

การวิเคราะห์อนุกรมเวลา (Time series Analysis)

3.1 การวิเคราะห์แนวโน้ม

ข้อมูลที่เก็บบันทึกตามเวลา (chronological data) ซึ่งถือเป็นตัวแปรเชิงสุ่ม (Random variable) ที่สุ่มในเวลาที่ยาวเท่า ๆ กัน อันเป็นลักษณะหนึ่งของอนุกรมเวลา ข้อมูลอนุกรมเวลานี้สามารถนำมาวิเคราะห์แนวโน้ม (Long term trend) ของตัวแปรสุ่มว่าในระยะยาวจะมีลักษณะใดคือมีแนวโน้มที่จะเพิ่มขึ้นหรือลดลงในอัตราใด การวิเคราะห์อนุกรมเวลาตามระเบียบวิธีสถิติกระทำโดยพยายามหาสมการคณิตศาสตร์ (Mathematical model) อธิบายข้อมูลอนุกรมเวลาที่มีอยู่ เพื่ออธิบายแนวโน้มด้วยการแสดงความสัมพันธ์ระหว่างตัวแปรเชิงสุ่มกับเวลาวัตถุประสงค์ที่สำคัญในการใช้สมการคณิตศาสตร์คือ ศึกษาความเปลี่ยนแปลง (Deviation) ที่ต่างไปจากแนวโน้ม, เป็นภาพจำลองเหตุการณ์ในอดีตและใช้ในการประมาณค่าตัวแปรในเวลาที่ต้องการ ตลอดจนการพยากรณ์ในอนาคต สมการคณิตศาสตร์ที่สำคัญที่มักนำมาใช้กับการสร้างให้กับแนวโน้มระยะยาวคือ

3.1.1 สมการเส้นตรง (Linear regression equation)

ที่มีรูปสมการ เป็น $Z_t = a + bt$

Z_t เป็น dependent variable ที่ขึ้นกับ t

t เป็น independent variable ในที่นี้หมายถึงช่วงเวลา

a, b เป็นพารามิเตอร์ที่ต้องประมาณค่าจากข้อมูล โดย a หมายถึง

intercept ของเส้นตรง ส่วน b หมายถึง slope ของเส้นตรง

วิธีที่ดีที่สุดในการหาพารามิเตอร์ คือ Least square method

ซึ่งหา a, b จากการแก้สมการ Normal equations

$$\sum Z = Na + b \sum t$$

$$\sum t Z = a \sum t + b \sum t^2$$

ถ้านำสมการเส้นตรงมาใช้ในหน่วยของ logarithm จะมีสมการเป็น

$$\log Z_t = \log a + t \log b$$

สมการ Normal equations ที่ใช้หาค่า $\log a$, $\log b$ ซึ่งเป็นพารามิเตอร์ของสมการจะเปลี่ยนเป็น

$$\sum \log Z_t = N \log a + \log b \sum t$$

$$\sum t \log Z_t = \log a \sum t + \log b \sum t^2$$

๓.๑.๒ สมการ Nonlinear เป็นสมการเส้นโค้งต่างๆ เช่น สมการ Polynomials ที่ dependent variable ขึ้นกับ independent variable มีกำลังมากกว่า ๑, Modified-exponential curve, Logistic curve

จะเห็นได้ว่า มีสมการคณิตศาสตร์หลายชนิดที่สามารถนำมาแสดงความสัมพันธ์ระหว่างตัวแปรเชิงเส้นกับเวลา เพื่อนำมาวิเคราะห์แนวโน้มระยะยาวของข้อมูลอนุกรมเวลา

การเลือกชนิดของสมการคณิตศาสตร์นั้นขึ้นอยู่กับวัตถุประสงค์ในการนำมาใช้ ถ้านำมาใช้แสดงภาพจำลองของเหตุการณ์ในอดีตและวิเคราะห์ความเบี่ยงเบน (deviation) ที่เบนไปจากแนวโน้ม หรือเส้นที่แสดงแนวโน้มของข้อมูล หรือ สมการคณิตศาสตร์ของเส้น trend ควรเป็นรูปง่ายพอควรและแสดงการประมาณที่ทำให้หน้าความแตกต่างมาวิเคราะห์ได้ชัดเจน

อย่างไรก็ดี วิธีตรวจสอบเบื้องต้นอาจทำได้โดยการพิจารณา scatter diagram และค่าความแตกต่าง (difference)

เช่น สร้างสมการเส้นตรง $Z = a + bt$ ถ้าหากว่าค่าความแตกต่างที่ ๑ (first difference) หรือค่าแตกต่างระหว่างค่าตัวแปรในปีปัจจุบันกับปีที่แล้ว มีค่าคงที่ หรือ scatter diagram บนกระดาษกราฟที่มีหน่วยแบบเลขคณิต (Arithmetic paper) มีลักษณะแบบเส้นตรง^๑

สำหรับสมการเส้นตรงในหน่วย log ที่มีรูปเป็น $\log Z_t = \log a + t \log b$ ค่าแตกต่างที่ ๑ ของตัวแปรมีแนวโน้มที่จะลดลงหรือเพิ่มขึ้นในเปอร์เซ็นต์ที่คงที่

หรือค่าแตกต่างที่ ๑ ของค่า log ของตัวแปรคงที่ ถ้าดูจาก scatter diagram บน semi-logarithmic paper จะมีลักษณะแนวโน้มเป็นเส้นตรง¹

๓.๒ การวิเคราะห์ส่วนเบี่ยงเบน

เมื่อหาสมการคณิตศาสตร์ที่เป็นตัวแทนแนวโน้มหรือเป็นภาพจำลองในอดีตแล้ว มักจะวิเคราะห์ส่วนที่แตกต่างไปจากแนวโน้ม การสร้างแบบจำลองหรือสมการคณิตศาสตร์สำหรับค่าแตกต่างนั้นจะอาศัยทฤษฎีของ stationary time series ซึ่งกล่าวว่า "ในกรณีที่ข้อมูลแสดงแนวโน้มในระยะยาวที่สามารถอธิบายได้ด้วยความสัมพันธ์ทางคณิตศาสตร์แบบง่าย ๆ แล้ว ส่วนที่เบนไปจากแนวโน้มให้ถือว่ามีความเป็น stationary"² แบบจำลองที่ได้จึงเป็น Linear Stationary Model ซึ่งเป็นแบบจำลองประเภทหนึ่งของ Stochastic Model หรือ Stochastic process

ดังนั้น stationary Model จึงเป็น Model ที่สร้างให้กับอนุกรมส่วนที่แตกต่างหรือเบี่ยงเบนไปจากระดับหรือค่าคงที่ค่าหนึ่งของอนุกรมเวลานั้นหรือเป็นการสร้างแบบจำลองที่ต้องการวิเคราะห์เกี่ยวกับระดับของอนุกรมเวลา

Linear Stationary Model ที่มักนำมาวิเคราะห์ในทางปฏิบัติมากที่สุดคือ

1. AUTOREGRESSIVE MODEL
2. MOVING AVERAGE MODEL
3. MIXED AUTOREGRESSIVE-MOVING AVERAGE MODEL

แบบจำลองทั้ง ๓ นี้ล้วนแต่แสดงค่าแต่ละ เทอมในอนุกรมในรูปของค่าอนุกรมในหน่วยเวลาที่ล่วงมาแล้วกับ shock ที่เป็นอิสระ ซึ่งโดยปกติค่าสังเกตแต่ละค่าในอนุกรมเวลานั้นมักไม่เป็นอิสระ ค่าสังเกตในอดีตจึงควรแสดงความสัมพันธ์กับค่าสังเกตในปัจจุบัน ความไม่เป็นอิสระนี้เองที่ขัดกับทฤษฎีเรสชันจึงต้องแปลงความสัมพันธ์นี้ให้อยู่ในรูปของ shocks ที่เป็นอิสระซึ่งเป็นอนุกรมเวลาของตัวแปรที่อิสระนั่นเอง

๑. AUTOREGRESSIVE MODEL เป็นแบบจำลองที่ใช้ในทางปฏิบัติมากที่สุด เพราะแบบจำลองนี้ค่าของอนุกรมในปัจจุบันจะแสดงความสัมพันธ์กับค่าของอนุกรม

¹Croxton and others, Applied General Statistics (New Delhi, 1969) p282-283

²P. Holgate, "Time Series Analysis Applied to wildfowl Counts", Journal of the Royal Statistical Society XV No1 (1966), p15



ในอิตีในรูปของ

$$\tilde{z}_t = \phi_1 \tilde{z}_{t-1} + \phi_2 \tilde{z}_{t-2} + \dots + \phi_p \tilde{z}_{t-p} + a_t \quad (๑)$$

โดย \tilde{z}_t เป็นค่าเบี่ยงเบนจากแนวโน้มในเวลาที t

a_t คือ shock ในเวลาที t หรือค่าผิดพลาด (error term)

p คือจำนวนเทอมของอนุกรม z ในอิตีที่นำมาใช้ในการสร้างสมการ

$\phi_1, \phi_2, \dots, \phi_p$ เป็นพารามิเตอร์ที่ต้องประมาณจากข้อมูล

วิธีหนึ่งของการประมาณพารามิเตอร์นี้คือ วิธี yule-walker estimate ซึ่งจะกล่าวโดยละเอียดต่อไปในหัวข้อ การประมาณค่าพารามิเตอร์ของสมการ AUTOREGRESSIVE และโดยทั่วไปแล้วเรียกสมการ (๑) ว่า AUTOREGRESSIVE ที่มี ORDER p ให้สัญลักษณ์เป็น AR(p)

๒. MOVING AVERAGE MODEL เป็นแบบจำลองที่แสดงค่าอนุกรมเวลาของตัวแปร z_t หรือส่วนเบี่ยงเบนในรูปของค่าผิดพลาดหรือ random shock a_t ในอิตี q ค่า

รูปของ MOVING AVERAGE ORDER q หรือ MA(q) คือ

$$\tilde{z}_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}$$

โดย $\theta_1, \theta_2, \dots, \theta_q$ เป็นพารามิเตอร์ที่ต้องประมาณจากข้อมูล

๓. MIXED AUTOREGRESSIVE-MOVING AVERAGE MODEL

เป็นแบบจำลองที่สร้างให้กับข้อมูลที่มีลักษณะผสมระหว่าง AUTOREGRESSIVE กับ MOVING AVERAGE MODEL จึงมีรูปสมการเป็น

$$\tilde{z}_t = \phi_1 \tilde{z}_{t-1} + \dots + \phi_p \tilde{z}_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q}$$

ดังนั้น $\phi_1, \phi_2, \dots, \phi_p, \theta_1, \theta_2, \dots, \theta_q$ ต้องประมาณจากข้อมูล

แบบจำลองนี้เรียกสั้นๆว่า ARMA(p,q)

ในทางปฏิบัติแล้ว stationary time series ที่ได้จาก AUTOREGRESSIVE MODEL หรือ MOVING AVERAGE MODEL หรือ MIXED AUTOREGRESSIVE-MOVING AVERAGE MODEL มักจะมี ORDER p, q ไม่เกิน ๒

ถึงได้กล่าวแล้วว่า จุดประสงค์ที่สำคัญในการหาแบบจำลองของข้อมูลที่มีอยู่ คือ เพื่อใช้แบบจำลองอธิบายความสัมพันธ์ระหว่างตัวแปรอิสระกับตัวแปรไม่อิสระ

ในรูปที่เป็นสูตรที่สามารถคำนวณเป็นตัวเลขได้ แบบจำลองที่แท้จริงต้องเป็นตัวแทนของข้อมูล และมีความใกล้เคียงความจริง เพื่อใช้ประมาณค่าและพยากรณ์ในเวลาที่ต้องการ การเลือกแบบจำลองในการวิเคราะห์อนุกรมเวลาจึงเป็นสิ่งสำคัญ ด้วยเหตุนี้การทดสอบข้อมูลก่อนใช้แบบจำลองจริงเพื่อช่วยให้เห็นลักษณะของแบบจำลองที่เหมาะสมจึงเป็นสิ่งจำเป็นอย่างยิ่งในการเลือกแบบจำลอง

สำหรับการสร้าง Linear Stationary Model นั้นมีวิธีการทดสอบเบื้องต้นที่เป็นแนวทางในการเลือกแบบจำลองเป็นขั้น ๆ ดังนี้

1. ทดสอบความเป็นอิสระระหว่างค่าสังเกตในอนุกรมเวลากับค่าข้างเคียงหรือค่าสังเกตที่เกิดขึ้นต่างเวลากันโดยใช้สัมประสิทธิ์ของสหสัมพันธ์แบบ serial

(Serial correlation coefficient) r_k^* เป็นค่าสถิติที่นำมาทดสอบความเป็นอิสระอย่างมีนัยสำคัญ โดยเทียบค่า r_k^* ที่คำนวณได้กับค่าในตารางสหสัมพันธ์แบบ serial ของ R.L. Anderson Table ด้วย degree of freedom $N-k$

เมื่อ N = จำนวนค่าสังเกตทั้งหมดที่นำมาสร้างสมการ

k = จำนวนเวลาที่ต่างกันหรือจำนวนเวลาที่ล่าหลัง

ถ้าวัดค่า r_k^* ที่คำนวณได้เกินกว่าค่าใน R.L. Anderson Table แสดงว่าปฏิเสธข้อสมมติที่ว่า อนุกรมเวลามีความเป็นอิสระ หรืออนุกรมเวลานั้นไม่เป็น random series นั่นคือ แต่ละเทอมในอนุกรมเวลามีความไม่เป็นอิสระซึ่งกันและกัน ค่าของอนุกรมเวลาที่ดวงมาแล้วสามารถนำมาใช้ประมาณค่าอนุกรมเวลาในปัจจุบันได้

ค่า r_k^* ดังกล่าวจะหาได้จากสูตร

$$r_k^* = \frac{\sum_{t=1}^{N-k} z_t z_{t+k} - \left(\sum_{t=1}^{N-k} z_t \right) \left(\sum_{t=k+1}^N z_t \right) / (N-k)}{\sqrt{\left[\sum_{t=1}^{N-k} z_t^2 - \left(\sum_{t=1}^{N-k} z_t \right)^2 / (N-k) \right] \left[\sum_{t=k+1}^N z_t^2 - \left(\sum_{t=k+1}^N z_t \right)^2 / (N-k) \right]}}$$

โดย k เป็นจำนวนเวลาที่ต่างกันหรือจำนวนเวลาที่ล่าหลัง r_k^* จะมีการระหว่าง -1 กับ 1 ถ้า r_k^* มีค่าใกล้ 1 แสดงว่าองค์ความไม่เป็นอิสระของเทอมต่าง ๆ ในอนุกรมเวลามีมากและแปรผันในทางบวก ตรงกันข้ามถ้า r_k^* มีค่าใกล้ -1 แสดงว่า

องค์ความไม่เป็นอิสระของเทอมต่าง ๆ ในอนุกรมเวลามีมากแต่เป็นไปในทางตรงกันข้ามหรือกลับกัน

2. คุณลักษณะความสัมพันธ์ของอนุกรมเวลาที่เกิดขึ้นต่างเวลากว่าเป็นไปในแบบเส้นตรงพอที่จะสร้างควย Linear Stationary model หรือไม่ การดูความสัมพันธ์ดังกล่าวอาศัยจาก scatter diagram ของ joint probability distribution ของ Z_t กับ Z_{t+k} โดยนำค่าแต่ละคู่ที่เกิดขึ้นต่างเวลากัน k หน่วยเวลามาเขียนลงในแผนภาพ

เมื่อพลอตแล้วแสดงการ แจกแจงรวมในแนว เส้นตรงลงมา แสดงว่า ในช่วงเวลาที่ห่างกัน k หน่วยเวลา ค่าที่อยู่ใกล้กัน k หน่วยเวลามีความสัมพันธ์แบบเส้นตรงที่แปรในทางกลับกัน ดังรูปที่ 3.1.1 เมื่อ $k=1$ Z_t กับ Z_{t+k} มีความสัมพันธ์แบบเส้นตรงเป็นลบ ถ้าเส้นตรงชี้ขึ้นแสดงว่า ค่าข้างเคียง k หน่วยเวลานี้มีความสัมพันธ์แบบเส้นตรงแปรในทางบวก ดังรูปที่ 3.1.2 แสดงความสัมพันธ์แบบเส้นตรงเป็นบวก เมื่อ $k=2$

3. คุณลักษณะของ AUTOREGRESSIVE MODEL, MOVING AVERAGE MODEL และ MIXED AUTOREGRESSIVE-MOVING AVERAGE MODEL จากแผนภาพ autocorrelation function ที่แสดงความสัมพันธ์ระหว่าง lag k กับ autocorrelation coefficient

ค่าของ autocorrelation coefficient จะประมาณจากสูตร

$$r_k = \frac{c_k}{c_0} = \hat{\rho}_k$$

โดย
$$c_k = \frac{1}{N} \sum_{t=1}^{N-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z}), k=0,1,2,\dots,K$$

ให้ r_k เป็นค่าประมาณของ autocorrelation coefficient ที่ lag k หรือ $\hat{\rho}_k$

c_k เป็นค่าประมาณของ autocovariance หรือ $\hat{\gamma}_k$


\bar{Z} เป็น mean ของอนุกรมเวลาของค่าสังเกตทั้งหมด

K เป็นค่าที่มากที่สุดของ k ในทางปฏิบัติค่า k เป็น 20 ก็เพียงพอที่จะ


เห็นลักษณะ autocorrelation function ที่จะเป็แนวทางในการสร้างสมการ¹

¹Box&Jenkins, Time Series Analysis forecasting and control,

ภาพที่ ๓.๑



ภาพที่ ๓.๑.๑ scatter diagram ที่ lag 1 แสดงความสัมพันธ์ระหว่าง Z_t กับ Z_{t+1} เป็นลบ



ภาพที่ ๓.๑.๒ scatter diagram ที่ lag 2 แสดงความสัมพันธ์ระหว่าง Z_t กับ Z_{t+2} เป็นบวก

ค่าของ r_k มีค่าไม่เกิน ๑ เสมอ
(แผนภาพ)

ถ้ากราฟ autocorrelation function มีลักษณะ damped
exponentials หรือ damped sine wave หรือทั้ง damped exponentials
และ damped sine wave รวมกัน แสดงถึงความไม่สิ้นสุด

(Infinity) ของ autocorrelation คือไม่ว่า lag k มีค่ามากเท่าใด
ค่าของ r_k ยังมีค่าไม่ใกล้ ๐ หรือ tails off คือค่า r_k สูงมากเมื่อ k มีค่าน้อย
และคาดลดลงอย่างช้าๆ เกือบถึง ๐ เมื่อค่า k มีค่าเพิ่มขึ้นมากๆ แบบจำลอง
ที่เหมาะสมกับข้อมูลที่มีลักษณะ autocorrelation ดังกล่าวคือ AUTOREGRESSIVE
MODEL แต่ถ้า autocorrelation function แสดงลักษณะตรงข้ามกับลักษณะ
แรกคือมีลักษณะ finite หรือ cuts off ซึ่งค่า r_k ใน lag k ใดๆ จะมีค่า
ใกล้ ๐ นั่นคือ r_k มีค่าลดลงอย่างรวดเร็ว MOVING AVERAGE MODEL
จะเหมาะสมกับข้อมูลที่มีลักษณะดังกล่าวนี้

สำหรับ autocorrelation function ของ MIXED
AUTOREGRESSIVE-MOVING AVERAGE MODEL นั้นมีลักษณะคล้าย
autocorrelation function ของ AUTOREGRESSIVE MODEL
คือ infinite หรือ tails off ที่มีลักษณะ damped exponentials หรือ
damped sine wave หรือเป็นทั้ง damped exponentials กับ damped
sine wave หลัง q-p lags แล้วเป็นต้นไป

๔. คุณลักษณะของ partial autocorrelation function
เพื่อช่วยในการหา order ของแบบจำลองทั้ง ๓ คือ หา p ถ้าลักษณะ r_k เป็นแบบ AR
หา q ถ้าลักษณะ r_k เป็นแบบ MA และหาทั้ง p และ q ถ้าลักษณะ r_k
เป็น ARMA

ลักษณะของ partial autocorrelation function จะดูได้จาก
แผนภาพแสดงความสัมพันธ์ระหว่าง lag k กับ partial autocorrelation
function ϕ_{kk} ซึ่ง ϕ_{kk} นี้ประมาณจากสมการ

$$\hat{\phi}_{kj} = \hat{\phi}_{k1} r_{j-1} + \dots + \hat{\phi}_{k(k-1)} r_{j-k+1} + \hat{\phi}_{kk} r_{j-k}, \quad j=1, 2, \dots, k$$

$$\text{หรือ} \begin{bmatrix} 1 & r_1 & r_2 & \dots & r_{k-1} \\ r_1 & 1 & r_1 & \dots & r_{k-2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ r_{k-1} & r_{k-2} & r_{k-3} & \dots & 1 \end{bmatrix} \begin{bmatrix} \hat{\phi}_{k1} \\ \hat{\phi}_{k2} \\ \vdots \\ \hat{\phi}_{kk} \end{bmatrix} = \begin{bmatrix} r_1 \\ r_2 \\ \vdots \\ r_k \end{bmatrix}$$

$$\text{หรือจากสูตร} \quad \hat{\phi}_{kk} = \begin{cases} r_1 & , k=1 \\ \frac{r_k - \sum_{j=1}^{k-1} \hat{\phi}_{k-1,j} r_{k-j}}{1 - \sum_{j=1}^{k-1} \hat{\phi}_{k-1,j} r_j} & , k=2, 3, \dots, K \end{cases}$$

$$\hat{\phi}_{kj} = \hat{\phi}_{k-1,j} - \hat{\phi}_{kk} \hat{\phi}_{k-1,k-j} \quad , j=1, 2, \dots, k-1$$

ลักษณะของ partial autocorrelation function ของแบบจำลองแต่ละชนิด มักมีลักษณะตรงข้ามกับลักษณะของ autocorrelation function ของแบบจำลอง ชนิดนั้น ยกเว้นแบบจำลอง MIXED AUTOREGRESSIVE-MOVING AVERAGE เช่น แบบจำลอง AUTOREGRESSIVE ซึ่งมีลักษณะ autocorrelation function แบบ infinite หรือ damped exponentials หมายถึงค่า autocorrelation function จะลดลงอย่างช้า ๆ จนเกือบถึง 0 เมื่อ k มีค่าสูงมาก ๆ แต่ partial autocorrelation function ของแบบจำลอง AUTOREGRESSIVE จะมีค่าลดลงอย่างรวดเร็วใน lag k น้อย ๆ เรียกว่ามีลักษณะ **cuts off** หรือ finite และมีค่าเป็น 0 หรือเกือบถึง 0 หลุดจาก lag ใด lag หนึ่ง ถ้าหลัง lag p ไปค่า partial autocorrelation function เป็น 0 แบบจำลอง AUTOREGRESSIVE นี้ควรมี order เป็น p สรุปได้ว่า ถ้าลักษณะ partial autocorrelation function ของแบบจำลอง AUTOREGRESSIVE ไม่เป็น 0 สำหรับ k ที่มีค่าน้อยกว่าหรือเท่ากับ p นอกนั้นเป็น 0

$$\text{คือ } \hat{\phi}_{kk} \neq 0 \quad , k \leq p$$

$$\text{และ } \hat{\phi}_{kk} = 0 \quad , k > p$$

แบบจำลอง AUTOREGRESSIVE นั้นมี order เป็น p

หรือ AR(p) model

ในกรณีที่ partial autocorrelation function มีลักษณะเป็น

infinite แบบ damped exponentials หรือ damped sine wave หรือเป็น

ทั้ง damped exponentials กับ damped sine wave รวมกัน อันเป็นลักษณะ

tails off ที่ตรงกันข้ามกับลักษณะ autocorrelation function ของ

MOVING AVERAGE MODEL ซึ่งเป็น finite หลังจาก lag q แล้วมีค่าเป็น 0

q จึงควรเป็น order ของ MOVING AVERAGE MODEL

ส่วนลักษณะของ partial autocorrelation function ของแบบจำลอง

MIXED AUTOCORRELATION-MOVING AVERAGE นั้นจะมีลักษณะคล้ายลักษณะ

autocorrelation function ของ model นี้ อีก คือเป็น infinite

แบบ damped exponentials หรือ damped sine wave หรือเป็นทั้ง damped

exponentials กับ damped sine wave รวมกัน หลัง $p-q$ lags ไป คือยัง

คงเป็น tails off

ในการคัดเลือกของ autocorrelation function และ partial

autocorrelation function เพื่อช่วยในการเลือก model ค่า k ที่สูงที่สุด

คือ 20 หรือ $k=20$

ภาพที่ ๓.๒ แสดงลักษณะ damped exponentials ต่างๆ

ดังกล่าวนั้นในทางปฏิบัติค่า p, q มีค่าไม่เกิน ๒ ดังนั้นจึงควรสนใจ

ลักษณะและคุณสมบัติของ AUTOREGRESSIVE MODEL, MOVING AVERAGE

MODEL และ MIXED AUTOREGRESSIVE MODEL ที่มี ORDER ไม่เกิน ๒ โดยศึกษา

จาก autocorrelation function, partial autocorrelation function

และเงื่อนไขที่ทำให้เป็น stationary model แบบจำลองที่น่าสนใจศึกษาคือ


๑. AUTOREGRESSIVE MODEL ที่มี ORDER เป็น 1

๒. AUTOREGRESSIVE MODEL ที่มี ORDER เป็น 2


๓. MOVING AVERAGE MODEL ORDER 1

๔. MOVING AVERAGE MODEL ORDER 2


ภาพที่ ๓.๒ ลักษณะที่สำคัญของ autocorrelation function ρ_k และ partial autocorrelation function ϕ_{kk}




ลักษณะdamped exponential to zeroหรือ smooth ทางบวก



ลักษณะdamped exponention in sign หรือ oscillate in sign



ลักษณะ damped exponential ทางคานลบ



ลักษณะ damped exponential แบบ sine waves

ลักษณะคั้งกลารวมเรียกว่า infiniteหรือ tails off

5. THE FIRST-ORDER AUTOREGRESSIVE--FIRST-ORDER MOVING AVERAGE MODEL

1. AUTOREGRESSIVE MODEL ที่มี ORDER 1

รูปสมการคือ $\tilde{z}_t = \rho_1 \tilde{z}_{t-1} + a_t$
 ถ้า ρ_1 ของ process นี้คาระหว่าง -1 ถึง 1 process นั้นเป็น Stationary

ลักษณะของ autocorrelation function

เนื่องจาก ρ_k ต้อง satisfy สมการ

$$\rho_k = \rho_1 \rho_{k-1}, \quad k > 0$$

$$\text{ซึ่งมีค่าตัว unknown เป็น } \rho_k = \rho_1^k, \quad k \geq 0$$

$$\therefore \rho_0 = 1$$

เมื่อ k มีค่ามาก ค่า autocorrelation function ยังมีค่าลดลงตามลำดับ
 มีลักษณะเป็น exponential และสรุปได้ว่า

เมื่อ ρ_1 มีค่าเป็นบวก autocorrelation function จะมีลักษณะ
 exponential จนถึงค่าที่ต่ำที่สุดคือศูนย์ (exponentially to zero)

เมื่อ ρ_1 มีค่าเป็นลบ autocorrelation function จะมีลักษณะ
 เป็น exponentially to zero เหมือนกรณี

ρ_1 มีค่าเป็นบวก แต่ค่าของ ρ_k จะสลับระหว่างค่าบวกและค่าลบตามลำดับของ
 k (oscillate in sign)

ลักษณะดังกล่าวจะเห็นได้จากรูปที่ 3.3

2. AUTOREGRESSIVE MODEL ที่มี ORDER 2

$$\text{รูปสมการคือ } \tilde{z}_t = \rho_1 \tilde{z}_{t-1} + \rho_2 \tilde{z}_{t-2} + a_t$$

เงื่อนไขที่ทำให้ process เป็น Stationary (stationary condition)


คือรากของสมการ characteristic $\rho(B) = 1 - \rho_1 B - \rho_2 B^2 = 0$ ต้องมีค่าอยู่
 นอก unit circle นั่นคือ ค่าพหุนามมีเทออร์ ρ_1 และ ρ_2 ต้องตกอยู่ภายใน
 บริเวณเนื้อที่รูปสามเหลี่ยม (triangular region) ในภาพ 3.4.1

ลักษณะของ autocorrelation, partial autocorrelation function


ลักษณะของ autocorrelation function ของ AR (2)

ไม่ว่ารากของสมการ characteristic จะเป็นค่าจริงหรือ complex ก็ยังคงมี


ภาพที่ ๓.๓ ลักษณะ autocorrelation function จาก AUTOREGRESSIVE PROCESS ที่มี ORDER เป็น ๑




$$\tilde{z}_t = 0.8 \tilde{z}_{t-1} + a_t$$



ลักษณะ autocorrelation function exponential to zero



$$\tilde{z}_t = -0.8 \tilde{z}_{t-1} + a_t$$



ลักษณะ autocorrelation function แบบ oscillate in sign

ลักษณะ infinite หรือ tails of

๑. การรากของสมการ characteristic คือ $\phi(B) = 1 - \phi_1 B - \phi_2 B^2 = 0$ มีค่าจริง autocorrelation function จะมีลักษณะเป็นลักษณะผสมระหว่าง damped exponentials (Mixture of damped exponentials)

หรือเมื่อ $\phi_1^2 + 4\phi_2 < 0$ ค่านี้จะอยู่ในบริเวณเนื้อที่ที่ ๑ และ ๒ ซึ่งอยู่เหนือเขตของพาราโบลา (parabolic boundary) โดยเฉพาะในพื้นที่เขต ๑

autocorrelation function ยังคงเป็นบวก ในขณะที่มีลักษณะเป็น damped out ค่าย ส่วนในพื้นที่ที่ ๒ ค่า autocorrelation function จะสลับระหว่างค่าบวกและลบในขณะที่ damped out

ลักษณะต่างๆดังกล่าวแสดงในรูป ๓.๔.๑

๒. การรากของสมการ characteristic $\phi(B) = 1 - \phi_1 B - \phi_2 B^2 = 0$ เป็น complex หรือ เมื่อ $\phi_1^2 + 4\phi_2$ มีค่าน้อยกว่า ๐. AUTOREGRESSIVE PROCESS ORDER 2 จะมีลักษณะเป็นแบบ periodic เทียม (pseudo periodic behavior) ลักษณะนี้ทำให้ autocorrelation function มีลักษณะเป็น damped sine wave ซึ่งดูได้จากภาพที่ ๓.๔.๑ ในพื้นที่เขต ๓ และ ๔


ในพื้นที่เขต ๔ ค่าของ autocorrelation function เริ่มด้วยค่าบวกใน $2-3$ lag แรก แต่ในพื้นที่เขต ๓ ค่าของ autocorrelation function มักจะมีค่า switches sign จาก lag ๐ ถึง lag 1

สำหรับลักษณะของ partial autocorrelation function ของ AUTOREGRESSIVE MODEL ที่มี ORDER เป็น ๒ จะมีลักษณะ cuts off หลังจาก lag 2 เป็นต้นไป ไม่ว่า รากสมการ characteristic จะมีลักษณะเช่นใด ก็จะเห็นในภาพ ๓.๔.๑


การประมาณค่าพารามิเตอร์ของสมการ AUTOREGRESSIVE

จากสมการ Yule-walker ซึ่งแสดงความสัมพันธ์ระหว่าง พารามิเตอร์กับ autocorrelation function ค่าประมาณของพารามิเตอร์ได้จากการแก้สมการ Yule-walker เรียกค่าพารามิเตอร์นี้ว่า Yule-walker estimate


ภาพที่ ๓.๔ ลักษณะ autocorrelation function ρ_k และ partial autocorrelation function ϕ_{kk} ของแบบจำลอง



ภาพที่ ๓.๔.๑ ลักษณะ ρ_k และ ϕ_{kk} สำหรับแบบจำลอง AR (2)



ภาพที่ ๓.๔.๒ ลักษณะ ρ_k และ ϕ_{kk} สำหรับแบบจำลอง MA(2)



ภาพที่ ๓.๔.๓ ลักษณะ ρ_k และ ϕ_{kk} สำหรับแบบจำลอง ARMA(1, 1)

Yule-Walker estimate ของ AR process order p

ในรูปmatrix เป็น

$$\hat{\phi} = R^{-1} r$$

โดยที่

$$R = \begin{bmatrix} 1 & r_1 & \dots & r_{p-1} \\ r_1 & \ddots & \dots & r_{p-2} \\ \vdots & \vdots & \ddots & \vdots \\ r_{p-1} & r_{p-2} & \dots & 1 \end{bmatrix}$$

$$r = \begin{bmatrix} r_1 \\ r_2 \\ \vdots \\ r_p \end{bmatrix}$$

เมื่อ r เป็น vector ของ autocorrelation function ของ lag ที่ k=1,2,...,p

ดังนั้น พารามิเตอร์ของ AR process order 1 คือ

$$\hat{\phi}_1 = r_1 = \text{ค่าประมาณ autocorrelation function lag } k=1$$

สำหรับ AR process order 2 ค่าพารามิเตอร์ได้จากการแก้สมการ

$$r_1 = \hat{\phi}_1 + \hat{\phi}_2 r_1$$

$$r_2 = \hat{\phi}_1 r_1 + \hat{\phi}_2$$

เมื่อแก้สมการทั้ง ๒ จะได้ค่าพารามิเตอร์ในรูปของ

$$\hat{\phi}_1 = \frac{r_1(1-r_2)}{1-r_1^2}$$

$$\hat{\phi}_2 = \frac{r_2-r_1^2}{1-r_1^2}$$

โดย r₁, r₂ คือค่าประมาณของ autocorrelation function ที่ lag k=1,2

ตามลำดับ

๓. MOVING AVERAGE MODEL ORDER 1

รูปสมการคือ $\hat{z}_t = a_t - \theta_1 a_{t-1}$

process เป็น stationary สำหรับทุกค่าของ θ_1

ลักษณะของ autocorrelation function

เนื่องจาก autocorrelation function มีค่าเป็น

$$\rho_k = \begin{cases} -e_1 & , k=1 \\ \frac{-e_1}{1+e_1^2} & \\ 0 & , k \geq 2 \end{cases}$$

ดังนั้น autocorrelation function จะมีลักษณะ cuts off หลังจาก lag 1 ส่วน partial autocorrelation function ได้จาก

$$\phi_{kk} = -e_1^k \{1 - e_1^2\} / \{1 - e_1^{2(k+1)}\}$$

ดังนั้น ϕ_{kk} มีค่าน้อยกว่า e_1^k

จึงสรุปลักษณะ partial autocorrelation function ของ

MOVING AVERAGE ORDER 1 ได้ดังนี้

เมื่อ e_1 มีค่าเป็นบวก partial autocorrelation function มีลักษณะเป็น damped exponentials ทางคานลบอย่างเคียว

เมื่อ e_1 มีคาลบ partial autocorrelation function มีลักษณะเป็น damped exponentials ที่สลับคานวกกับคาลบคาน

ลำดับของ k

4. MOVING AVERAGE MODEL ORDER 2

รูปสมการ $\tilde{z}_t = a_t - e_1 a_{t-1} - e_2 a_{t-2}$

process เป็น stationary โคหุคคาคของ e_1 และ e_2

ลักษณะของ autocorrelation function

เนื่องจาก autocorrelation function มีค่าเป็น

$$\rho_1 = \frac{-e_1(1-e_2)}{1+e_1^2+e_2^2} \quad , \quad \rho_2 = \frac{-e_2}{1+e_1^2+e_2^2}$$

$$\rho_k = 0 \quad , \quad k \geq 3$$

ดังนั้น autocorrelation function จึงมีลักษณะ cuts off หลัง lag 2

ลักษณะของ partial autocorrelation function สรุปได้ดังนี้

ตารางของสมการ characteristic $1 - e_1 B - e_2 B^2 = 0$ เป็นจริง

ลักษณะของ partial autocorrelation function จะ damp แบบ exponential ตารางของสมการ characteristic เป็น complex ลักษณะของ

partial autocorrelation function จะเป็น damped sine wave
 ลักษณะ partial autocorrelation function ของ MOVING
 AVERAGE MODEL ORDER 2 จึงเหมือนกับ autocorrelation function
 ของ AUTOREGRESSIVE MODEL ORDER 2 อย่างไรก็ตาม จะคุณลักษณะของ
 autocorrelation function และ partial autocorrelation
 function ของ MA (2) ได้ที่ภาพที่ ๓.๔.๒

5. THE FIRST-ORDER AUTOREGRESSIVE-FIRST-ORDER MOVING
 AVERAGE MODEL

มีรูปสมการเป็น $Z_t - \phi_1 Z_{t-1} = a_t - \theta_1 a_{t-1}$
 process เป็น stationary เมื่อ $-1 < \phi_1 < 1$

autocorrelation function หาได้จาก

$$\rho_1 = \frac{(1 - \phi_1 \theta_1)(\phi_1 - \theta_1)}{1 + \theta_1^2 - 2\phi_1\theta_1}, \quad \rho_2 = \phi_1 \rho_1$$

ลักษณะของ autocorrelation function สรุปได้ดังนี้

- ถ้า ϕ_1 เป็นบวก ลักษณะของ autocorrelation function เป็น exponential ที่ค่อนข้างเรียบ (smooth) ตั้งแต่ค่า ρ_1 เป็นต้นมา
 - ถ้า ϕ_1 เป็นลบ ลักษณะของ autocorrelation function ยังคงเป็น exponential แต่มีค่าสลับระหว่างค่าบวกค่าลบตั้งแต่ค่า ρ_1 เป็นต้นมา
- นอกจากนั้นเครื่องหมายของ ρ_1 จะเหมือนกับเครื่องหมายของ $(\phi_1 - \theta_1)$

ลักษณะของ partial autocorrelation function

- เนื่องจากค่า partial autocorrelation function มีค่าเท่ากับ ρ_1 ดังนั้นลักษณะของ partial autocorrelation function ของ ARMA(1,1) จึงมีลักษณะแบบ MA(1) คือ damped exponentials และสรุปได้ดังนี้
- ถ้า θ_1 เป็นบวก damped exponentials ที่ค่อนข้างเรียบตั้งแต่ค่า ρ_1 เป็นต้นมา ตามเครื่องหมายของ $(\phi_1 - \theta_1)$
 - ถ้า θ_1 เป็นลบ ต่างกับกรณีแรกคือ exponential ซึ่ง oscillate ตั้งแต่ค่า ρ_1 ตามเครื่องหมายของ $(\phi_1 - \theta_1)$
- ลักษณะของ autocorrelation function และ partial

autocorrelation function ของ ARMA(1,1) ดูได้จากภาพที่ ๓.๕.๓

จากลักษณะของ autocorrelation function และ partial autocorrelation function ที่สำคัญดังกล่าวเหล่านี้จึงพอเป็นแนวทางในการเลือกแบบจำลองสำหรับข้อมูลอนุกรมเวลาคือ

ถ้าสร้างแบบจำลอง AUTOREGRESSIVE ORDER 1 ถ้า autocorrelation function มีลักษณะเป็น exponential to zero ทั้งแบบสลับเครื่องหมายหรือไม่ก็ตามและ partial autocorrelation function มีค่าเป็น ๐ หลังจาก lag 1 แสดงว่าลักษณะ exponential เป็นลักษณะของ partial autocorrelation function แทน และ autocorrelation function มีค่า cuts off หลังจาก lag 1 แล้ว ควรสร้างแบบจำลอง MOVING AVERAGE ORDER 1

สำหรับการสร้างแบบจำลองที่มี ORDER 2 ยังคงพิจารณาทั้งลักษณะ autocorrelation function และ partial autocorrelation function ถ้าลักษณะของ autocorrelation function เป็น damped exponentials แบบใดก็ตาม เช่น แบบ sine wave, แบบ oscillate แบบ smooth และลักษณะ partial autocorrelation function มีค่าเป็น ๐ หลังจาก lag 2 เป็นต้นไป สร้างแบบจำลอง AUTOREGRESSIVE ORDER 2 แสดงว่าลักษณะของ autocorrelation function เป็น ๐ หลังจาก lag 2 และลักษณะ partial

autocorrelation function เป็น damped exponentials แบบใดก็ได้ แบบจำลอง MOVING AVERAGE ORDER 2 เป็นแบบที่เหมาะสมกว่าแบบอื่น

ในกรณีที่ autocorrelation และ partial autocorrelation function มีลักษณะนอกเหนือจากลักษณะดังกล่าว ควรใช้แบบจำลอง ARMA(1,1) ซึ่งทั้ง autocorrelation function และ partial autocorrelation function มีลักษณะ damped exponentials เริ่มต้นที่จุด ρ_1 เป็นต้นไป ซึ่ง ρ_1 นี้มีเครื่องหมายตาม $(\theta_1 - \alpha_1)$ และลักษณะ damped exponentials ของ autocorrelation function เป็นแบบใดนั้นขึ้นอยู่กับเครื่องหมายของ θ_1 ขณะเดียวกันเครื่องหมายของ α_1 ก็กำหนดแบบของ damped exponentials ของ partial autocorrelation function ด้วย

๓.๓ แบบจำลอง NONSTATIONARY

ในการวิเคราะห์อนุกรมเวลา อาจจะมีอนุกรมเวลาที่ "ต้องการวิเคราะห์" เกี่ยวกับความเบี่ยงเบนไปจากแนวโน้มหรือ fixed mean แต่อนุกรมเวลายังคงแสดงความเป็น HOMOGENEOUS หรือมีลักษณะคล้ายแบบเดิมและเมื่อเวลาเปลี่ยนไป ระดับหรือค่าเฉลี่ยของความกระเพื่อม (fluctuation) ก็เปลี่ยนไปด้วย ลักษณะดังกล่าวนี้เป็นลักษณะหนึ่งของ Nonstationary time series ซึ่งอนุกรมส่วนแตกต่างที่ d (d^{th} difference) หรือส่วนแตกต่างระหว่างค่าในอนุกรม Nonstationary นั้นเองจะมี process เป็น Stationary อนุกรมส่วนแตกต่างที่ d นี้จึงสามารถแทนได้ด้วยแบบจำลอง Linear Stationary ส่วนค่า d นี้ในทางปฏิบัติพบว่ามีค่าไม่เกิน ๒ คือ มักมีค่า ๐, ๑, ๒ เสมอ

$$\text{ให้ } w_t = \nabla^d z_t \quad \text{หรือส่วนแตกต่างที่ } d$$

$$\nabla^d z_t = z_t - z_{t-1} - \dots - z_{t-d}$$

$d = 0$ แสดงว่า นำความแตกต่างมาเกี่ยวข้องของยังคงเป็นอนุกรมเวลาเดิมคือ z_t

$$d = 1, \quad \nabla_1 z_t = z_t - z_{t-1}$$

$$d = 2, \quad \nabla_2 z_t = z_t - z_{t-1} - z_{t-2}$$

การหาแบบจำลอง NONSTATIONARY จึงเริ่มด้วยการสร้างแบบจำลอง Linear Stationary ให้กับอนุกรมส่วนแตกต่างที่ ๐, อนุกรมส่วนแตกต่างที่ ๑, อนุกรมส่วนแตกต่างที่ ๒, แล้วเลือกแบบจำลองที่สอดคล้องกันระหว่าง ๓ แบบจำลองนี้ เป็นแบบจำลองสำหรับอนุกรม Nonstationary

ดังนั้นการเลือกแบบจำลอง NONSTATIONARY จึงต้องอาศัยการดู

ลักษณะของ autocorrelation function และ partial autocorrelation function ของอนุกรม z_t , ∇z_t และ $\nabla^2 z_t$ แทน z_t เพื่อหาค่า p, q, d ที่เหมาะสมกับข้อมูล

จะเห็นว่า โดยทั่วไปแล้ว NONSTATIONARY MODEL เป็นแบบจำลองที่วิเคราะห์อนุกรมเวลาของตัวแปรโดยไม่เกี่ยวข้องกับระดับของค่าเฉลี่ยหรือแนวโน้ม

- ของอนุกรมเวลาใดๆ ส่วน STATIONARY MODEL เป็นแบบจำลองที่วิเคราะห์เกี่ยวกับความเบี่ยงเบนไปจากระดับของค่าเฉลี่ยที่คงที่ (a constant mean level) หรือค่าที่คงที่ค่าหนึ่งที่เป็นค่าควบคุม (control) ค่าที่แปรไป ดังนั้นการวิเคราะห์อนุกรมเวลาของอัตราของทารกในบทต่อไป เพื่อหาแบบจำลองที่เหมาะสมกับส่วนเบี่ยงเบนจากแนวโน้ม (Long term trend) ด้วยทฤษฎีบางประการของ Stationary time series ซึ่งให้แบบจำลอง Linear Stationary นอกจากนี้ยังพิจารณา Linear Nonstationary model ให้กับอนุกรมเวลาอัตราตายของทารกโดยตรงอีกด้วย.



ศูนย์วิทยทรัพยากร
จุฬาลงกรณ์มหาวิทยาลัย

3.4 การทดสอบความเหมาะสมของแบบจำลอง (Lack of fit test)

ความเหมาะสมของแบบจำลองจะพิจารณาจาก autocorrelation function ของ residual ของแบบจำลองคือ a_t เป็นการทดสอบค่าของ autocorrelation function รวมทั้งหมด ด้วย statistic Q

$$Q = n \sum_{k=1}^K r_k^2(\hat{a})$$

การแจกแจงของ Q เป็น approximate Chi-square ที่มี degree of freedom เป็น $K-p-q$

เมื่อ K เป็นค่า lag ที่มากที่สุด

p เป็น ORDER ของ Autoregressive process

q เป็น ORDER ของ Moving Average process

$n = N-d$ คือ จำนวนค่าสังเกตที่ใช้สร้างแบบจำลอง

d คือ จำนวนช่วงเวลาที่แตกต่างกัน เช่น $d=1$

อนุกรมเวลาของตัวแปรจะเปลี่ยนเป็นอนุกรมเวลาของส่วนแตกต่างที่ 1 ของตัวแปรนี้ และมีจำนวนค่าสังเกตลดลง 1 ค่า

การทดสอบจะอาศัยค่า Q ที่คำนวณได้มาเทียบกับตาราง χ^2 ที่มี degree of freedom เป็น $K-p-q$ ถ้า Q มีค่าน้อยกว่า χ^2 ในตาราง แสดงว่าแบบจำลองที่สร้างให้กับอนุกรมเวลาของค่าสังเกตมีความเหมาะสมพอ เพราะถ้ายังแบบจำลองที่สร้างไม่เหมาะสมกับข้อมูล จะทำให้ค่าเฉลี่ยของ Q สูงมากขึ้น (inflate)

จุฬาลงกรณ์มหาวิทยาลัย