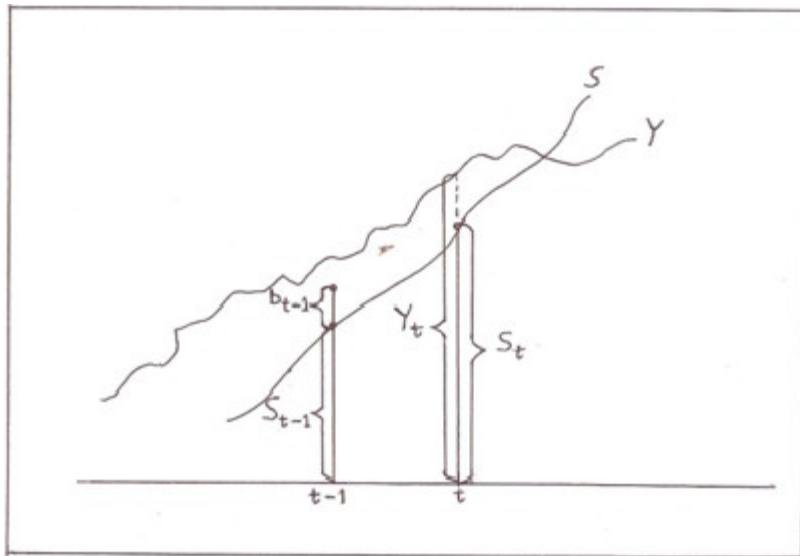
$$S_t = \alpha Y_t + (1 - \alpha)(S_{t-1} + b_{t-1}) \quad \dots \quad (4,4)$$

$$b_t = \gamma(S_t - S_{t-1}) + (1 + \gamma)b_{t-1} \quad \dots \quad (4,5)$$

$$F_{t+m} = S_t + b_t m \quad \dots \quad (4,6)$$

حيث تمثل S قيمة مهدة ، b اتجاه عام و m عدد الفترات المراد التنبؤ بها للأمام. ومن المفيد للقارئ أن يتذكر أن كلمة تمهيد تعني ببساطة عمليةأخذ متوسط بشكل ما . وكل معادلات التمهيد الأسى تتضمن أخذ متوسط (مرجع) لتمهيد قيم ما.

في المعادلة (4,4) يتم تمهيد قيم السلسلة للحصول على قيم مهدة S بدلاً عن القيم الأصلية Y ليتمكن بعد ذلك استخدام هذه القيم (التي يتوقع أن تمثل النمط العام لسير السلسلة) في التنبؤ من خلال المعادلة (4,6). القيمة المهددة في الزمن t ، S_t يتم الحصول عليها بتعديل القيمة المهددة في الزمن السابق S_{t-1} بإضافة الاتجاه العام في الزمن $t-1$ ، b_{t-1} إليها لينعكس تأثيره عليها زيادة أو نقصاناً فتقرب بذلك من القيمة الفعلية في الزمن t أي Y_t . القيمة المهددة في الزمن t تؤخذ بعد ذلك كمتوسط مرجح بالأوزان α و $1 - \alpha$ لـ Y_t و $S_{t-1} + b_{t-1}$. انظر شكل (4,1).



شكل (٤٠١)

الاتجاه العام b بدوره قد يتغير مع الزمن. لذلك نحتاج لأن ننظر إليه كسلسلة زمنية ونقوم بتمهيده حتى يمكن تبيان نمطه العام وتقدير قيمته في كل فترة زمنية.

وإذا توفرت القيم المهددة في الزمن t والزمن $t-1$ أي S_t و S_{t-1} فإن أفضل تقدير للاتجاه العام في الزمن $t-1$ يكون الفرق بينهما $S_t - S_{t-1}$ فإذا كان الاتجاه العام يتجه نحو الزيادة فإن هذا الفرق يكون موجباً وإذا كان نحو التقصان فإنه يكون سالباً ولهذا فمن المنطقي أن يمثل تقديراً للاتجاه العام في الزمن $t-1$. وتقوم المعادلة (٤، ٥) التي مهمتها تمديد الاتجاه العام ، بأخذ الاتجاه العام في الزمن t أي b_t كوسط مرجح بين هذا التقدير والاتجاه العام في الزمن السابق b_{t-1} .

إذا كتبنا المعادلة (٤، ٥) التي هي في الواقع معادلة تمديد أسي مفرد مطبقة على

$$\text{الاتجاه العام} - \text{بالشكل: } b_t = b_{t-1} + \gamma((S_t - S_{t-1}) - b_{t-1})$$

نرى أن الاتجاه العام في الزمن t يتم الحصول عليه بتعديل الاتجاه العام السابق b_{t-1} بإضافة الفرق بينأحدث تقدير b_{t-1} و $S_t - S_{t-1}$ (بعد الضرب في γ). فإذا كان $S_t - S_{t-1} - b_{t-1}$ أقل من b_{t-1} يتم رفع قيمته بإضافة القيمة الموجبة $b_{t-1} - S_t - S_{t-1}$

إليه وإذا كان أكبر تخفض قيمته بإضافة القيمة السالبة. وبهذا يحدث الاتجاه العام ويطور مع كل تمديد جديد.

أما المعادلة (٤,٦) فتستخدم للتنبؤ من الزمن t لـ m وحده زمنية للأمام.

وليمكن استخدام المعادلات (٤,٤)-(٤,٦) في التنبؤ لابد من الحصول على قيم S_1 و b_1 إذا لا توجد قيم S_0 و b_0 يمكن استخدامها للحصول عليهما من (٤,٤) و (٤,٥). وبالتالي لا يمكن الانطلاق للتنبؤ في الفترات اللاحقة . بالنسبة لـ S_1 جرى العرف علىأخذ $S_1 = Y_1$. أما بالنسبة لـ b_1 فهناك عدة طرق منها :

$$b_1 = \frac{(Y_2 - Y_1) + (Y_3 - Y_2) + (Y_4 - Y_3)}{3} \quad \text{و} \quad b_1 = Y_2 - Y_1$$

ويعجرد تحديد قيمة لـ b_1 و S_1 يمكن إجراء التنبؤ للفترات التالية كما يوضح المثال (٤,٥) أدناه. لاحظ أنه لا يوجد تنبؤ في الفترات ١ و ٢ لأننا افترضنا أن قيمها Y_1 و Y_2 معروفة واستخدمت في تقدير S_1 و b_1 .

مثال (٤,٥)

العمود الثاني بجدول (٤,٣) يبين المبيعات السنوية لشركة خلال ٦ سنوات.

مستخدماً $\alpha = 0.2$ و $\gamma = 0.3$ تنبأ بالقيم في السنوات ١٩٨٦-١٩٨٩.

رقم السنة (t)	السنة	Y_t المبيعات بملايين الجنيهات	S_t	b_t	F_t	خطا التنبؤ e_t	التنبؤ بالتمديد الأسوي المفرد	الخطا في التمديد المفرد
١	١٩٨٤	١٤	١٤,٠	٢				
٢	١٩٨٥	١٦	١٦,٠	٢				
٣	١٩٨٦	٢٠	١٨,٤٠	٢,١٢	١٨	٢,٠	١٨,٤٥	١,٥٥
٤	١٩٨٧	٢٤	٢١,٢١	٢,٣٣	٢٠,٥٢	٣,٤٨	١٨,٧٦	٥,٢٤
٥	١٩٨٨	٢٢	٢٣,٢٣	٢,٢٤	٢٣,٥٤	-١,٥٤	١٩,٨٠	٢,٢
٦	١٩٨٩	٢٦	٢٥,٥٨	٢,٢٧	٢٥,٤٧	٠,٥٣	٢٠,٢٤	٥,٧٦

جدول (٤,٣)

سنأخذ $b_1 = Y_2 - Y_1 = 2$ و $S_1 = Y_1 = 14$

من (٤,٤) و (٥,٤) نجد بالترتيب للسنة الثانية :

$$\begin{aligned} S_2 &= \alpha Y_2 + (1-\alpha)(S_1 + b_1) \\ &= 0.2 \times 16 + 0.8(14 - 2) = 16 \\ b_2 &= \gamma(S_2 - S_1) + (1-\gamma)b_1 \quad , \\ &= 0.3(16 - 14) + 0.7 \times 2 = 2 \end{aligned}$$

في السنة ٣ نحسب المقادير :

$$\begin{aligned} S_3 &= 0.2 Y_3 + (1-0.2)(S_2 + b_2) \\ &= 0.2 \times 20 + 0.8(16 + 2) = 18.4 \\ b_3 &= 0.3(18.4 - 16) + 0.7 \times 2 = 2.12 \end{aligned}$$

التنبؤ في السنة ٣ باستخدام (٦,٤) من السنة ٢ :

$$F_3 = S_2 + b_2 \times (1) = 16 + 2 \times 1 = 18$$

في السنة ٤ نحسب

$$\begin{aligned} S_4 &= 0.2 \times 24 + 0.8(18.4 + 2.12) = 21.21 \\ b_4 &= 0.3(21.21 - 18.4) + 0.7 \times 2.12 = 2.33 \end{aligned}$$

التنبؤ في السنة ٤ من السنة ٣ :

$$F_4 = S_3 + b_3 \times (1) = 18.4 + 2.12 \times 1 = 20.52$$

وهكذا نجد بقية القيم في العمود الرابع والخامس والسادس.

ويوضح العمود قبل الأخير التنبؤ بالتمهيد الأسى المفرد بأخذ F_1 تساوي متوسط القيم الـ ٦ وهو $20, 33$ وبأخذ $\alpha = 0.2$. ومقارنة أخطاء التنبؤ في حالة التمهيد الأسى المفرد (العمود الأخير) بنظيرتها في التمهيد المزدوج نلاحظ أن الأخطاء في التمهيد المزدوج أقل كثيراً (باستثناء حالة واحدة) منها في التمهيد المفرد. وهذا ليس يستغرب لأن السلسلة المعطاة تحوى اتجاهات عاماً وهو ما لا يعالج أثر وجوده التمهيد المفرد.

٤، ٥ ، التمهيد الأسّي الثلاثي لويينترز

Winter's three-parameter exponential smoothing method

عندما يكون بالسلسلة الزمنية تغيرات موسمية فإن الطرق السابقة لا يتوقع أن تؤدي لتبؤ يقترب من الواقع لأنها لا تضع في الاعتبار التغيرات الموسمية. ممكن بالطبع التخلص من التغيرات الموسمية بطرق مثل تلك التي ذكرناها في الباب الثاني قبل استخدام طرق التمهيد السابقة.

طريقة وينترز للتمهيد الأسّي تعالج مشكلة الموسمية كما تعالج أيضاً مشكلة الاتجاه العام إن وجد. لهذا تستخدم عادة عندما يكون بالسلسلة تأثير موسمي. وتعتمد الطريقة على ثلاثة ثوابت تمهد α ، γ و β تتراوح قيمة كل منها بين الصفر والواحد والمعادلات الأربع التالية :

$$S_t = \alpha \frac{Y_t}{I_{t-L}} + (1 - \alpha)(S_{t-1} + b_{t-1}) \quad \dots (4,7)$$

$$b_t = \gamma(S_t - S_{t-1}) + (1 + \gamma)b_{t-1} \quad \dots (4,8)$$

$$I_t = \beta \frac{Y_t}{S_t} + (1 - \beta)I_{t-L} \quad \dots (4,9)$$

$$F_{t+m} = (S_t + b_t m) I_{t-L+m} \quad \dots (4,10)$$

حيث L طول فترة التكرار الموسمي ، I الدليل الموسمي (أو العامل الموسمي) وحيث بقية الرموز كما في طريقة هولت.

المعادلة (4,7) تقوم بتمهيد قيم السلسلة كما تفعل المعادلة (4,4) في طريقة هولت مع فارق أساسي هو تخليص القيمة Y_t من التأثير الموسمي أولاً بقسمتها على الدليل الموسمي الخاص بالفترة t والذي يكون قد تم حسابه قبل L فترة ويرمز له I_{t-1} .

مثلاً إذا كانت السلسلة شهرية وهناك تأثير موسمي يتكرر كل ١٢ شهر أي $L=12$ ، وإذا كانت t تقابل شهر مارس في سنة ما فإن الدليل الموسمي الخاص بشهر مارس

يكون قد حسب في مارس من السنة السابقة أي قبل ١٢ شهر لهذا تقسم Y_t على I_{t-12} . لاحظ أن الدليل الموسمي الخاص بأي موسم (مثلاً شهر) ليس قيمة واحدة ثابتة تحسب مرة واحدة وتستخدم كدليل على تأثير الموسم متى تكرر كما فعلنا في طريقة التفكير التقليدية بالباب الثاني. ولكن الدليل الموسمي في طريقة وينترز يجدد ويتطور مع الزمن.

أما المعادلة (٤، ٨) فهي تمهد الاتجاه العام وهي تتطابق تماماً مع المعادلة (٥، ٤) في طريقة هولت. في المعادلة (٤، ٩)، S_t قيمة ممدة أو متوسط وبالتالي خالية من التأثير الموسمي وقسمة Y_t عليها يعطينا وبالتالي تقديرأً للتأثير الموسمي في الزمن t . ولأن هذا المقدار عرضه لتغيرات عشوائية يتم تمديده بأخذ متوسط مرجح له وأخر دليل موسمي I_{t-1} . إذا كتبنا (٤، ٩) بالشكل

$$I_t = I_{t-L} + \beta \left(\frac{Y_t}{S_t} - I_{t-L} \right)$$

نرى أن الدليل الموسمي في الزمن t عبارة عن الدليل الموسمي في الزمن $t-L$ بعد تعديله بإضافة الفرق بينه وأخر تقدير له $\frac{Y_t}{S_t}$ (بعد الضرب في β) إليه.

أخيراً المعادلة (٤، ١٠) للتنبؤ m فترة للإمام. لاحظ أن آخر دليل موسمي تم حسابه للموسم المقابل ل $t+m$ هو I_{t+m-L} . لهذا كان الضرب في I_{t+m-L} لوضع التأثير الموسمي في الاعتبار عند التنبؤ.

ولبدء طريقة وينترز نحتاج لبيانات في السلسلة الزمنية لموسمين كاملين على الأقل ، أي $2L$ قيمة . ذلك أننا نحتاج لل $2L$ قيمة الأولى في السلسلة لإيجاد تقدير مبدئي للاتجاه العام والذي يقدر من

$$b = \frac{1}{L} \left[\frac{(Y_{L+1} - Y_1)}{L} + \frac{(Y_{L+2} - Y_2)}{L} + \dots + \frac{(Y_{L+L} - Y_L)}{L} \right]$$

و بما أن كل حد داخل القوس الكبير هو تقدير للاتجاه العام في فترة طولها L فإن القيمة المبدئية b حسب هذه القاعدة هي متوسط هذه التقديرات .

كذلك ، لإيجاد قيم مبدئية للعامل الموسمي في الفترة الأولى نوجد متوسطها

$$M = \frac{1}{L} [Y_1 + Y_2 + \dots + Y_L]$$

وتكون قيم العامل الموسمي في الفترة الأولى :

$$I_1 = \frac{Y_1}{M}, I_2 = \frac{Y_2}{M}, \dots, I_L = \frac{Y_L}{M}$$

لاحظ أننا لا نستطيع أن نبدأ التمهيد قبل الفترة $L+1$ لأنه فقط ابتداءً من الفترة $L+1$ تكون لدينا قيمة للدليل الموسمي I_{L+1} أو I_1 ليمكن استخدام المعادلة (٤، ٧). نحتاج إذن أيضاً لقيمة مبدئية b . وهناك عدة طرق لإيجاد قيمة بداية b منها استخدام وسط مرجع بمعاملات ذو الحدين للقيمة الأولى في السلسلة الزمنية. مثلاً إذا كانت $L=4$ فيما أن معاملات ذو الحدين $n=3$ هي $1, 3, 1$ فإن :

$$S_L = \frac{1 \times Y_1 + 3 \times Y_2 + 3 \times Y_3 + 1 \times Y_4}{1 + 3 + 3 + 1}$$

ومثال التالي يوضح كيفية التنبؤ باستخدام طريقة وينترز للتمهيد الأسني.

مثال (٤، ٦)

جدول (٤,٤) يوضح عدد السيارات التي مرت بنقطة (بالعشرات) في كل من ثلاثة فترات من اليوم A,B,C في ثلاثة أيام متتالية.

اليوم	الفترة	الرقم التسلسلي للفترة (t)	عدد السيارات Y_t	S_t	b_t	I_t
١	A	١	١٠			١,٢٥
	B	٢	٦			٠,٧٥
	C	٣	٨	٧,٥٠	٠,٢٢	١,٠٠
٢	A	٤	١٠	٧,٧٨	٠,٢٣	١,٢٥
	B	٥	٧	٨,٢٧	٠,٢٦	٠,٧٦
	C	٦	٩	٨,٦٢	٠,٢٧	١,٠٠
٣	A	٧	١١	٨,٨٧	٠,٢٧	١,٢٥
	B	٨	٩	٩,٧٠	٠,٣٣	٠,٧٧
	C	٩	١٠	١٠,٠٣	٠,٣٣	١,٠٠

جدول (٤,٤)

سنستخدم ثوابت التمهيد $\alpha = 0.2$ ، $\beta = 0.06$ و $\gamma = 0.1$. في هذا المثال الموسم هو الفترة وبالتالي $L = 3$. نحتاج لقيم لكل من I_1, I_2, I_3 و S_3 لنبدأ التمهيد.

$$\begin{aligned}
 b_3 &= \frac{1}{L \times L} [(Y_4 - Y_1) + (Y_5 - Y_2) + (Y_6 - Y_3)] : b_3 \\
 &= \frac{1}{9} [0 + 1 + 1] = 0.22
 \end{aligned}$$

ثانياً : لإيجاد I_1, I_2 و I_3 نحسب متوسط القيم الثلاث الأولى :

$$M = \frac{10 + 6 + 8}{3} = 8$$

وبقسمة كل من القيم الثلاث الأولى على ٨ نحصل على :

$$I_1 = \frac{Y_1}{8} = \frac{10}{8} = 1.25, I_2 = \frac{Y_2}{8} = \frac{6}{8} = 0.75, I_3 = \frac{Y_3}{8} = \frac{8}{8} = 1$$

ثالثاً: S_3 نحصل عليها بأخذ متوسط القيم الثلاث الأولى مرجحة بمعاملات ذوالحدين

$$S_3 = \frac{1*10 + 2*6 + 1*8}{1+2+1} = 7.5 \quad : 1, 2, 1$$

يمكنا الآن أن نبدأ التمهيد باستخدام المعادلات (٤، ٩) - (٤، ٧)

في الفترة ٤ :

$$\begin{aligned} S_4 &= \alpha \frac{Y_4}{I_{4-3}} + (1-\alpha)(S_3 + b_3) \\ &= 0.2 \times \frac{10}{1.25} + 0.8(7.5 + 0.22) = 7.78 \\ b_4 &= \gamma(S_4 - S_3) + (1-\gamma)b_3 \\ &= 0.1(7.78 - 7.5) + 0.9 \times 0.22 = 0.23 \\ I_4 &= \beta \frac{Y_4}{S_4} + (1-\beta)I_{4-3} \\ &= 0.06 \times \frac{10}{7.78} + 0.94 \times 1.25 = 1.25 \end{aligned}$$

في الفترة ٥ :

$$\begin{aligned} S_5 &= \alpha \frac{Y_5}{I_{5-3}} + (1-\alpha)(S_4 + b_4) \\ &= 0.2 \times \frac{7}{0.75} + 0.8(7.78 + 0.23) = 8.27 \\ b_5 &= \gamma(S_5 - S_4) + (1-\gamma)b_4 \end{aligned}$$

$$\begin{aligned}
&= 0.1(8.27 - 7.78) + 0.9 \times 0.23 = 0.26 \\
I_5 &= \beta \times \frac{Y_5}{S_5} + (1 - \beta)I_{5-3} \\
&= 0.06 \times \frac{7}{8.27} + 0.94 \times 0.75 = 0.76
\end{aligned}$$

وهكذا لبقية الفترات.

للتنبؤ من الفترة ٦ بالقيمة في الفترة ٨ نستخدم المعادلة (٤ ، ١٠) بأخذ

$$L = 3, t = 6, m = 2$$

$$\begin{aligned}
F_{t+m} &= (S_t + b_t \times m)I_{t-L+m} \\
F_8 &= (S_6 + b_6 \times 2) \times I_5 \\
&= (8.62 + 0.27 \times 2) \times 0.76 = 6.96
\end{aligned}$$

لاحظ أننا قد افترضنا ضمناً في طريقة وينترز التي استخدمناها النموذج

$$Y_t = T_t \times S_t \times e_t \quad \text{الضربي:}$$

ولكن ذلك لا يمنع - إذا كانت طبيعة السلسلة تستدعي ذلك - أن يكون النموذج المستخدم جمعي. كذلك قد لا يكون بالسلسلة الزمنية اتجاه عام وإنما تأثير موسمي فقط.

عندما تكون السلسلة الزمنية خاضعة لتأثير موسمي فقط (بدون اتجاه عام)

يمكن استخدام ما يسمى بالتمهيد الأسي الموسمي البسيط **Simple seasonal exponential smoothing** والذي يتم من خلال المعادلات:

$$S_t = \alpha(Y_t - I_{t-L}) + (1 - \alpha)S_{t-1} \quad \dots .1$$

$$I_t = \delta(Y_t - S_t) + (1 - \delta)I_{t-L} \quad \dots .2$$

$$F_{t+m} = S_t + I_{t+m-L} \quad \dots .3$$

حيث α و δ ثوابت تمهيد.

٤، ٥ ، ملاحظات عامة عن طرق التمهيد الأسني

١. في كل طرق التمهيد الأسني التي ناقشناها افترضنا أن الاتجاه العام خطى. لكن هناك حالات لا يكون فيها الاتجاه العام خطياً ومنها

أ. الاتجاه العام الأسني: في هذه الحالة يكون معدل النمو أو الانخفاض في السلسلة أسرع مما يعكسه الخط المستقيم.

ب. الاتجاه العام المتضائل Damped trend: وفيه يكون معدل النمو في السلسلة الزمنية أبطأ مما يمثله الخط المستقيم.

٢. ثوابت التمهيد تحدد السرعة التي تتناقص بها الأوزان المعطاة لقيم السلسلة وتحسن نتيجة نحو القيم الأقدم. فالقيمة الصغيرة (مثلاً قرب الصفر) تسمح لقيم بعيدة للتأثير بشكل أكبر.

٣. تحديد ثابت التمهيد يتم بإحدى طريقتين:

أ. طريقة تعتمد على التقدير الشخصي : وفق هذه الطريقة يحدد الثابت حسب ما نعتقد أنه حادث في السلسلة. فإذا كنا نعتقد أن السلسلة (أو بدقة أكبر الآلة المولدة لها) قد حدثت فيها تغيرات كبيرة أخيراً فمثلاً قرب الواحد مثلاً ٩٠٠،١٠٠ إذا كنا نرى أن السلسلة مستقرة لدرجة كبيرة فقد نستخدم ثابتاً في حدود ١٠٠،١.

ب. طريقة موضوعية: وفيها نترك للسلسلة الزمنية توجيهنا في اختيار ثابت التمهيد، وذلك بتجربة عدة قيم للثابت واختيار القيمة التي تعطي أفضل تنبؤ وفق معيار مناسب مثلاً متوسط مربعات الخطأ.

٤. تتميز طرق التمهيد الأسني بأنها تستخدم معادلة تنبؤ متطرورة ، تعطي فيها القيم الأحدث وزناً أكبر ويتطور فيها الاتجاه العام (كما في طريقة هولت) أو الاتجاه العام والدليل الموسمي (كما في طريقة وينترز). فهي وبالتالي تستند - في حالة الاتجاه العام - على معادلة اتجاه عام محلية Local trend equation بدلاً من معادلة اتجاه عام عامة global trend equation

٥، ٤ التمهيد الأسى باستخدام الحاسب

لتنفيذ طرق التمهيد الأسى المفرد و الثنائي الم Holt والثلاثي لوينترز باستخدام

حزمة SPSS يتم إتباع الخطوات الآتية:

١. تدخل السلسلة الزمنية بالنسبة لطريقة وينترز يجب أيضاً تحديد الوحدات الزمنية

بالتأشير على Define dates في شريط الخدمة ثم استخدام الصفة التي تنطبق على البيانات. مثلاً Years months . ولا تنفذ طريقة وينترز ما لم تجرب هذه الخطوة.

٢. أشر على Analyze في شريط الخدمة واختار Forecasting أو time series . create models

٣. في النافذة التي تفتح أنقل متغير السلسلة إلى مستطيل variable

٤. أشر على المكان المكتوب فيه Expert modeler واختار smoothing

٥. أشر على criteria وعندما تفتح نافذة أشر على الطريقة التي تريد : المفرد ،
هolt ... الخ ثم Continue .

٦. عندما ترجع للنافذة الأولى أشر على statistic وأشر على الإحصائيات التي تريد وأهمها R^2 و root mean square error . parameter estimates

٧. أشر على plots في شريط الخدمة واختار أن يرسم لك السلسلة ، Forecasts ، Fit values وفترات الثقة .

٨. يمكن طلب الـ Expert modeler ليختار لك أفضل نموذج تمديد أسى.

$\wedge \xi$

الباب الخامس

النماذج الخطية المستقرة

Linear Stationary Models

١ ، ٥ مقدمة

في هذا الباب نتعرف على مجموعة هامة من نماذج السلسل الزمنية تسمى النماذج الخطية المستقرة. وهي نماذج لا تتغير فيها الخصائص الإحصائية للسلسلة الزمنية مع الزمن. هذه النماذج هي التي يمكن فيها إجراء الاستدلال الإحصائي (من تقدير واختبار فرض) بكفاءة. وفي الباب السادس ستتعرض للنماذج غير المستقرة، والتي يجب أن تحول لمستقرة ليتمكن إجراء الاستدلال الإحصائي عليها بالكفاءة المطلوبة. وقبل أن نتناول هذه النماذج نتعرف أولاً على بعض الرموز والمصطلحات الهامة.

٢ ، ٥ مشغل الإزاحة ومشغل الفرق

Shift operator & Difference operator

للسلسلة الزمنية $\{Y_t\}$ يعرف مشغل الإزاحة للخلف Backward shift operator بـ B ويرمز له بـ B كما يلي :

$$BY_t = Y_{t-1}$$

أي أنه يرجع المشاهدة فترة زمنية واحدة للوراء. ويمكن استخدام B بشكل مكرر فمثلاً :

$$B(BY_t) = B^2 Y_t = Y_{t-2}$$

يرجع المشاهدة فترتين زمنيتين للخلف. في بعض الأحيان تحتاج لمشغل يقوم بالعملية العكسية أي ينقل المشاهدة فترة للأمام.. يسمى هذا مشغل الإزاحة للأمام ويرمز له

بـ $F = B^{-1}$ ويعرف شكلياً :

$$FY_t = Y_{t+1}$$

من ناحية أخرى يمكن أن نعرف مشغل للفرق ونرمز له بـ ∇ بحيث :

$$\nabla = 1 - B$$

$$\nabla Y_t = (1 - B)Y_t = Y_t - Y_{t-1}$$

وبالتالي نجد أن

هو في الواقع الفرق بين القيمة في الزمن t والقيمة في الزمن قبلها. يسمى هذا الفرق الأول **first difference**. الفرق الثاني **second difference** هو الفرق بين القيمة في الزمن t والقيمة التي تسبقها بفترتين زمنيتين أي :

$$Y_t - Y_{t-2} = (1 - B^2)Y_t$$

عموماً الفرق d :

$$Y_t - Y_{t-d} = (1 - B^d)Y_t$$

إذا أخذنا الفرق الأول للفرق الأول نحصل على

$$Y_t - Y_{t-1} - (Y_{t-1} - Y_{t-2}) = Y_t - 2Y_{t-1} + Y_{t-2}$$

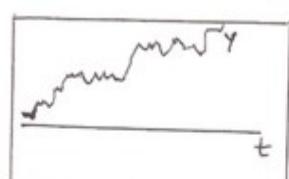
$$= (1 - 2B + B^2)Y_t = (1 - B)^2 Y_t = \nabla^2 Y_t$$

يسمى هذا الفرق ذو الرتبة 2 **second-order difference** وهو مختلف عن الفرق الثاني الذي هو مجرد الفرق بين القيمة والتي تسبقها بوحدتين زمنيتين. وفي الحالة العامة إذا أجرينا عمليةأخذ الفرق الأول d مرة يكون لدينا الفرق ذو الرتبة d . وهدف عادة من عمليةأخذ فروق هو جعل السلسلة الزمنية مستقرة بالمفهوم الذي سنشرحه بعد قليل.

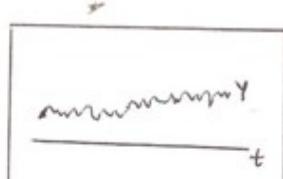
٣،٥ الإستقرار Stationarity يقال أن العملية التصاديفية مستقرة بشكل كامل **strictly stationary** إذا كانت جميع خصائصها الإحصائية لا تتغير مع الزمن . ويعني ذلك أننا إذا أجرينا المشاهدات $Y_{t_1}, Y_{t_2}, \dots, Y_{t_n}$ في الأزمنة t_1, t_2, \dots, t_n فإن دالة كثافة الإحتمال المشتركة لها تتطابق مع تلك التي للمشاهدات $Y_{t_1+m}, Y_{t_2+m}, \dots, Y_{t_n+m}$ في الأزمنة $t_{1+m}, t_{2+m}, \dots, t_{n+m}$.

وتوصف أى سلسلة زمنية تولدت عن هذه العملية التصادفية بأنها مستقرة بشكل كامل . وبما أنه يتعدى في الواقع العملي التحقق من وجود الاستقرار الكامل فإنه يكتفى عادة بما يسمى بالاستقرار الضعيف **weak stationarity** والذي يتطلب فقط أن يكون متوسط العملية وتبينها لا يتغيران مع الزمن (ثوابت) وأن السلسلة الزمنية التغایر بإبطاء k يعتمد فقط على فارق الزمن k وليس على الزمن . أى لا يتغير مع الزمن إذا كانت k ثابتة . وفي أدبيات السلسلة الزمنية جرى العرف على استخدام "مستقرة " للعملية التصادفية (وبالتالي السلسلة المولدة عنها) التي تحقق الاستقرار الضعيف . وهذا ما ستتبعه في هذا الكتاب .

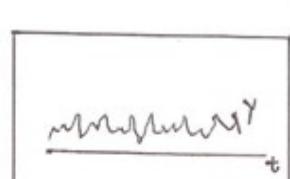
وتجدر الإشارة إلى أنه يمكن أحياناً من رسم السلسلة الزمنية تبين ما إذا كانت السلسلة مستقرة من حيث المتوسط أو من حيث التباين . وتكون السلسلة مستقرة من حيث المتوسط **stationary in the mean** إذا كانت لا تظهر تغيراً في المتوسط مع الزمن (شكل ٥.a). وتكون مستقرة من حيث التباين إذا لم يظهر تغير في التباين (شكل ٥.b) . أما شكل (٥.c) و شكل (٥.d) فتظهران



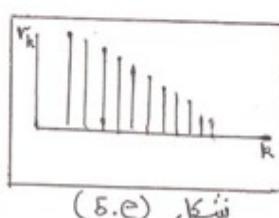
شكل (٥.c)



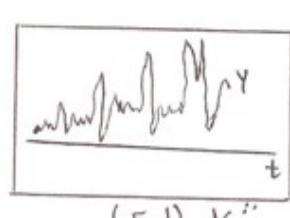
شكل (٥.b)



شكل (٥.a)



شكل (٥.e)



شكل (٥.d)

عدم استقرار في المتوسط والتباين بالترتيب . كذلك إذا كانت السلسلة مستقرة فإن

معامل الارتباط الذاتي لن يكون كبيراً بعد إبطاء أو اثنين أما اذا كانت السلسلة غير مستقرة فإن عدد معاملات الارتباط الذاتي تكون معنوية لعدد كبير من الابطاءات وقد تأخذ شكل اتجاه عام . كما في شكل (e) ٥.

ويعالج عدم الاستقرار في المتوسط بأخذ فرق مناسب*. كما يعالج عدم الاستقرار في التباين باستخدام تحويله مناسبة.

ملحوظة :

إذا كانت السلسلة مستقرة فإن دالة التغير ودالة الارتباط الذاتي تتحققان $\rho_k = \rho_{-k}$ و $\gamma_k = \gamma_{-k}$ بالترتيب أى هما دوال زوجية في k .

البرهان :

بما أن $(\gamma_k = \text{cov}(Y_t, Y_{t+k}))$ لا يعتمد على t فإنه بوضع $t = t - k$ نجد $\gamma_k = \text{cov}(Y_{t-k}, Y_{t-k+k}) = \text{cov}(Y_{t-k}, Y_t) = \gamma_{-k}$

٤، ٥ القابلية للعكس Invertibility

رأى يول ((1927)) أن السلسلة الزمنية التي ترتبط قيمها المتالية بعضها يمكن اعتبارها قد تولدت من سلسلة من المزاحات shocks المستقلة e . وأن هذه المزاحات تمثل مشاهدات عشوائية من توزيع معين (عادة يفترض التوزيع الطبيعي) بمتوسط صفر وتبالين σ_e^2 . ويسمى التالي $e_1, e_{t-1}, e_{t-2}, \dots$ عادة عملية الضجة البيضاء white noise process . هذه الضجة البيضاء يفترض أنها قد تحولت للمشاهدات Y_t بالسلسلة من خلال ما يسمى بالمصفاة الخطية linear filter والتي تقوم بأخذ مجموع مرجع للقيم السابقة لـ e بحيث يعطينا القيمة الحالية لـ Y . بمعنى آخر :

$$\begin{aligned} Y_t &= \mu + e_t + \psi_1 e_{t-1} + \psi_1 e_{t-2} + \dots \\ &= \mu + \psi(B)e_t \end{aligned}$$

* هناك طرق أخرى ذكرنا بعضها في الباب الثاني.

حيث μ متوسط أو مستوى العملية Y_t و

$$\psi(B) = 1 + \psi_1 B + \psi_2 B^2 + \dots$$

لنفرض الآن أن لدينا العملية البسيطة

$$\tilde{Y}_t = e_t - \theta e_{t-1} = (1 - \theta B)e_t \quad \dots (1)$$

حيث \tilde{Y}_t تمثل المحراف Y_t عن متوسط العملية μ .

إذا كتبنا (1) بالشكل

$$e_t = (1 - \theta B)^{-1} \tilde{Y}_t$$

وطبقنا البديهية :

$$(1 - z)^{-1} = 1 + z + z^2 + z^3 + \dots$$

نخلص إلى

$$e_t = \tilde{Y}_t + \theta \tilde{Y}_{t-1} + \theta^2 \tilde{Y}_{t-2} + \theta^3 \tilde{Y}_{t-3} + \dots$$

أو

$$\tilde{Y}_t = e_t - \theta e_{t-1} - \theta^2 e_{t-2} - \theta^3 e_{t-3} - \dots$$

ولكن إذا كان $|\theta| \geq 1$ فإن \tilde{Y}_t (التي تعتمد على القيم السابقة لـ \tilde{Y})

ستكون لانهائية لأن أوزان $\tilde{Y}_{t-1}, \tilde{Y}_{t-2}, \tilde{Y}_{t-3}, \dots$ تتزايد كلما زاد الإبطاء. لهذا

نحتاج لأن نتفادى مثل هذا الوضع بإضافة الشرط $1 < |\theta|$. هذا يجعل السلسلة

$(1 - \theta B)^{-1}$ تقارب. نصف السلسلة في هذه الحالة بأنها تميز بالقابلية للعكس

invertibility أو أنه يمكن عكسها.

خاصية القابلية للعكس مستقلة عن خاصية الاستقرار ، وسنحتاجها لاحقاً في

نقاشنا لنماذج السلسلات الزمنية.

٥، ٥ عملية الانحدار الذاتي Autoregressive Process

عملية (أو نموذج) الانحدار الذاتي برتبة p ، ويرمز لها اختصاراً

بـ AR(p) هي عملية ينظر فيها للقيمة Y_t كدالة في القيم السابقة لـ Y حتى إبطاء p مع وجود خطأ عشوائي e_t وثابت μ . وهي تأخذ الشكل :

...(٥, ١a)

$$Y_t = \mu + \phi_1(Y_{t-1} - \mu) + \phi_2(Y_{t-2} - \mu) + \dots + \phi_p(Y_{t-p} - \mu) + e_t$$

وضع $\tilde{Y} = Y - \mu$

$$\tilde{Y}_t = \phi_1 \tilde{Y}_{t-1} + \phi_2 \tilde{Y}_{t-2} + \dots + \phi_p \tilde{Y}_{t-p} + e_t \quad ... (٥, ١b)$$

وهي تشبه معادلة الانحدار مع الاختلاف في أن المتغيرات "المستقلة" هي القيم السابقة للمتغير ذاته ، ومن هنا كانت التسمية "انحدار ذاتي" .

١، ٥، ٥ نموذج الانحدار الذاتي برتبة ١ AR(1)

لعل أهم نموذج انحدار ذاتي هو النموذج ذو الرتبة ١ :

$$Y_t = \mu + \phi(Y_{t-1} - \mu) + e_t \quad ... (٥, ٢)$$

والذي يفترض فيه أن قيمة السلسلة في الزمن t تعتمد على القيمة في الزمن $t-1$ (بالإضافة للخطأ). لندرس بعض خصائص هذا النموذج دعونا نعرض عن

Y_{t-1} في (٥, ٢) بقيمتها بدلالة Y_{t-2} وعن Y_{t-3} بقيمتها بدلالة Y_{t-1} هذا

$$\begin{aligned} Y_t &= \mu + \phi[\mu + \phi(Y_{t-2} - \mu) + e_{t-1} - \mu] + e_t \\ &= \mu + \phi[\phi(\mu + \phi(Y_{t-3} - \mu) + e_{t-2} - \mu) + e_{t-1}] + e_t \\ &= \mu + \phi^3(Y_{t-3} - \mu) + \phi^2 e_{t-2} + \phi e_{t-1} + e_t \\ &= \mu + \phi^3(Y_{t-3} - \mu) + \sum_{j=0}^{3-1} \phi^j e_{t-j} \end{aligned}$$

وإذا استمررنا في التعويض حتى أبطاء t لنصل لـ Y_0 نجد أن (٥, ٢) يمكن كتابتها بالشكل :

$$Y_t = \mu + \phi^t(Y_0 - \mu) + \sum_{j=0}^{t-1} \phi^j e_{t-j} \quad ... (٥, ٣)$$

بافتراض أن e^t غير مرتبطة ولكل منها متوسط ، نجد بأخذ توقع

الطرفين :

$$\mu_t = \mu + \phi^t (\mu_0 - \mu) \quad \dots(4)$$

$$\text{حيث } \mu_t = E(Y_t)$$

كذلك بما أن الضجة البيضاء e_t غير مرتبطة وكل منها بتباين σ_e^2 فإن

(حيث V ترمز لتبابين)

$$\begin{aligned} V(Y_t) &= \sum_{j=0}^{t-1} \phi^{2j} \sigma_e^2 + \phi^{2t} V(Y_0) \\ &= \sigma_e^2 \left(\frac{1 - \phi^{2t}}{1 - \phi^2} \right) + \phi^{2t} V(Y_0) \end{aligned} \quad \dots(5)$$

باستخدام بدائية كثيرة الحدود :

$$\frac{1 - x^{n+1}}{1 - x} = \sum_{j=0}^n x^j$$

بوضع $n = t - 1$ و $x = \phi^2$

نلاحظ من (4, 5) أن المتوسط لن يكون ثابتاً (مساوياً لـ μ) في الحالة العامة لأن الحد الثاني يعتمد على الزمن t . نفس الشيء في (5) لن يكون التباين ثابتاً لاعتماده على t ما لم توضع شروط إضافية. هذا يعني أن نموذج الانحدار الذاتي برتبة 1 قد لا يكون مستقرًا. سنرى فيما يلي أننا إذا افترضنا $|\phi| < 1$ فإن العملية AR(1) ستكون مستقرة. إذا وضعنا الشرط $|\phi| < 1$ فإن (4, 5) تصبح لـ t كبيرة:

$$\mu_t = \mu \quad |\phi| < 1$$

كذلك يتلاشى الحد الثاني في (٥،٥) ويصبح الحد الأول $\frac{\sigma_e^2}{1-\phi^2}$. أي ان التباين يصبح ثابتاً أيضاً

$$V(Y_t) = \frac{\sigma_e^2}{1-\phi^2} \quad |\phi| < 1$$

بالاستفادة من خصائص المتواالية الهندسية الالانهائية هذا يعني أننا إذا نظرنا للسلسلة الزمنية المشاهدة على أنها نتجمت عن عملية ظلت مستمرة لفترة طويلة وأن $|\phi| < 1$ ، فإن السلسلة ستكون مستقرة منذأخذ أول مشاهدة . عموماً أي عملية AR(1) لها تاريخ لا نهائي وبها $|\phi|$ تكون مستقرة .
إذا كتبنا (٢،٥) بشكل المحرافات عن المتوسط تكون :-

$$\tilde{Y}_t = \phi \tilde{Y}_{t-1} + e_t$$

باستخدام مشغل الإزاحة للخلف :

$$(1 - \phi B) \tilde{Y}_t = e_t$$

ويمـا أن جذر المعادلة $1 - \phi B = 0$ (إذا نظرنا لـ B كمتغير صوري) هو $B = \phi^{-1}$ فـان الشرط $|\phi| < 1$ المطلوب للاستقرار يكافـع القول بأن جذر المعادلة المميـزة $1 - \phi B = 0$ يجب أن يقع خارج دائرة الوحدة (أي يكون أكبر من واحد عددياً).

ليكتمـل إثبات الاستقرار يجب أن يكون التغيـير أيضاً غير معتمـد على الزـمن t . نلاحظ أولاً أنـا إذا استمرـينا في تـكرار التعـويض عن قـيم \tilde{Y} بالقيـم السـابقة كما فعلـنا في الوصول إلى (٣،٥) فإنـا سنصل في النـهاية إلى التـمـثـيل :

$$Y_t = \mu + \sum_{j=0}^{\infty} \phi^j e_{t-j} \quad ... (5.ba)$$

الآن التغير بإبطاء \mathbf{k} :

$$\begin{aligned}
 \gamma_k &= \text{cov}(Y_t, Y_{t+k}) \\
 &= E\left(\mu + \sum_{j=0}^{\infty} \phi^j e_{t-j} - E(\mu + \sum_{j=0}^{\infty} \phi^j e_{t-j})\right) \times \\
 &\quad \left(\mu + \sum_{j=0}^{\infty} \phi^j e_{t+k-j} - E(\mu + \sum_{j=0}^{\infty} \phi^j e_{t+k-j})\right) \\
 &= E\left(\sum_{j=0}^{\infty} \phi^j e_{t-j}\right) \left(\sum_{j=0}^{\infty} \phi^j e_{t+k-j}\right)
 \end{aligned}$$

لأن :

$$\begin{aligned}
 E\left(\mu + \sum_{j=0}^{\infty} \phi^j e_t\right) &= \mu + \sum_{j=0}^{\infty} \phi^j E(e_t) \\
 &= \mu + 0 = \mu
 \end{aligned}$$

كذلك يمكن كتابة

$$\begin{aligned}
 \gamma_k &= E\left(\sum_{j=0}^{\infty} \sum_{j'=0}^{\infty} \phi^j \phi^{j'} e_{t-j} e_{t+k-j'}\right) \\
 &= \sum_{j=0}^{\infty} \sum_{j'=0}^{\infty} \phi^j \phi^{j'} E(e_{t-j} e_{t+k-j'})
 \end{aligned}$$

لكن التوقع في الطرف الأيمن سيساوى صفر بسبب عدم ارتباط قيم المختلفة

ما لم تتساوى المؤشرات j' و $t = k - j'$ أي ما لم تكن

وهي الحالة التي يكون فيها التوقع مساوياً للتبالين σ_e^2
 $E(e_{t-1} e_{t+k-j'}) = V(e_t) = \sigma_e^2$ $j' = j + k$
 وبالتالي

$$\begin{aligned}
\gamma_k &= \sigma_e^2 \sum_{j=0}^{\infty} \phi^j \phi^{j+k} = \sigma_e^2 \sum_{j=0}^{\infty} \phi^{2j+k} \\
&= \sigma_e^2 \phi^k \sum_{j=1}^{\infty} (\phi^2)^j
\end{aligned}$$

وإذا كانت $|\phi| < 1$ فإن

$$\begin{aligned}
\gamma_k &= \sigma_e^2 \phi^k \left(\frac{1}{1-\phi^2} \right) \\
&= \phi^k \gamma_0
\end{aligned} \tag{5, 6b}$$

باستخدام مجموع المتواالية الهندسية اللانهائية التي بها $1 < |\phi|$.

و بما أن الطرف الأيمن لا يعتمد على t فإن التغایر أيضاً ثابت، وهذا يكمل إثبات إن عملية الانحدار الذاتي برتبة 1 تكون مستقرة إذا تحقق الشرط $1 < |\phi|$. لاحظ أنه يمكن أيضاً استخدام (5, 6a) لإثبات كل من المتوسط والتباين مباشرة.

٢، ٥، ٥ عمليه الانحدار الذاتي برتبة p

الحالة العامة لعملية الانحدار الذاتي والتي تكون فيها الرتبة p ويرمز لها ب AR(p) يأخذ فيها النموذج الشكل :

... (5, 7)

$$Y_t = \mu + \phi_1(Y_{t-1} - \mu) + \phi_2(Y_{t-2} - \mu) + \dots + \phi_p(Y_{t-p} - \mu) + e_t$$

ويكن كتابته بدلالة مشغل الإزاحة للخلف :

$$\phi(B)(Y_t - \mu) = e_t$$

حيث :

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$$

وجدنا أن عملية الانحدار الذاتي برتبة 1 تكون مستقرة عندما يتحقق $|\phi| < 1$ وهو يعني أيضاً في تلك العملية عندما يكون جذر المعادلة المميزة (أو الحل بالنسبة ل z)

$$1 - \phi z = 0$$

أكبر عددياً من واحد. لاحظ أن جذر هذه المعادلة وهو z سيحقق $|z| > 1$. إذا تحقق $|\phi| < 1$.

في عملية الانحدار الذاتي برتبة P نجد أيضاً أنه إذا كانت العملية مستقرة فان جميع جذور المعادلة المميزة :

$$1 - \phi_1 z - \phi_2 z - \dots - \phi_p z = 0$$

ستكون عددياً أكبر من 1 أي تقع خارج دائرة الوحدة. ومن الضروري أن نلاحظ أن كون جميع معاملات الانحدار الذاتي أقل من واحد عددياً لا يعني بالضرورة أن العملية مستقرة إذ لابد من التأكد أيضاً من أن جميع جذور معادلة كثيرة الحدود المميزة تقع خارج دائرة الوحدة. في حالة AR(1) ، يؤدي تحقق أحدهما للأخر كما رأينا. لإثبات انه إذا كانت العملية AR(p) مستقرة فان جميع جذور كثيرة الحدود المميزة يجب أن تكون أكبر من 1 ، نلاحظ انه إذا كانت السلسلة Y مستقرة فان تغيرها الذاتي

(بما أن μ ثابت وبالتالي لا يضيف للتغير الذاتي) يتحقق :

$$\begin{aligned} \gamma_k &= Cov(Y_t, Y_{t-k}) \\ &= Cov\left(\sum_{j=1}^p \phi_j Y_{t-j} + e_t, Y_{t-k}\right) \\ &= E\left\{\left[\sum_{j=1}^p \phi_j Y_{t-j}\right] \left[Y_{t-k}\right]\right\} - E\left[\sum_{j=1}^p \phi_j Y_{t-j}\right] E\left[Y_{t-k}\right] \end{aligned}$$

$$\begin{aligned}
&= \sum_{j=1}^p \phi_j [E(Y_{t-j} Y_{t-k}) - E(Y_{t-j}) E(Y_{t-k})] \\
&= \sum_{j=1}^p \phi_j \text{Cov}(Y_{t-j}, Y_{t-k}) \\
&= \sum_{j=1}^p \phi_j \gamma_{t-j-t+k} \\
&= \sum_{j=1}^p \phi_j \gamma_{k-j} \quad k \geq p \dots (5, 8)
\end{aligned}$$

هذه معادله فروق من الدرجة P بمعاملات ثابتة وحلها هو

$$\gamma_k = \sum_{j=1}^p A_j z_j^{-k} \quad k \geq 0 \dots (5, 9)$$

حيث z_j (جذور المعادلة المميزة و A_1, A_2, \dots, A_p ثوابت.

و بما أنه إذا $\infty \rightarrow 0 \rightarrow k$ فان γ_k (وهي حقيقة بدويه لأننا لا نتوقع أن تكون قيم السلسلة التي تبعد عن بعضها بعداً كبيراً مرتبط) وبما أن الـ A_j ثوابت فإن

$$(5, 9) \text{ تقتضى أن تكون } |z_j| > 1 \text{ لكل } j .$$

في العملية (1) AR(1) رأينا أن الاستقرار لا يتحقق ما لم يكن كتابة Y_t بدلالة

مجموع متقارب من الضجة البيضاء* أو الاهتزاز e_t ، وهو ما يتطلب أن تكون

$$|\phi| < 1 \text{ في :}$$

$$Y_t = \mu + \sum_j^\infty \phi^j e_{t-j}$$

وإذا كتبنا هذه العملية بالشكل البديل

$$(1 - \phi B)(Y_t - \mu) = e_t$$

نلاحظ أنها تكون مستقرة فقط إذا أمكن عكس $(1 - \phi B)$ والذي يتحقق

* لأن هذا فقط يضمن أن يكون التباين محدوداً.

عندما تكون $|\phi| < 1$

في حاله عمليه الانحدار الذاتي ذو الرتبه p والتي يمكن كتابتها بالشكل :

$$(1 - \phi B - \phi_2 B^2 - \dots - \phi_p B^p)(Y_t - \mu) = e_t$$

يمكن إثبات انه يمكن كتابتها أيضاً بالشكل :

$$\left(1 - \frac{B}{Z_1}\right) \left(1 - \frac{B}{Z_2}\right) \dots \left(1 - \frac{B}{Z_p}\right) (Y_t - \mu) = e_t$$

حيث Z_1, \dots, Z_p جذور المعادلة المميزة (والتي يمكن لبعضها أن يكون مركباً).

من هذا نرى أنه لم يكن كتابة Y_t كمجموع متقارب في الضجة البيضاء e_t لابد

من أن يكون ممكناً عكس كل الحدود $\left(1 - \frac{B}{Z_j}\right)$ حيث $j = 1, \dots, p$. حيث

ما يتيسر فقط إذا كانت $|Z_j| > 1$ لكل j . لاحظ أن عملية الانحدار الذاتي دائماً قابلة للعكس (بالمعنى المشار إليه في الفصلالجزئي ٤، ٥). ذلك أن السلسلة $(B)(\phi)$ محدودة ولا تحتاج لأى قيود على معاملات الانحدار لضمان قابلية العكس ، إذ يمكن

التعبير عن Y_t (أو e_t) بدلالة عدد محدود من قيم Y السابقة.

٣، ٥، ٤ اختبار الاستقرار

رأينا انه لتكون العملية : $AR(1)$

$$\tilde{Y}_t = \phi \tilde{Y}_{t-1} + e_t$$

أو

$$(1 - \phi B) \tilde{Y}_t = e_t$$

مستقرة لابد أن يتحقق :

$$|\phi| < 1$$

وفي هذه الحالة يتحقق جذر المعادلة المميزة :

$$1 - \phi z = 0$$

الخاصة $|z| > 1$ لأن $|\phi| = 1$ فإن $|z| = |\phi|$ وتكون

Y_t غير مستقرة. وفي هذه الحالة يمكن جعل السلسلة مستقرة بأخذ فرق ذو رتبة 1.

وفي الحالة العامة AR(P)، إذا كان في السلسلة الزمنية عدد r من جذور الوحدة **unit roots** (أي r جذر في المعادلة المميزة تساوي قيمة كل منها 1) فإننا نحتاج لأخذ فرق أو فرق برتبة r للحصول على الاستقرار.

بما أن وجود جذر وحده في السلسلة الزمنية (أو العملية التصادفية المولدة لها) يعني عدم استقرارها ، فإن محاولات التحقق من عدم الاستقرار ترتكز على محاولة اختبار وجود جذر وحده . وهناك عده اختبارات متوفرة لفرض العدم بأن هناك جذر وحده ومن هذه الاختبارات اختبار سارقان - بهارفافا

. Phillip - Peron Bhargava- Sargan غير أن أشهر هذه الاختبارات هو اختبار ديكى - فولر(1979) – Fuller وهو ما سنتناوله باختصار هنا.

نفرض أن لدينا العملية :

$$\tilde{Y}_t = \phi_* \tilde{Y}_{t-1} + e_t$$

حيث e_t ضجة بيضاء من توزيع متوسط 0 وتباعن σ_e^2 مستقلة عن بعض وحيث ϕ_* موجبه . في هذه الحالة العبارة $1 - \phi_* = 0$ تكافع العبارة أن الجذر في المعادلة المميزة $1 - \phi_* z = 0$ يساوى 1 أيضاً . لهذا لاختبار وجود جذر وحده يكفي أن نختبر :

$$H_1 : \phi_* < 1 \text{ مقابل } H_0 : \phi_* = 1$$

لاحظ أننا إذا رفضنا H_0 نستطيع بثقة أن نرفض الفرض بأن

$\phi_* > 1$. لاحظ أيضاً أن رفض H_0 يعني قبول أن السلسلة الزمنية مستقرة.
اختبار ديكى وفولر لاكتشاف وجود جذر الواحدة تم التوصل إليه من تجربة محاكاة
وفكرته الأساسية كما يلى :

(١) تفرض صحة H_0 أي توضع $\phi_* = \phi$ في نموذج العملية ليصبح :

$$\tilde{Y}_t = \tilde{Y}_{t-1} + e_t$$

(٢) تسحب n قيمه من التوزيع الطبيعي لتمثيل الضجة e وتسحب الواحدة تلو الأخرى وكلما سحبت قيمة استخدمت في $\tilde{Y}_t = \tilde{Y}_{t-1} + e_t$ لتوليد قيمة ل \tilde{Y} .

ولتوضيح ذلك أفرض أننا بدأنا ب e_0 حيث $\tilde{Y}_0 = e_0$ قيمه مسحوبة من التوزيع الطبيعي إذا سحبنا القيمة e_1 تتولد لدينا القيمة \tilde{Y}_1 من $\tilde{Y}_0 + e_1$

وبعد سحب القيمة e_2 تتولد \tilde{Y}_2 من ... \tilde{Y}_n وهكذا حتى .

(٣) يجرى تحليل الخدار السلسلة الزمنية المتحصل عليها في (٢) بافتراض النموذج :

$$\tilde{Y}_t = \phi_* \tilde{Y}_{t-1} + e_t$$

وتقدر قيمة ϕ_* ، $\hat{\phi}_*$ مثلاً وخطاؤها المعياري $SE(\hat{\phi}_*)$ ومن ثم تحسب قيمة الإحصائية :

$$t' = \frac{\hat{\phi}_* - 1}{\hat{SE}(\hat{\phi}_*)}$$

(٤) تكرر الخطوات (١) – (٣) آلاف المرات وفي كل مرة تحسب قيمة t' لدينا ذلك بالتوزيع التكراري ل t' (توزيع ديكى – فولر).

(٥) تحدد القيم في التوزيع المشار إليه في (٤) التي تليها أو تسبقها نسبة (صغريرة) من القيم ، مثلاً ٥٪ ، ٢٪ ، ١٪، هذه القيم تمثل القيم الحرجية المقابلة لمستويات معنوية مختلفة والتي على أساسها يرفض فرض العدم بوجود جذر واحد (أي السلسلة غير مستقرة) أو لا يرفض .

يعنى آخر أنتا في اختبار ديكى - فولر نستخدم إحصائية t ولكن التوزيع المرجع هو توزيع ديكى - فولر وليس توزيع t المعروف. والسبب في ذلك أنه في حالة عدم استقرار السلسلة الزمنية فإن توزيع t' لن يتبع توزيع t وإنما يتبع توزيع ديكى - فولر. وقد وجد أن استخدام توزيع t يؤدى - في المتوسط - لرفض H_0 بمعدل أكبر.

وقد تم تعليم اختبار ديكى - فولر ليشمل اختبار وجود عدة جذور وحده في السلسلة الزمنية. ففي العملية

$$\tilde{Y}_t = \phi_1 \tilde{Y}_{t-1} + \phi_2 \tilde{Y}_{t-2} + \dots + \phi_p \tilde{Y}_{t-p} + e_t$$

والتي يمكن كتابتها بدلالة الفرق الأول (حيث $\Delta Y_t = Y_t - Y_{t-1}$) :

$$\Delta \tilde{Y}_t = \phi^* \tilde{Y}_{t-1} + \phi_1 \Delta \tilde{Y}_{t-1} + \phi_2 \Delta \tilde{Y}_{t-2} + \dots + \phi_{p-1} \Delta \tilde{Y}_{t-p+1} + e_t$$

حيث e_t يفترض أنها تتبع التوزيع الطبيعي بمتوسط صفر وتبالن σ^2 (هذا الافتراض يجعل مقدرات المربعات الصغرى تحتفظ بخصائص مقدراتها عند الاستدلال) وحيث :

$$\phi^* = (\phi_1 + \phi_2 + \dots + \phi_p) - 1$$

ويختبر اختبار ديكى - فولر المتدا **Augmented Dickey –Fuller**

test فرض العدم $H_0 : \phi^* = 0$ مقابل الفرض البديل $\phi^* < 0$ فإذا رفض H_0 لصالحة H_1 دعم هذا الادعاء . بأن السلسلة مستقرة .

The Partial autocorrelation coefficient ^{٤ , ٥} معامل الارتباط الذاتي الجزئي من المفاهيم الهامة في تحليل السلسلة الزمنية مفهوم معامل الارتباط الذاتي الجزئي . ويعرف معامل الارتباط الذاتي الجزئي ذو الإبطاء k ويرمز له ب ϕ_{kk} ، بأنه معامل الارتباط الذاتي بين القيم في السلسلة الزمنية التي تبعد عن بعضها ب فترة k

زمنية مع إبقاء آثار الإبطاءات $1, 2, \dots, k-1$ ثابتة . يعني آخر هو الارتباط الشرطي بين Y_t و Y_{t+1}, Y_{t+k-1} في الواقع فإن معامل الارتباط الذاتي الجزئي بإبطاء k هو آخر معامل المحدار جزئي في عملية المحدار ذاتي برتبه k . فمثلاً معامل الارتباط الذاتي الجزئي بإبطاء 2 ، ϕ_{22} ، هو المعامل ϕ_2 في العملية :

$$Y_t = \mu + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + e_t$$

هذا يعني أن معامل الارتباط الذاتي الجزئي ϕ_{kk} في العملية AR(p) يكون صفرًا لكل $k > p$ إذ لا توجد حدود للإبطاءات ... $p+1, p+2, \dots$ في العملية . وإذا نظرنا لمعامل الارتباط الذاتي الجزئي كدالة في الإبطاء k يكون لدينا دالة الارتباط الذاتي الجزئي **partial autocorrelation function** و اختصاراً (PACF) . وتلعب دالة الانحدار الذاتي الجزئي دوراً مهماً في التعريف بالنمذج في تحليل السلاسل الزمنية.

٥ دالة التغایر الذاتی و دالة الارتباط الذاتی لعملیة الانحدار الذاتی
في معادلة (٥) إذا حولنا μ للطرف الأيسر و ضربنا طرفي المعادلة في

ثم أخذنا التوقع نحصل على :

$$\begin{aligned} E(Y_t - \mu)(Y_{t-k} - \mu) &= \phi_1 E(Y_{t-1} - \mu)(Y_{t-k} - \mu) + \phi_2 E(Y_{t-2} - \mu) \\ &\quad (Y_{t-k} - \mu) + \dots + \phi_p E(Y_{t-p} - \mu)(Y_{t-k} - \mu) + E(e_t(Y_{t-k} - \mu)) \end{aligned}$$

أو

$$\text{Cov}(Y_t, Y_{t-k}) = \phi_1 \text{Cov}(Y_{t-1}, Y_{t-k}) + \dots + \phi_p \text{Cov}(Y_{t-p}, Y_{t-k}) + \text{Cov}(e_t(Y_{t-k} - \mu))$$

يعني آخر دالة التغایر الذاتی للعملیة AR(p) تحقق معادلة الفروق :

....(٥، ٩)

$$0 \leq k \leq p \quad \gamma_k = \phi_1 \gamma_{k-1} + \phi_2 \gamma_{k-2} + \dots + \phi_p \gamma_{k-p} + \sigma_e^2 I_k$$

حيث I_k متغير صوري يأخذ القيمة ١ إذا كانت $k = 0$ و ٠ عدا ذلك.

إذا قسمنا $(5, 9)$ على التباعي $\% 70$ نجد أن دالة الارتباط الذاتي للعملية تتحقق معادلة الفروق من الرتبة p :

$$0 \leq k \leq p \quad(5, 10)$$

$$\rho_k = \phi_1 \rho_{k-1} + \phi_2 \rho_{k-2} + \dots + \phi_p \rho_{k-p} + I_k \frac{\sigma_e^2}{\sigma_y^2}$$

وإذا عوضنا $k = 1, 2, \dots, p$ نحصل على ما يسمى بعادلات يول - ووكر
:-Walker equations

$$\begin{aligned}\rho_1 &= \phi_1 + \phi_2 \rho_1 + \dots + \phi_p \rho_{p-1} \\ \rho_2 &= \phi_1 \rho_1 + \phi_2 + \dots + \phi_p \rho_{p-2}\end{aligned}\quad \text{... (11)}$$

$$\rho_p = \phi_1 \rho_{p-1} + \phi_2 \rho_{p-2} + \dots + \phi_p$$

حيث استخدمنا النتيجة التي ذكرناها سابقاً من أنه في العمليات المستقرة يتحقق :

$$\cdot \rho_k = \rho_{-k}$$

وتساعد معادلات يول - ووكر - بين أشياء أخرى - في تقدير معاملات الانحدار الذاتي كما سنرى لاحقاً.

٦٥،٥ طيف القوة The Power Spectrum

في عملية الانحدار الذاتي

تعني \tilde{Y} حيث $\tilde{Y}_t = \phi_1 \tilde{Y}_{t-1} + e_{t-1} + \dots + \phi_p \tilde{Y}_{t-p} + e_t$

الحرف Y عن الثابت μ إذا عوضنا بالالتالي عن Y_t ، \tilde{Y}_t وهكذا نحصل على سلسلة لا نهاية في الضجة أي أن العملية

$$\left(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p\right) \tilde{Y}_t = e_t$$

$$\phi(B)\tilde{Y}_t = e_t \quad \text{أو}$$

اختصاراً تكافع العملية الخطية (أو ما يسمى أحياناً المصفاه الخطية

: (Linear filter

$$\begin{aligned}\tilde{Y}_t &= \sum_{j=0}^{\infty} \psi_j e_{t-j} & \dots (5, 12) \\ &= \psi(B)e_t \\ \psi(B) &= (1 + \psi_1 B + \psi_2 B^2 + \dots + \dots)\end{aligned}$$

وحيث

$$\psi(B) = \phi^{-1}(B) \quad \dots (5, 13)$$

الدالة المولدة للتغير الذاتي
The autocovariance generating function
للعملية الخطية (5, 12) تعرف :

$$\gamma(B) = \sum_{k=-\infty}^{\infty} \gamma_k B^k \quad \dots (5, 14)$$

وهي تعطى التغير الذاتي ذو الرتبة k كمعامل B^{-k} و B^k

إذا كان تباين e_t يساوي σ_e^2 لكل t فإن التغير الذاتي بإبطاء k يكون :

$$\begin{aligned}\gamma_k &= E[\tilde{Y}_t \tilde{Y}_{t+k}] - E(\tilde{Y}_t)E(\tilde{Y}_{t+k}) \\ &= E[\tilde{Y}_t \tilde{Y}_{t+k}] \\ &= E\left[\sum_{j=0}^{\infty} \sum_{j'=0}^{\infty} \psi_j \psi_{j'} e_{t-j} e_{t+k-j'} \right] \\ &= \sum_{j=0}^{\infty} \psi_j \psi_{j+k} E(e_{t-j}^2)\end{aligned}$$

$$= \sigma_e^2 \sum_{j=0}^{\infty} \psi_j \psi_{j+k} \quad \dots (5, 15)$$

ذلك أنه في الضجة البيضاء e يكون $E(e_t) = 0$ لكل t مما يجعل

$$E(\tilde{Y}_t) = 0 \quad \text{من (5, 12) وبالتالي اختفاء الحد الثاني في المعادلة الأولى. كذلك}$$

ما أن e_t و $e_{t'}$ غير مرتبطتين إذا كانت $t \neq t'$ فإن $(e_{t-j} e_{t+k-j'})$

يكون صفرًا ما لم يتساوي المؤشران $j - t$ و $j' - t'$ أي ما لم تكن

$$E(e_{t-j}^2) = j + k \quad \text{أو } k - j = -j \quad \text{وهو}$$

$$\cdot \sigma_e^2$$

الآن إذا عوضنا (5, 15) في :

$$\gamma(B) = \sigma_e^2 \sum_{k=-\infty}^{\infty} \sum_{j=0}^{\infty} \psi_j \psi_{j+k} B^k$$

$$= \sigma_e^2 \sum_{j=0}^{\infty} \sum_{k=-\infty}^{\infty} \psi_j \psi_{j+k} B^k$$

$$= \sigma_e^2 \sum_{j=0}^{\infty} \sum_{k=-j}^{\infty} \psi_j \psi_{j+k} B^k$$

لأنه $k < -j$ يكون $\psi_{j'} = 0$ و $j + k < 0$ إذا كانت $j' < 0$ من

تعريف العملية (5, 12).

كذلك إذا وضعنا $k = j' - j$ بحيث تكون $j + k = j'$ فإن (ما أن

$$(j' = 0 \quad k = -j \quad \text{تكافئ})$$

$$\gamma(B) = \sigma_e^2 \sum_{j=0}^{\infty} \sum_{j'=0}^{\infty} \psi_j \psi_{j'} B^{j'-j}$$

$$= \sigma_e^2 \sum_{j'=0}^{\infty} \psi_{j'} B^{j'} \sum_{j=0}^{\infty} \psi_j B^{-j}$$

$$\begin{aligned}
&= \sigma_e^2 \psi(B) \psi(B^{-1}) \\
&= \sigma_e^2 \psi(B) \psi(F)
\end{aligned} \quad \dots (5, 16)$$

حيث F مشغل الإزاحة للأمام ، لأن يؤدي إلى $B^{-1}Y_t = Y_{t-1}$

نعلم أن طيف القوة بدلالة التغایر الذاتي يمكن كتابته بالشكل (الباب الثالث) :

$$p(f) = 2 \sum_{k=-\infty}^{\infty} \gamma_k \cos 2\pi f k \quad 0 \leq f \leq \frac{1}{2}$$

إذا عرضنا $B = e^{-i2\pi f}$ في (14, 5) نحصل على

$$\begin{aligned}
\gamma(B) &= \sum_{k=-\infty}^{\infty} \gamma_k e^{-i2\pi f k} = \sum_{k=-\infty}^{\infty} \gamma_k (\cos i2\pi f k - i \sin 2\pi f k) \\
&= \sum_{k=-\infty}^{\infty} \gamma_k \cos i2\pi f k
\end{aligned}$$

بما أن زاوية الجيب فردية. وهو نصف طيف القوة . لهذا وإذا استخدمنا الصيغة

البديلة (16, 5) ووضربنا في 2 نحصل على طيف القوة للعملية الخطية (5, 12) :

...(5, 17)

$$p(f) = 2\sigma_e^2 \psi(e^{-i2\pi f}) \psi(e^{i2\pi f}) \quad 0 \leq f \leq \frac{1}{2}$$

٧، ٥، ٥ طيف القوة لعملية الانحدار الذاتي ذات الرتبة p

في العملية $\text{AR}(p)$ نجد من (5, 13) أن

$$\psi(B) = \phi^{-1}(B)$$