

บทที่ 7

การเลือกสมการถดถอยที่เหมาะสม

การวิเคราะห์การถดถอยในบทที่แล้ว ๆ มาจะสมมติให้ตัวแปรอิสระที่อยู่ในโมเดลมีอิทธิพลต่อตัวแปรตาม รูปแบบของโมเดลถูกต้อง และมีลักษณะที่สอดคล้องกับข้อตกลงเบื้องต้นของการวิเคราะห์ บางครั้งพบว่าความรู้ทางทฤษฎีและประสบการณ์ในอดีตจะช่วยในการตัดสินใจเลือกตัวแปรอิสระเข้าในโมเดลได้เช่นกัน ซึ่งการค้นหาสับเช็ตของตัวแปรอิสระที่เหมาะสมสำหรับโมเดลจะเรียกว่า การเลือกตัวแปร (*Variable selection*) ในบทนี้ จะกล่าวถึงเกณฑ์ที่ใช้ในการพิจารณาคัดเลือกตัวแปร รวมทั้งวิธีในการคัดเลือกตัวแปร แต่อย่างไรก็ตามไม่วิธีคัดเลือกตัวแปรใดที่สามารถรับประทานได้ว่าให้สมการถดถอยที่ดีที่สุด (*Best regression equation*) สำหรับข้อมูลที่พิจารณา นอกเหนือจากนั้นวิธีในการคัดเลือกตัวแปรต้องใช้คอมพิวเตอร์เป็นส่วนใหญ่ ซึ่งนักวิเคราะห์ไม่ควรเนื่องผลที่ได้จากคอมพิวเตอร์เพียงอย่างเดียว ควรคำนึงถึงประสบการณ์และความสมเหตุสมผลประกอบการตัดสินใจด้วย ดังนั้นวิธีการเลือกตัวแปรควรที่จะพิจารณาว่าเป็นวิธีการสำรวจโครงสร้างของข้อมูลเบื้องต้นมากกว่า ที่จะเป็นผลสรุปในขั้นสุดท้าย

7.1 ปัญหาในการเลือกโมเดลถดถอย

การสร้างโมเดลถดถอยโดยทั่วไปพบว่านักวิเคราะห์ต้องการให้โมเดลประกอบด้วยตัวแปรอิสระเพียงไม่กี่ตัว แต่สามารถอธิบายอิทธิพลที่มีต่อค่าพยากรณ์ Y ได้อย่างเพียงพอ ซึ่งถ้าจำนวนตัวแปรอิสระเพิ่มขึ้น ความแปรปรวนของค่าพยากรณ์จะสูงขึ้นตาม อีกทั้งยังทำให้ค่าใช้จ่ายในการเก็บรวบรวมข้อมูลเพิ่มขึ้นอีกด้วย นอกจากนี้ วิธีในการคัดเลือกตัวแปรเข้าในโมเดลมีหลายวิธี และป้อยครึ่งที่วิธีในการคัดเลือกตัวแปรเหล่านี้ใช้สับเช็ตของตัวแปรอิสระที่แตกต่างกันในการสร้างสมการถดถอยที่ดีที่สุดของแต่ละวิธี อีกทั้งไม่มีนิยามที่ชัดเจนเกี่ยวกับสมการถดถอยที่ดีที่สุดอีกด้วย ซึ่งปัญหาในการเลือกตัวแปรมักจะนำเสนอในเชิงอุดมคติ โดยสมมติว่าทราบรูปแบบพังก์ชันของตัวแปรอิสระที่ถูกต้อง เช่น $\ln X$, X^2 เป็นต้น และไม่มีค่าสังเกตที่ผิดปกติหรือค่าสังเกตที่มีอิทธิพลอยู่ในข้อมูล ซึ่งในทางปฏิบัติมักไม่ค่อยเกิดขึ้น การวิเคราะห์ความคลาดเคลื่อนที่ได้อธิบายไว้แล้วในบทที่ 4 จะช่วยในการค้นหาพังก์ชันของตัวแปรอิสระที่เหมาะสม หรืออาจมีถึงตัวแปรอิสระตัวใหม่ที่ควรเพิ่มเข้าไป

ในโมเดล และข้อนอกพร่องของข้อมูลเกี่ยวกับค่าสังเกตที่ผิดปกติและค่าลังกอกที่มีอิทธิพล ดังนั้นจะเห็นได้ว่า การตรวจสอบความเหมาะสมของโมเดลมีความสัมพันธ์อย่างใกล้ชิดกับปัญหาในการเลือกตัวแปร และการพิจารณาควบคู่กันไป กล่าวคือ สร้างสมการลดด้อยโดยใช้วิธีในการตัดเลือกตัวแปรเข้าในโมเดล หลังจากนั้น ตรวจสอบความเหมาะสมของโมเดลที่ได้ในขั้นสุดท้ายเพื่อให้ได้สมการที่เหมาะสม

การตัดตัวแปรอิสระบางตัวออกจากโมเดล จะช่วยเพิ่มความแม่นยำในการพยากรณ์และการประมาณ พารามิเตอร์ของตัวแปรอิสระที่ยังคงอยู่เหลืออยู่ในโมเดลได้ ถึงแม้ว่าตัวแปรที่ถูกตัดทิ้งบางตัวจะยังคงมีอิทธิพล ต่อตัวแปรตามก็ตาม นอกเหนือจากการตัดตัวแปรอิสระออกไปจะทำให้ตัวประมาณค่าสัมประสิทธิ์ลดด้อยของตัว-แปรอิสระที่ยังคงอยู่เหลืออยู่ในโมเดลเป็นตัวประมาณที่เอนเอียง แต่อย่างไรก็ตามค่าตัวแปรที่ถูกตัดออกไปนี้ อิทธิพลน้อยมาก จะทำให้ MSE ของตัวประมาณที่เอนเอียงนั้นมีค่าน้อยกว่าความแปรปรวนของตัวประมาณ ที่ไม่เอนเอียง ซึ่งแสดงว่าขนาดของความเอนเอียงที่เกิดขึ้นมีค่าน้อยกว่าความผันแปรที่ลดลง ขณะเดียวกัน การเก็บตัวแปรที่ไม่มีอิทธิพลไว้ในโมเดล นั่นคือ ตัวแปรที่มีค่าสัมประสิทธิ์ลดด้อยเข้าใกล้ศูนย์หรือมีค่าน้อยกว่าค่า ความคลาดเคลื่อนมาตรฐานของการประมาณที่ได้จาก Full model จะทำให้ความแปรปรวนของการประมาณค่า สัมประสิทธิ์ลดด้อยและค่าพยากรณ์สูงขึ้น

7.2 เกณฑ์ที่ใช้ในการเลือกโมเดลลดด้อย

การเลือกตัวแปรอิสระที่ควรอยู่ในโมเดลสามารถแบ่งได้เป็น 2 ขั้นตอนคือ การสร้างสับเช็ตของสมการลดด้อย ที่เป็นไปได้ และการพิจารณาว่าสับเช็ตของสมการใดกว่าสับเช็ตอื่น ซึ่งเกณฑ์ที่ใช้ในการประเมินและเบริญ เทียนสับเช็ตของสมการลดด้อยมีดังนี้

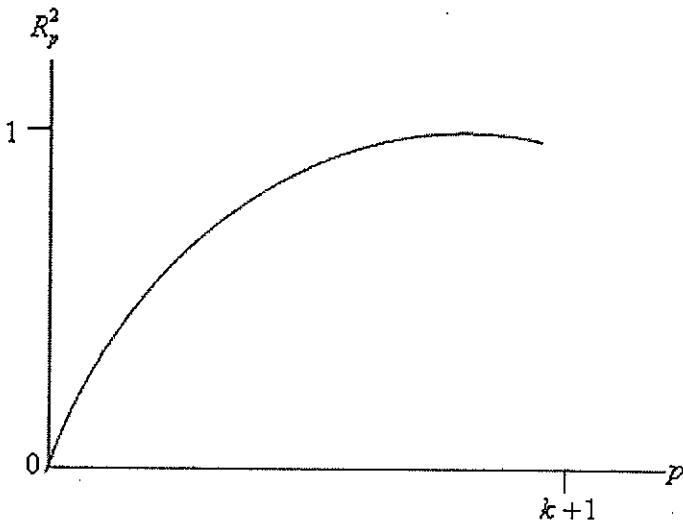
7.2.1 ค่าสัมประสิทธิ์ตัวกำหนดแบบพหุ

เป็นที่ทราบแล้วว่าค่าสัมประสิทธิ์ตัวกำหนดเชิงพหุ หรือ R^2 เป็นค่าที่ใช้กันอย่างแพร่หลายในการวัดความ เหมาะสมของโมเดล ให้ R_p^2 แทน ค่าสัมประสิทธิ์ตัวกำหนดเชิงพหุสำหรับสับเช็ตของโมเดลลดด้อยที่มี p เทอม (ตัวแปรอิสระ $p - 1$ ตัว และระบบทดแทน β_0) นั่นคือ

$$R_p^2 = \frac{SSR_p}{SST} = 1 - \frac{SSE_p}{SST} \quad (7.1)$$

เมื่อ SSR_p และ SSE_p แทน ผลรวมกำลังสองเนื้องมาจากการลดด้อยและความคลาดเคลื่อนของโมเดล ที่มี p เทอม ตามล่าดับ

ซึ่งในแต่ละสับเช็ตของโมเดลขนาด p จะมี R_p^2 ทั้งหมด $\binom{k}{p-1}$ ตัว เมื่อ k แทน จำนวนตัวแปรอิสระ จะเห็นได้ว่า R_p^2 มีค่าสูงขึ้นเมื่อ p เพิ่มขึ้น และมีค่าสูงสุดเมื่อ $p = k + 1$ ดังนั้นการเพิ่มตัวแปรอิสระ



รูปที่ 7.1: กราฟระหว่าง R_p^2 และ p

เข้าไปในโมเดลจะหดกระทำกีต่อเมื่อทัวแปรอิสระที่เพิ่มเข้าไปนั้นไม่มีประโยชน์หรือมีประโยชน์น้อยมาก โดยทำให้ค่า R_p^2 เพิ่มขึ้นเพียงเล็กน้อยเท่านั้น รูปที่ 7.1 แสดงลักษณะของกราฟระหว่างค่าสูงสุดของ R_p^2 ในแต่ละสับเช็ตของโมเดลขนาด p กับจำนวนพารามิเตอร์ p โดยจุดที่กราฟเริ่มหักโค้งจะเป็นจุดที่ก้าหนดจำนวนตัวแปรอิสระที่ควรอยู่ในโมเดลสุดท้าย ซึ่งขึ้นอยู่กับการตัดสินใจของนักวิเคราะห์แต่ละคน

7.2.2 ค่าสัมประสิทธิ์ตัวก้าหนดแบบพหุที่มีการปรับค่าแล้ว

เพื่อที่จะหลีกเลี่ยงความยุ่งยากในการแปลผลค่า R^2 บางครั้งจึงนิยมใช้ค่าสัมประสิทธิ์ตัวก้าหนดแบบพหุที่มีการปรับค่าแล้ว หรือ R_{adj}^2 เป็นเกณฑ์ในการเปรียบเทียบสับเช็ตของโมเดล โดยที่

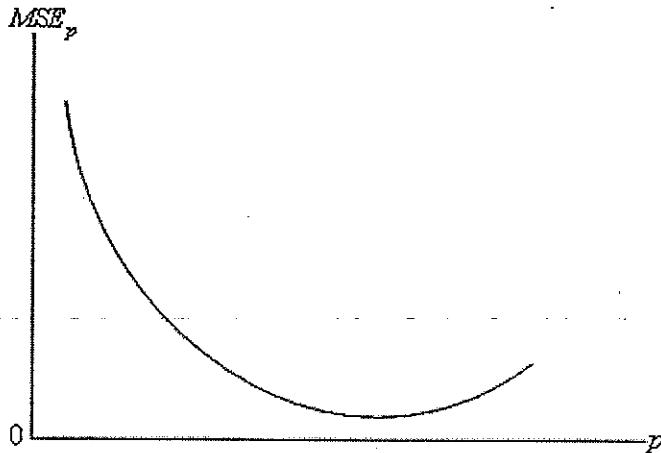
$$R_{adj}^2(p) = 1 - \frac{n-1}{n-p}(1 - R_p^2) \quad (7.2)$$

เมื่อ $R_{adj}^2(p)$ แทน ค่าสัมประสิทธิ์ตัวก้าหนดแบบพหุที่มีการปรับค่าแล้วสำหรับสับเช็ตของโมเดลถูกอยู่ที่มี p เทอม โดยที่ $R_{adj}^2(p)$ ไม่จำเป็นต้องมีค่ามากขึ้นทุกครั้งที่เพิ่มตัวแปรอิสระเข้าไปในโมเดล ดังนั้นเกณฑ์ในการเลือกสับเช็ตของโมเดลที่เหมาะสมทำได้โดยเลือกโมเดลที่มีค่า $R_{adj}^2(p)$ สูงสุดนั่นเอง

7.2.3 ความคลาดเคลื่อนกำลังสองเฉลี่ย

ความคลาดเคลื่อนกำลังสองเฉลี่ยสำหรับสับเช็ตของโมเดลที่มี p เทอม แทนด้วย MSE_p มีสูตรดังนี้

$$MSE_p = \frac{SSE_p}{n-p} \quad (7.3)$$



รูปที่ 7.2: กราฟระหว่าง MSE_p และ p

เมื่อ p เพิ่มขึ้น พบว่า SSE_p มีค่าลดลงเสมอ รูปที่ 7.2 แสดงลักษณะของ MSE_p เมื่อ p เพิ่มขึ้น ซึ่งจะเห็นได้ว่า MSE_p มีค่าลดลงในช่วงแรก แล้วคงที่ และเพิ่มขึ้นในช่วงท้าย ๆ อาจเนื่องมาจากการตัวแปรอิสระที่เพิ่มเข้าไปในโมเดลไม่เพียงพอที่จะชดเชยจำนวนของความเป็นอิสระของตัวหารในสมการที่ (7.3) ที่สูญเสียไป ดังนั้นเกณฑ์ในการเลือกจำนวนตัวแปรอิสระเมื่อพิจารณาจาก MSE_p ทำได้ดังนี้

- เลือก p ที่ทำให้ MSE_p มีค่าต่ำสุด
- เลือก p ที่ทำให้ MSE_p มีค่าใกล้เคียงกับ MSE ของ Full model
- เลือก p ที่อยู่ใกล้จุดที่ทำให้ MSE_p เพิ่มขึ้น

และสับเช็คของโมเดลลดด้อยที่ทำให้ MSE_p มีค่าต่ำสุด จะทำให้ $R^2_{adj(p)}$ มีค่าสูงสุดด้วย โดยจะเห็นได้จาก

$$\begin{aligned}
 R^2_{adj(p)} &= 1 - \frac{n-1}{n-p} (1 - R_p^2) \\
 &= 1 - \frac{n-1}{n-p} \cdot \frac{SSE_p}{SST} \\
 &= 1 - \frac{n-1}{SST} \cdot \frac{SSE_p}{n-p} \\
 &= 1 - \frac{n-1}{SST} \cdot MSE_p
 \end{aligned}$$

ดังนั้นการเลือกจำนวนตัวแปรอิสระเข้าในโมเดลโดยใช้เกณฑ์ที่ทำให้ MSE_p มีค่าต่ำสุด เทียบเท่ากับเกณฑ์ที่ทำให้ $R^2_{adj(p)}$ มีค่าสูงสุดนั่นเอง

7.2.4 สถิติ Mallows' C_p

ในปีค.ศ. 1964 Mallows ได้เสนอเกณฑ์ในการเลือกตัวแปรอิสระที่สัมพันธ์กับความคลาดเคลื่อนกำลังสอง

เฉลี่ยของค่าพยากรณ์ ซึ่งมีสูตรดังนี้

$$\begin{aligned} E[\hat{Y}_i - E(Y_i)]^2 &= V(\hat{Y}_i) + [\text{Bias}(\hat{Y}_i)]^2 \\ &= V(\hat{Y}_i) + [E(Y_i) - E(\hat{Y}_i)]^2 \end{aligned} \quad (7.4)$$

เมื่อ

$E(Y_i)$ แทน ค่าคาดหวังที่ได้จากการถดถอยที่แท้จริง

$E(\hat{Y}_i)$ แทน ค่าคาดหวังที่ได้จากการลับเข็ตของสมการถดถอยที่มี p เทอม

ให้ Γ_p แทน ผลรวมของความคลาดเคลื่อนกำลังสองเฉลี่ยของค่าพยากรณ์ในรูปค่าแหนມาตรฐาน (Standardized total mean square error) โดยที่

$$\begin{aligned} \Gamma_p &= \frac{1}{\sigma^2} \left\{ \sum_{i=1}^n V(\hat{Y}_i) + \sum_{i=1}^n [E(Y_i) - E(\hat{Y}_i)]^2 \right\} \\ &= \frac{1}{\sigma^2} \sum_{i=1}^n V(\hat{Y}_i) + \frac{SSB_p}{\sigma^2} \end{aligned} \quad (7.5)$$

เมื่อ $SSB_p = \sum_{i=1}^n [E(Y_i) - E(\hat{Y}_i)]^2$ แทน ผลรวมกำลังสองของความเอียง (Total squared bias) สำหรับสมการถดถอยที่มี p เทอม

และสามารถแสดงได้ว่า

$$\sum_{i=1}^n V(\hat{Y}_i) = p\sigma^2 \quad (7.6)$$

$$E[SSE_p] = SSB_p + (n-p)\sigma^2 \quad (7.7)$$

แทนค่า $\sum_{i=1}^n V(\hat{Y}_i)$ และ SSB_p เข้าไปในสมการที่ (7.5) จะได้ว่า

$$\begin{aligned} \Gamma_p &= \frac{p\sigma^2}{\sigma^2} + \frac{\{E[SSE_p] - (n-p)\sigma^2\}}{\sigma^2} \\ &= \frac{E[SSE_p]}{\sigma^2} - n + 2p \end{aligned}$$

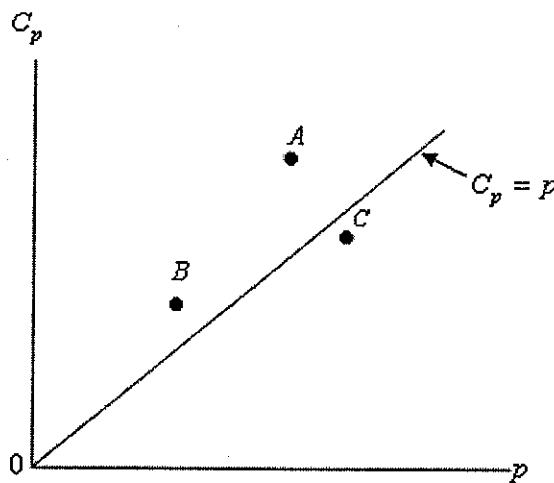
แทนค่า σ^2 และ $E[SSE_p]$ ด้วยค่าสังเกตที่ได้จากข้อมูลตัวอย่าง คือ $\hat{\sigma}^2$ และ SSE_p ตามลำดับ จะได้ว่า

$$C_p = \frac{SSE_p}{\hat{\sigma}^2} - n + 2p \quad (7.8)$$

เมื่อ C_p เป็นตัวประมาณของ Γ_p

ถ้า $SSB_p = 0$ จะส่งผลให้ $E[SSE_p] = (n - p)\sigma^2$ ดังนั้น

$$E[C_p | \text{Bias} = 0] = \frac{(n - p)\sigma^2}{\sigma^2} - n + 2p = p \quad (7.9)$$



รูปที่ 7.3: กราฟระหว่าง C_p และ p

รูปที่ 7.3 แสดงกราฟของ C_p ซึ่งเป็นพังก์ชันของ p สำหรับสมการทดสอบแต่ละสมการ โดยถ้าสมการทดสอบมีความเอียงเล็กน้อย ค่า C_p จะตกใจลักษณะเด่นตรง $C_p = p$ (จุด C) แต่ถ้าสมการทดสอบมีความเอียงมาก ค่า C_p จะตกอยู่เหนือเส้นตรง $C_p = p$ (จุด A) โดยทั่วไปแล้วต้องการ C_p ที่มีค่าน้อย ๆ ถึงแม้ว่าจุด B จะตกอยู่เหนือเส้น $C_p = p$ แต่อยู่ต่ำกว่าจุด C แสดงว่าโมเดล B มีความคลาดเคลื่อนน้อยกว่าโมเดล C ซึ่งจะเห็นได้ว่าในบางครั้งอาจต้องรับເຄາສມາກที่มีความเอียงเล็กน้อยเพื่อทำให้ความคลาดเคลื่อนเหลือของ การพยากรณ์ลดลง

7.2.5 เกณฑ์การเปรียบเทียบโมเดลทดสอบ จำแนกตามจุดมุ่งหมาย

เป็นที่ทราบแล้วว่าเกณฑ์ในการเลือกและเปรียบเทียบโมเดลมีความสัมพันธ์กับจุดมุ่งหมายของการสร้างโมเดล แสดงความสัมพันธ์ระหว่างข้อมูลดังนี้

- ถ้าจุดมุ่งหมายของการสร้างสมการทดสอบเพื่ออธิบายกระบวนการหรือระบบที่ซับซ้อน พบว่าการค้นหาสมการทดสอบที่มีค่า SSE น้อยที่สุดจะเป็นที่ต้องการ เนื่องจาก SSE มีค่าน้อยที่สุด เมื่อสมการทดสอบ

โดยมีตัวแปรอิสระทั้ง k ตัว แต่นักวิเคราะห์มักต้องการใช้ตัวแปรอิสระเพียงไม่เกิน k ข้างเดียวกันสามารถ อธิบายความผันแปรในข้อมูลได้ในสัดส่วนที่มากพอ ดังนั้นอาจต้องตัดตัวแปรอิสระบางตัวที่อธิบายความ- สัมพันธ์ในข้อมูลได้น้อยออกจากสมการ ซึ่งอาจส่งผลให้ SSE เพิ่มขึ้นเล็กน้อย

- ถ้าจุดมุ่งหมายของการสร้างสมการลดด้อยเพื่อพยากรณ์ค่าสังเกตค่าใหม่หรือประมาณค่าเฉลี่ยของตัวแปร ตาม โดยทั่วไปมักเลือกสมการที่ทำให้ผลรวมกำลังสองของความคลาดเคลื่อนของค่าพยากรณ์ ($Predictive error-sum of squares$) สำหรับสับเข็ตของโมเดลลดด้อยที่มี p เทอม แทนด้วย $PRESS_p$ มีค่าน้อย ที่สุด มีสูตรดังนี้

$$\begin{aligned} PRESS_p &= \sum_{i=1}^n \left[Y_i - \hat{Y}_{(i)} \right]^2 \\ &= \sum_{i=1}^n \left(\frac{e_i}{1 - h_{ii}} \right)^2 \end{aligned} \quad (7.10)$$

- ถ้าจุดมุ่งหมายของการสร้างสมการลดด้อยเพื่อประมาณค่าพารามิเตอร์ ควรพิจารณาเลือกสมการโดย พิจารณาทั้งค่าความเออนเอียงและความแปรปรวนของการประมาณค่าสัมประสิทธิ์ลดด้อยที่ได้จากโมเดล ที่มีตัวแปรอิสระบางตัวถูกตัดออกไป
- ถ้าจุดมุ่งหมายของการสร้างสมการลดด้อยเพื่อควบคุมค่าของตัวแปรตาม พนวณการประมาณค่าพารามิ- เเตอร์ที่ถูกต้องเป็นสิ่งสำคัญ จึงควรเลือกสมการโดยพิจารณาจากค่าความคลาดเคลื่อนมาตรฐานของการ ประมาณสัมประสิทธิ์ลดด้อย ซึ่งควรมีค่าน้อย ๆ

7.3 วิธีเลือกตัวแปรอิสระสำหรับโมเดลลดด้อย

จะเห็นได้ว่าการเลือกโมเดลลดด้อยเป็นการค้นหาสับเข็ตของตัวแปรอิสระที่เหมาะสมสำหรับข้อมูลที่พิจารณา นั่นเอง ซึ่งวิธีเลือกตัวแปรอิสระใส่เข้าในโมเดลมีหลายวิธีด้วยกัน และบัญชีนี้โปรแกรมวิเคราะห์ข้อมูลทาง สถิติส่วนใหญ่ได้รวมเอาวิธีการเลือกตัวแปรเหล่านี้ไว้แล้ว ทำให้สะดวกต่อการใช้งานมากขึ้น แต่ยังไก่dam ผู้วิเคราะห์ไม่ควรขึ้นอยู่กับผลที่ได้จากการพิจารณาเพียงอย่างเดียว แต่ควรคำนึงถึงความสมเหตุสมผลประกอบ ด้วย ในบทนี้จะกล่าวถึงวิธีการเลือกตัวแปรอิสระเข้าในโมเดลที่นิยมใช้ 4 วิธีดังนี้

7.3.1 การเลือกตัวแปรด้วยวิธี All Possible Regressions

วิธีนี้จะเลือกสมการลดด้อยที่ดีที่สุดจากรูปแบบของสมการลดด้อยที่เป็นไปได้ทั้งหมด ซึ่งได้จากการสร้างสมการ ลดด้อยที่มีตัวแปรอิสระหนึ่งตัว สองตัว ไปเรื่อย ๆ จนครบทั้ง k ตัว แล้วพิจารณาจากเกณฑ์ที่ใช้ในการเลือก สมการ เพื่อค้นหาสมการลดด้อยที่ดีที่สุด หากสมการที่เป็นไปได้ทั้งหมดมีรูปแบบตัดแกน Y หรือ b_0 อยู่ด้วย

และมีตัวแปรอิสระที่ต้องพิจารณาทั้งหมด k ตัว พบร่วมต้องสร้างและตรวจสอบสมการทั้งหมดจำนวน 2^k สมการ เช่น ถ้า $k = 5$ จำนวนสมการที่เป็นไปได้ทั้งหมด คือ $2^5 = 32$ สมการ และเมื่อ $k = 10$ จำนวนสมการที่เป็นไปได้ทั้งหมด คือ $2^{10} = 1,024$ จะเห็นได้ว่าจำนวนสมการที่ต้องตรวจสอบจะเพิ่มขึ้นอย่างรวดเร็ว เมื่อจำนวนตัวแปรอิสระเพิ่มขึ้น ซึ่งในอดีตการสร้างสมการลดด้อยที่เป็นไปได้ทั้งหมดจะจำกัดอยู่เฉพาะกรณีที่มีตัวแปรอิสระเพียง 2 – 3 ตัวเท่านั้น เมื่อคอมพิวเตอร์ความเร็วสูงได้พัฒนาขึ้น อัลกอริทึมที่ใช้ในการสร้างและตรวจสอบสมการที่เป็นไปได้ทั้งหมดมีประสิทธิภาพมากขึ้น ทำให้ข้อจำกัดเหล่านี้ลดน้อยลง

ตัวอย่างที่ 7.1 การศึกษากำลังในการขันเคลื่อนเครื่องบิน โดยมีตัวแปรอิสระที่พิจารณา 4 ตัว คือ

X_1 แทน กำลังต่อหน้าหนักหนึ่งหน่วย

X_2 แทน พิสัยในการบิน

X_3 แทน สัดส่วนของน้ำหนักผู้โดยสารต่อน้ำหนักสุทธิของเครื่องบิน

X_4 แทน ระหว่างน้ำหนัก

โดย Y แทน จำนวนวันที่ขึ้นบินนับจากเดือนมกราคม หน่วยเป็นเดือน ได้ข้อมูลดังนี้

| Y | X_1 | X_2 | X_3 | X_4 |
|-----|-------|-------|-------|-------|
| 85 | 1.258 | 3.07 | 0.177 | 0.25 |
| 92 | 1.395 | 3.41 | 0.165 | 0.25 |
| 104 | 1.958 | 4.64 | 0.188 | 3.05 |
| 110 | 1.844 | 4.49 | 0.286 | 1.25 |
| 118 | 2.257 | 3.88 | 0.309 | 1.15 |
| 125 | 1.084 | 3.52 | 0.161 | 1.05 |
| 130 | 1.973 | 3.74 | 0.011 | 2.55 |
| 140 | 2.216 | 4.42 | 0.128 | 1.95 |
| 150 | 2.397 | 3.61 | 0.166 | 2.45 |
| 169 | 4.357 | 4.69 | 0.149 | 3.35 |
| 177 | 4.378 | 3.59 | 0.260 | 3.65 |
| 178 | 3.408 | 4.09 | 0.154 | 2.95 |
| 180 | 5.645 | 4.30 | 0.183 | 2.65 |
| 187 | 2.688 | 4.25 | 0.189 | 3.15 |
| 190 | 3.670 | 5.16 | 0.112 | 3.35 |

ตารางที่ 7.1: ข้อมูลของตัวอย่างที่ 7.1

จะเลือกตัวแปรเข้าไปในสมการลดด้อยโดยใช้วิธี All possible regressions

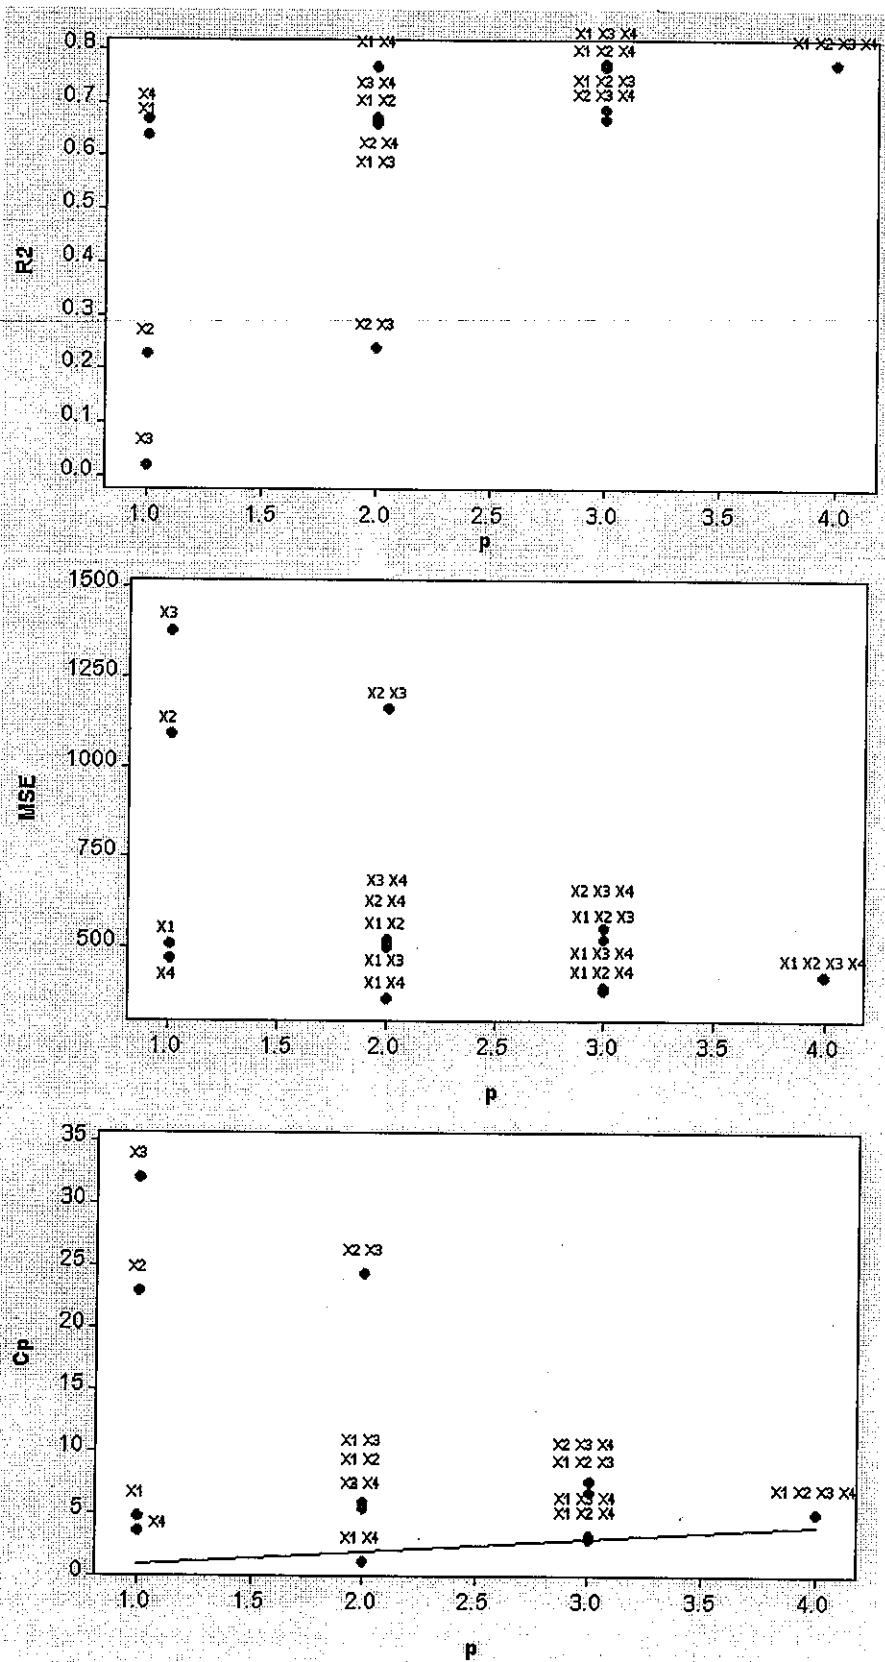
| จำนวนตัวแปรที่อยู่ในโมเดล | R^2 | R^2_{adj} | C_p | MSE | ตัวแปรที่อยู่ในโมเดล |
|---------------------------|--------|-------------|---------|-----------|----------------------|
| 0 | 0 | 0 | 30.9248 | 1308.2381 | ไม่มี |
| 1 | 0.6687 | 0.6432 | 3.5542 | 466.8110 | X_4 |
| 1 | 0.6410 | 0.6134 | 4.7680 | 505.7431 | X_1 |
| 1 | 0.2267 | 0.1672 | 22.9674 | 1089.4734 | X_2 |
| 1 | 0.0206 | 0.0548 | 32.0222 | 1379.8986 | X_3 |
| 2 | 0.7676 | 0.7288 | 1.2096 | 354.7533 | $X_1 X_4$ |
| 2 | 0.6734 | 0.6190 | 5.3455 | 498.4634 | $X_1 X_3$ |
| 2 | 0.6691 | 0.6139 | 5.5371 | 505.1195 | $X_3 X_4$ |
| 2 | 0.6687 | 0.6135 | 5.5528 | 505.6666 | $X_2 X_4$ |
| 2 | 0.6599 | 0.6032 | 5.9401 | 519.1231 | $X_1 X_2$ |
| 2 | 0.2392 | 0.1124 | 24.4196 | 1161.2276 | $X_2 X_3$ |
| 3 | 0.7721 | 0.7099 | 3.0109 | 379.4716 | $X_1 X_3 X_4$ |
| 3 | 0.7679 | 0.7047 | 3.1933 | 386.3825 | $X_1 X_2 X_4$ |
| 3 | 0.6879 | 0.6028 | 6.7093 | 519.6591 | $X_1 X_2 X_3$ |
| 3 | 0.6691 | 0.5788 | 7.5351 | 550.9647 | $X_2 X_3 X_4$ |
| 4 | 0.7723 | 0.6813 | 5.0000 | 416.9630 | $X_1 X_2 X_3 X_4$ |

ตารางที่ 7.2: แสดงการเลือกตัวแปรด้วยวิธี All possible regressions

วิธีทำ เนื่องจากมีตัวแปรอิสระ 4 ตัว ดังนั้นสมการลดถอยที่เป็นไปได้ทั้งหมดที่ต้องพิจารณาคือ $2^4 = 16$ สมการ ตารางที่ 7.2 สรุปการเลือกตัวแปรเข้าในโมเดลด้วยวิธี All possible regressions

จากการพิจารณาสับเซ็ตของโมเดลลดถอยในตารางที่ 7.2 จะเห็นได้ว่าโมเดลที่มีตัวแปรอิสระอยู่แล้ว 2 ตัว เมื่อเพิ่มตัวแปรอิสระเข้าไปอีก 1 ตัว ทำให้ค่า R^2 เพิ่มขึ้นเล็กน้อยเป็นส่วนใหญ่ ซึ่งสอดคล้องกับรูปที่ 7.4 (บน) และส่งผลให้การเลือกโมเดลสุดท้ายยังไม่ชัดเจน แต่เมื่อพิจารณาจากค่า R^2_{adj} พบว่าโมเดลที่ประกอบด้วยตัวแปรอิสระ (X_1, X_4) มีค่า R^2_{adj} สูงสุด เมื่อพิจารณาค่า MSE ดังแสดงในรูปที่ 7.4 (กลาง) พบว่าโมเดลที่มี (X_1, X_4) มีค่า MSE ต่ำที่สุด โดยที่ $MSE = 354.7533$ ซึ่งสอดคล้องกับที่คาดไว้ นั่นคือ โมเดลที่มี MSE ต่ำที่สุด จะให้ R^2_{adj} สูงสุด และเมื่อพิจารณาจากกราฟระหว่าง C_p กับ p ในรูปที่ 7.4 (ล่าง) พบว่าโมเดลที่สามารถยอมรับได้ 3 โมเดล คือ โมเดลที่ประกอบด้วยตัวแปรอิสระ (X_1, X_4), (X_1, X_2, X_4) และ (X_1, X_3, X_4) หากไม่มีข้อมูลเพิ่มเติมเกี่ยวกับตัวแปรอิสระหรือค่าใช้จ่ายในการเก็บรวบรวมข้อมูล การเลือกโมเดลที่ง่ายที่สุดที่ประกอบด้วยตัวแปรอิสระ 2 ตัว คือ (X_1, X_4) อาจมีความเหมาะสม เนื่องจากมีค่า C_p น้อยที่สุด

หมายเหตุ บางครั้งการเลือกโมเดลลดถอยที่ดีที่สุดโดยใช้วิธี All possible regressions อาจให้ผลที่ไม่ชัดเจน และบ่อยครั้งอาจพบว่าการพิจารณาเกณฑ์ที่แตกต่างกัน อาจนำไปสู่โมเดลที่แตกต่างกันด้วย แต่อย่างไรก็ตาม โมเดลที่จะรับไปใช้ในชั้นสุดท้าย ควรที่จะตรวจสอบความเหมาะสมของโมเดลเสมอ ซึ่งรวมถึงการตรวจสอบค่าสัมภพที่ผิดปกติ ค่าสัมภพที่มีอิทธิพล และปัญหา Multicollinearity ด้วย



รูปที่ 7.4: กราฟระหว่าง R^2 และ p (บน) กราฟระหว่าง MSE และ p (กลาง) และ กราฟระหว่าง C_p และ p (ล่าง)

7.3.2 การเลือกตัวแปรด้วยวิธี Forward Selection

จะเห็นได้ว่าการเลือกตัวแปรอิสระโดยพิจารณาจากโมเดลลดด้อยที่เป็นไปได้ทั้งหมดย่อมก่อให้เกิดความยุ่งยากในการคำนวณ จึงได้มีการพัฒนาวิธีในการเลือกตัวแปรที่อยู่ในโมเดล ซึ่งจะพิจารณาเฉพาะสับเข็ตของโมเดล ลดด้อยเพียงไม่กี่โมเดล การเลือกตัวแปรด้วยวิธี Forward Selection จะเริ่มจากโมเดลที่ไม่มีตัวแปรอิสระเลย การค้นหาสับเข็ตของโมเดลที่เหมาะสมได้จากการเพิ่มตัวแปรอิสระเข้าไปในโมเดลครั้งละ 1 ตัว และจะค้นหาจนกระทั่งไม่มีตัวแปรอิสระตัวใดที่สามารถอธิบายความผันแปรของ Y ได้อีก เมื่อตัวแปรอิสระตัวใดถูกเลือกเข้ามาอยู่ในโมเดลแล้ว จะไม่มีการพิจารณาตัดออกภายหลัง ซึ่งขั้นตอนในการเลือกตัวแปรด้วยวิธี Forward Selection มีดังนี้

1. เลือกตัวแปรอิสระตัวแรกเข้าในโมเดล โดยเลือกตัวที่มีค่าสัมประสิทธิ์สหสัมพันธ์อย่างง่ายกับตัวแปรตาม Y สูงสุดเข้าเป็นตัวแรก ซึ่งจะเป็นตัวแปรที่ให้ค่าสถิติ F ที่ใช้ทดสอบนัยสำคัญของตัวแปรอิสระสูงสุด ด้วยเช่นกัน สมมติตัวแปรอิสระที่ถูกเลือกเข้าเป็นตัวแรก คือ X_j
2. ทดสอบอิทธิพลของตัวแปรอิสระที่เพิ่มเข้ามา โดยกำหนดสมมติฐานของการทดสอบเป็น

$$H_0 : \beta_j = 0 \quad vs. \quad H_1 : \beta_j \neq 0$$

- หากยอมรับ H_0 นั่นคือ F_c ที่คำนวณได้มีค่าน้อยกว่าค่า F ที่กำหนด ซึ่งแทนด้วย F_{IN} จะหยุดพิจารณาเลือกตัวแปรอิสระเข้าในโมเดล
- หากปฏิเสธ H_0 นั่นคือ $F_c \geq F_{IN}$ จะรับเอา X_j เข้าในโมเดลลดด้อย และค้นหาตัวแปรอิสระตัวถัดไป โดยทำต่อในขั้นที่ 3
- 3. เลือกตัวแปรอิสระตัวใหม่เข้าในสมการ โดยเลือกตัวแปรที่ให้ค่าสัมประสิทธิ์สหสัมพันธ์บางส่วน หรือ ค่าสัมประสิทธิ์ตัวกำหนดบางส่วนกับตัวแปรตาม Y เนื่องจากนั้นให้ตัวแปรที่ถูกเลือกก่อนหน้านี้อยู่ในโมเดลด้วย มีค่าสูงสุด สมมติให้ตัวแปรที่พิจารณาเข้าในโมเดลตัวถัดไป คือ X_ℓ
- 4. ทดสอบอิทธิพลของตัวแปรอิสระที่เพิ่มเข้ามา เมื่อกำหนดให้ตัวแปรที่ถูกเลือกก่อนหน้านี้อยู่ในโมเดลด้วย โดยใช้ Partial F -test นั่นคือ

$$F_c = \frac{MSR(X_\ell | X_j)}{MSE(X_j, X_\ell)}$$

- หากยอมรับ H_0 จะรับเอาโมเดลลดด้อยเดิมที่มีเฉพาะ X_j อยู่ในโมเดลเป็นโมเดลสุดท้าย และหยุดพิจารณาเลือกตัวแปรอิสระเข้าในโมเดล

- หากปฏิเสธ H_0 จะรับเอา X_j เข้าในโมเดลทดแทน และค้นหาตัวแปรอิสระทั่วไป การพิจารณาเลือกตัวแปรอิสระเข้าในโมเดลจะทำไปเรื่อยๆ จนกระทั่งไม่สามารถหาตัวแปรอิสระเพิ่มเข้ามาในโมเดลได้อีก นั่นคือ $F_c < F_{IN}$ หรือจะทั่งตัวแปรอิสระทั่วสุดท้ายถูกเพิ่มเข้ามาในโมเดล

ตัวอย่างที่ 7.2 จากข้อมูลในตัวอย่างที่ 7.1 จงเลือกตัวแปรอิสระเข้าในโมเดลโดยใช้วิธี Forward selection

วิธีท่า

| | Y | X_1 | X_2 | X_3 | X_4 |
|-------|---------|--------|---------|---------|---------|
| Y | 1.0000 | 0.8006 | 0.4761 | -0.1434 | 0.8177 |
| X_1 | 0.8006 | 1.0000 | 0.4408 | 0.0454 | 0.7072 |
| X_2 | 0.4761 | 0.4408 | 1.0000 | -0.0672 | 0.5877 |
| X_3 | -0.1434 | 0.0454 | -0.0672 | 1.0000 | -0.1989 |
| X_4 | 0.8177 | 0.7072 | 0.5877 | -0.1989 | 1.0000 |

ตารางที่ 7.3: แสดงค่าสัมประสิทธิ์สหสัมพันธ์ของข้อมูลในตัวอย่างที่ 7.1

ขั้นที่ 1 พิจารณาค่าสัมประสิทธิ์สหสัมพันธ์ของตัวอย่างที่ระบุว่าตัวแปรตาม Y และตัวแปรอิสระ X_j เมื่อ $j = 1, 2, 3, 4$ ดังแสดงในตารางที่ 7.3 พบว่า X_4 มีค่าสัมประสิทธิ์สหสัมพันธ์ของตัวอย่างที่สูงที่สุด นั่นคือ $r_{Y4} = 0.8177$ ดังนั้น X_4 จะถูกพิจารณาเลือกเข้าในโมเดลเป็นตัวแรก สร้างสมการทดแทนระหว่าง Y กับ X_4 ได้เป็น

$$\hat{Y} = 85.3615 + 25.8571X_4$$

(12.444) (5.0482)

โดยที่ $SSR(X_4) = 12,247$, $SSE(X_4) = 6,068.5434$ และ $SST = 18315$

ขั้นที่ 2 ทดสอบอิทธิพลของ X_4 ที่มีต่อตัวแปรตาม Y โดยกำหนดสมมติฐานของการทดสอบเป็น

$$H_0 : \beta_4 = 0 \quad vs. \quad H_1 : \beta_4 \neq 0$$

คำนวณสถิติทดสอบ

$$\begin{aligned}
 F_c &= \frac{MSR(X_4)}{MSE(X_4)} \\
 &= \frac{12,247}{466.8110} \\
 &= 26.24
 \end{aligned}$$

ค่าวิกฤติ คือ $F_{IN} = F_{1,13}(0.05) = 4.67$

สรุปผล ปฏิเสธ H_0 นั้นคือ X_4 มีอิทธิพลต่อ Y อย่างมีนัยสำคัญ ที่ $\alpha = 0.05$ ดังนั้นจะรับเอา X_4 เข้าในสมการทดสอบ

ขั้นที่ 3 ค้นหาตัวแปรอิสระตัวใหม่ใส่เข้าในโมเดลที่มี X_4 อยู่ในโมเดลแล้ว

| ตัวแปรอิสระที่อยู่ในโมเดล | SSR | SSE | สมการทดสอบ |
|---------------------------|--------|------------|--|
| (X_1, X_4) | 14,058 | 4,257.0398 | $\hat{Y} = 74.3541 - \frac{12.1859}{(11.8911)} X_1 + \frac{15.9098}{(5.3926)} X_4$ |
| (X_2, X_4) | 12,247 | 6,069.9990 | $\hat{Y} = \frac{86.8097}{(46.0019)} - \frac{0.4249}{(12.9517)} X_2 + \frac{25.9823}{(6.4398)} X_4$ |
| (X_3, X_4) | 12,254 | 6,061.4341 | $\hat{Y} = \frac{83.3056}{(21.6298)} - \frac{10.1051}{(85.1776)} X_3 + \frac{25.9836}{(5.3584)} X_4$ |

ตารางที่ 7.4: แสดงการคำนวณค่าต่าง ๆ ของโมเดลทดสอบที่มี X_4 อยู่ในโมเดลแล้ว

จากตารางที่ 7.4 คำนวณค่าสัมประสิทธิ์ตัวกำหนดบางส่วนระหว่างตัวแปรอิสระแต่ละตัว เมื่อมี X_4 อยู่ในโมเดลแล้ว ดังนี้

$$R^2_{Y1.4} = \frac{SSR(X_1 | X_4)}{SSE(X_4)} = \frac{SSR(X_1, X_4) - SSR(X_4)}{SSE(X_4)} = \frac{14,058 - 12,247}{6,068.5434} = 0.2984$$

$$R^2_{Y2.4} = \frac{SSR(X_2 | X_4)}{SSE(X_4)} = \frac{SSR(X_2, X_4) - SSR(X_4)}{SSE(X_4)} = \frac{12,247 - 12,247}{6,068.5434} = 0$$

$$R^2_{Y3.4} = \frac{SSR(X_3 | X_4)}{SSE(X_4)} = \frac{SSR(X_3, X_4) - SSR(X_4)}{SSE(X_4)} = \frac{12,254 - 12,247}{6,068.5434} = 0.0012$$

เนื่องจาก $R^2_{Y1.4}$ มีค่าสูงสุด ดังนั้น X_1 เป็นตัวแปรอิสระตัวถัดไปที่ถูกพิจารณาเข้าในโมเดลที่มี X_4 อยู่ในโมเดลแล้ว

ขั้นที่ 4 ทดสอบอิทธิพลของ X_1 ที่มีต่อตัวแปรตาม Y เมื่อให้ X_4 อยู่ในโมเดลแล้ว โดยกำหนดสมมติฐานของการทดสอบเป็น

$$H_0 : \beta_1 = 0 \quad vs. \quad H_1 : \beta_1 \neq 0$$

คำนวณ Partial F-test

$$\begin{aligned}
 F_c &= \frac{MSR(X_1 | X_4)}{MSE(X_1, X_4)} \\
 &= \frac{1,811/1}{4,257.0398/12} \\
 &= 5.1049
 \end{aligned}$$

ค่าวิเคราะห์ F คือ $F_{IN} = F_{1,12}(0.05) = 4.75$

สรุปผล ปฏิเสธ H_0 นั้นคือ X_1 มีอิทธิพลต่อ Y อย่างมีนัยสำคัญ ที่ $\alpha = 0.05$ เมื่อให้ X_4 อยู่ในโมเดลแล้ว ดังนั้นจะรับเอา X_1 เข้าในโมเดลโดยเป็นตัวแปรตัวเดียว

ข้อที่ 5 ค้นหาตัวแปรอิสระตัวใหม่ใส่เข้าในโมเดลที่มี (X_1, X_4) อยู่ในโมเดลแล้ว

| ตัวแปรอิสระที่อยู่ในโมเดล | SSR | SSE | สมการทดแทน |
|---------------------------|--------|------------|---|
| (X_1, X_2, X_4) | 14,065 | 4,250.2077 | $\hat{Y} = 79.4602 + 12.2189X_1 - 1.5069X_2 + 16.3269X_4$ $(40.3542) \quad (5.6334) \quad (11.3325) \quad (7.2137)$ |
| (X_1, X_3, X_4) | 14,141 | 4,174.1876 | $\hat{Y} = 80.9837 + 12.9127X_1 - 35.8135X_3 + 6.8128X_4$ $(18.7765) \quad (5.7902) \quad (76.6450) \quad (14.8682)$ |

ตารางที่ 7.5: แสดงการคำนวณค่าต่าง ๆ ของโมเดลโดยที่มี (X_1, X_4) อยู่ในโมเดลแล้ว

จากตารางที่ 7.5 คำนวณค่าสัมประสิทธิ์ตัวกำหนดบางส่วนระหว่างตัวแปรอิสระแต่ละตัว เมื่อมี (X_1, X_4) อยู่ในโมเดลแล้ว ดังนี้

$$\begin{aligned}
 R^2_{Y2-14} &= \frac{SSR(X_2 | X_1, X_4)}{SSE(X_1, X_4)} = \frac{SSR(X_1, X_2, X_4) - SSR(X_1, X_4)}{SSE(X_1, X_4)} = \frac{14,065 - 14,058}{4,257.0398} \\
 &= 0.0016 \\
 R^2_{Y3-14} &= \frac{SSR(X_3 | X_1, X_4)}{SSE(X_1, X_4)} = \frac{SSR(X_1, X_3, X_4) - SSR(X_1, X_4)}{SSE(X_1, X_4)} = \frac{14,141 - 14,058}{4,257.0398} \\
 &= 0.0195
 \end{aligned}$$

เนื่องจาก R^2_{Y3-14} มีค่าสูงสุด ดังนั้น X_3 เป็นตัวแปรอิสระที่สำคัญที่สุดในโมเดลที่มี (X_1, X_4) อยู่ในโมเดลแล้ว

ข้อที่ 6 ทดสอบอิทธิพลของ X_3 ที่มีต่อตัวแปรตาม Y เมื่อให้ (X_1, X_4) อยู่ในโมเดลแล้ว โดยกำหนดสมมติฐาน

ของการทดสอบเป็น

$$H_0 : \beta_3 = 0 \quad vs. \quad H_1 : \beta_3 \neq 0$$

คำนวณ Partial F-test

$$\begin{aligned} F_c &= \frac{MSR(X_3 | X_1, X_4)}{MSE(X_1, X_3, X_4)} \\ &= \frac{83/1}{4,174.1876/11} \\ &= 0.2187 \end{aligned}$$

ค่าวิกฤติ คือ $F_{IN} = F_{1,11(0.05)} = 4.84$

สรุปผล ไม่สามารถปฏิเสธ H_0 ได้ นั่นคือ X_3 ไม่มีอิทธิพลต่อ Y อย่างมีนัยสำคัญ ที่ $\alpha = 0.05$ เมื่อให้ (X_1, X_4) อยู่ในโมเดลแล้ว ตั้งนั้นจะหยุดการค้นหาตัวแปรอิสระเข้าในโมเดล และรับเอาโมเดลที่มี (X_1, X_4) เป็นโมเดลสุดท้าย ได้สมการพยากรณ์ดังนี้

$$\hat{Y} = 74.3541 - 12.1859X_1 + 15.9098X_4$$
$$(11.8911) \quad (5.3926) \quad (6.2245)$$

โดยมีค่า $R^2 = 0.7676$ และ $R^2_{adj} = 0.7288$

7.3.3 การเลือกตัวแปรด้วยวิธี Backward Elimination

การเลือกตัวแปรด้วยวิธี Forward selection เริ่มด้วยโมเดลที่ไม่มีตัวแปรอิสระเลย แล้วจึงเพิ่มตัวแปรอิสระเข้าไปครั้งละตัว จนกระทั่งได้โมเดลที่เหมาะสม การเลือกตัวแปรด้วยวิธี Backward Elimination จะทำงานในลักษณะตรงกันข้าม นั่นคือ เริ่มต้นด้วยโมเดลลดด้อยที่ประกอบด้วยตัวแปรอิสระทั้ง k ตัว แล้วจึงตัดตัวแปรอิสระที่อธิบายความสัมพันธ์กับตัวแปรตาม Y ได้ออกไปครั้งละ 1 ตัว จนกระทั่งตัวแปรที่เหลืออยู่ในโมเดลสามารถอธิบายความสัมพันธ์กับ Y ได้ทั้งหมด ก็จะหยุดการทำงาน เมื่อตัวแปรอิสระตัวใดถูกตัดออกจากโมเดลแล้ว จะไม่มีการพิจารณาเพิ่มเข้ามาอยู่ในโมเดลอีกในภายหลัง ซึ่งการเลือกตัวแปรด้วยวิธี Backward elimination มีขั้นตอนดังนี้

- สร้างโมเดลลดด้อยที่ประกอบด้วยตัวแปรอิสระทุกตัว ซึ่งในที่นี้คือ k ตัว จากนั้นคำนวณ Partial F-test หรือ t test ของตัวแปรอิสระแต่ละตัว และพิจารณาตัวแปรอิสระที่มีส่วนอธิบายความสัมพันธ์กับ

Y ได้น้อยที่สุด นั่นคือ ตัวที่มีค่าสถิติ F_c หรือ $|t_c|$ ต่ำที่สุด สมมติให้เป็น X_i และทดสอบอิทธิพลของ X_i โดยกำหนดสมมติฐานของการทดสอบเป็น

$$H_0 : \beta_i = 0 \quad vs. \quad H_1 : \beta_i \neq 0$$

- หากปฏิเสธ H_0 นั่นคือ ค่า F_c ที่คำนวณได้มีค่ามากกว่าหรือเท่ากับค่า F ที่กำหนด ซึ่งเรียกว่า F_{OUT} หรือ $|t_c| \geq t_{OUT}$ แสดงว่าไม่สามารถตัด X_i ออกจากโมเดลได้ จะหยุดการทำงาน และรับเอาโมเดลดังกล่าวเป็นโมเดลสุดท้าย
 - หากยอมรับ H_0 นั่นคือ $F_c < F_{OUT}$ หรือ $|t_c| < t_{OUT}$ จะตัดตัวแปรทั้งกล่าวออกจากโมเดล และคันหาตัวแปรอิสระตัวใหม่ที่จะถูกตัดออกจากโมเดลเป็นลำดับต่อไป
2. สร้างสมการลดด้อยใหม่ที่ประกอบด้วยตัวแปรอิสระ $k - 1$ ตัว (ไม่รวม X_i) จากนั้นคำนวณ Partial F -test หรือ t test ของตัวแปรอิสระแต่ละตัวทั้ง $k - 1$ ตัว พิจารณาตัวแปรที่มีค่า F_c หรือ $|t_c|$ ต่ำที่สุด สมมติให้เป็น X_ℓ และกำหนดสมมติฐานเพื่อทดสอบอิทธิพลของ X_ℓ เมื่อตัวแปรอิสระอื่นอยู่ในโมเดล ด้วย กำหนดสมมติฐานของการทดสอบได้เป็น

$$H_0 : \beta_\ell = 0 \quad vs. \quad H_1 : \beta_\ell \neq 0$$

- หากปฏิเสธ H_0 แสดงว่าไม่สามารถตัด X_ℓ ออกจากโมเดลได้ จะหยุดการทำงาน และรับเอาโมเดลที่ประกอบด้วยตัวแปรอิสระ $k - 1$ ตัวเป็นโมเดลสุดท้าย
- หากยอมรับ H_0 จะตัด X_ℓ ออกจากโมเดล และคันหาตัวแปรอิสระตัวใหม่ที่จะถูกตัดออกจากโมเดลเป็นลำดับต่อไป ซึ่งการพิจารณาตัดตัวแปรอิสระออกไปครั้งละตัวจะทำไปเรื่อย ๆ จนกระทั่งไม่สามารถตัดตัวแปรตัวใดออกจากโมเดลได้อีก นั่นคือ ตัวแปรทุกตัวมีค่า $F_c \geq F_{OUT}$ หรือ $|t_c| \geq t_{OUT}$ นั่นเอง

ตัวอย่างที่ 7.3 จากข้อมูลในตัวอย่างที่ 7.1 จงเลือกตัวแปรอิสระเข้าในโมเดลโดยใช้วิธี Backward elimination

วิธีทำ

ขั้นที่ 1 สร้างสมการลดด้อยที่มีตัวแปรอิสระทั้ง 4 ตัว ได้ดังนี้

$$\hat{Y} = 85.0334 + 12.9307X_1 - 1.2326X_2 - 35.3682X_3 + 15.2223X_4 \quad (7.11)$$

| ตัวแปรอิสระที่อยู่ในโมเดล | ค่าสัมประสิทธิ์ถดถอย | ค่าความคลาดเคลื่อนมาตรฐาน | <i>t</i> |
|---------------------------|----------------------|---------------------------|----------|
| X_1 | 12.9307 | 6.0719 | 2.13 |
| X_2 | -1.2326 | 11.7889 | -0.10 |
| X_3 | -35.3682 | 80.4549 | -0.44 |
| X_4 | 15.2223 | 7.9038 | 1.93 |

ตารางที่ 7.6: แสดงการทดสอบอิทธิพลของตัวแปรอิสระแต่ละตัวของสมการที่ (7.11)

จากนั้นคำนวณสถิติทดสอบ t_c ดังแสดงในตารางที่ 7.6 จะเห็นได้ว่า $|t_c|$ ของตัวแปรอิสระ X_2 มีค่าต่ำสุด ทำการทดสอบอิทธิพลของ X_2 โดยกำหนดสมมติฐานของการทดสอบดังนี้

$$H_0 : \beta_2 = 0 \quad vs. \quad H_2 : \beta_2 \neq 0$$

ได้ค่าสถิติทดสอบ $|t_c| = 0.10$

ค่าวิกฤติ คือ $t_{0.025, 10} = 2.228$

สรุปผล ไม่สามารถปฏิเสธ H_0 ดังนั้น สามารถตัด X_2 ออกจากโมเดลได้

ขั้นที่ 2 สร้างสมการถดถอยที่มีตัวแปรอิสระ 3 ตัว (ตัด X_2 ออก) ได้ดังนี้

$$\hat{Y} = 80.9837 + 12.9127X_1 - 35.8135X_3 + 6.8128X_4 \quad (7.12)$$

| ตัวแปรอิสระที่อยู่ในโมเดล | ค่าสัมประสิทธิ์ถดถอย | ค่าความคลาดเคลื่อนมาตรฐาน | <i>t</i> |
|---------------------------|----------------------|---------------------------|----------|
| X_1 | 12.9127 | 5.7902 | 2.23 |
| X_3 | -35.8135 | 76.6450 | -0.47 |
| X_4 | 6.8128 | 14.8682 | 2.18 |

ตารางที่ 7.7: แสดงการทดสอบอิทธิพลของตัวแปรอิสระแต่ละตัวของสมการที่ (7.12)

จากตารางที่ 7.7 จะเห็นได้ว่า $|t_c|$ ของตัวแปรอิสระ X_3 มีค่าต่ำสุด ทำการทดสอบอิทธิพลของ X_3 โดยกำหนดสมมติฐานของการทดสอบดังนี้

$$H_0 : \beta_3 = 0 \quad vs. \quad H_2 : \beta_3 \neq 0$$

ได้ค่าสถิติทดสอบ $|t_c| = 0.47$

ค่าวิกฤติ คือ $t_{0.025, 11} = 2.201$

สรุปผล ไม่สามารถปฏิเสธ H_0 ดังนั้น สามารถตัด X_3 ออกจากโมเดลได้

ขั้นที่ 3 สร้างสมการโดยที่มีตัวแปรอิสระ 2 ตัว (ตัด X_2 และ X_3 ออก) ได้ดังนี้

$$\hat{Y} = 74.3541 - 12.1859X_1 + 15.9098X_4 \quad (7.13)$$

| ตัวแปรอิสระที่อยู่ในโมเดล | ค่าสัมประสิทธิ์ทดสอบ | ค่าความคาดเคลื่อนมาตรฐาน | t |
|---------------------------|----------------------|--------------------------|------|
| X_1 | 12.1859 | 5.3926 | 2.26 |
| X_4 | 15.9098 | 6.2245 | 5.56 |

ตารางที่ 7.8: แสดงการทดสอบอิทธิพลของตัวแปรอิสระแต่ละตัวของสมการที่ (7.13)

จากตารางที่ 7.8 จะเห็นได้ว่า $|t_c|$ ของตัวแปรอิสระ X_1 มีค่าต่ำสุด ทำการทดสอบอิทธิพลของ X_1 โดยกำหนดสมมติฐานของการทดสอบดังนี้

$$H_0 : \beta_1 = 0 \quad vs. \quad H_2 : \beta_1 \neq 0$$

ได้ค่าสถิติทดสอบ $|t_c| = 2.26$

ค่าวิกฤติ คือ $t_{0.025, 12} = 2.179$

สรุปผล ปฏิเสธ H_0 นั้นคือ X_1 มีอิทธิพลต่อ Y อย่างมีนัยสำคัญที่ $\alpha = 0.05$ จึงไม่สามารถตัด X_1 ออกจากโมเดลได้ และจะหยุดการตัดตัวแปรอิสระออกจากโมเดล ดังนั้นจึงรับเอาสมการที่มี X_1 และ X_4 เป็นสมการสุดท้าย ซึ่งจะเห็นได้ว่าผลที่ได้สอดคล้องกับการเลือกตัวแปรด้วยวิธี Forward selection

หมายเหตุ บอยครั้งการเลือกตัวแปรด้วยวิธี Backward elimination จัดเป็นกระบวนการที่ดีในการตัดเลือกตัวแปรเข้าในโมเดล และเป็นที่นิยมของนักวิเคราะห์ที่ต้องการศึกษาอิทธิพลของตัวแปรอิสระที่เป็นไปได้ทั้งหมด โดยไม่ได้เลขหรือมองข้ามตัวแปรทั้งหมด

7.3.4 การเลือกตัวแปรด้วยวิธี Stepwise Regression

นอกจากการเลือกตัวแปรด้วยวิธี Forward selection และ Backward elimination แล้ว ยังมีการเลือกตัวแปรอิภพน์ที่เป็นที่นิยมใช้กันมาก ก็คือ วิธี Stepwise regression ซึ่งประยุกต์มาจากวิธี Forward selection โดยเลือกตัวแปรอิสระเข้าในโมเดลครั้งละ 1 ตัว เช่นกัน แต่เพิ่มการทดสอบอิทธิพลของตัวแปรอิสระที่อยู่ในโมเดลก่อนหน้านี้แล้วทุกตัว เมื่อกำหนดให้ตัวแปรอิสระอื่นยังคงอยู่ในโมเดลตัวย โดยใช้ Partial F-test หรือ t-test ดังนั้นตัวแปรอิสระที่เพิ่มเข้ามาในโมเดลทดสอบอยู่ในขั้นแรก ๆ อาจถูกตัดออกไปได้ในภายหลัง นอกจากนี้ การเลือกตัวแปรด้วยวิธี Stepwise regression ต้องการค่าวิกฤติ 2 ค่า คือ F_{IN} และ F_{OUT} (หรือ t_{IN} และ

t_{OUT}) โดยอาจให้ $F_{IN} = F_{OUT}$ ก็ได้ แต่โดยทั่วไปนิยมให้ $F_{IN} > F_{OUT}$ เพื่อให้การเพิ่มตัวแปรเข้าในโมเดลทำได้ยากกว่าที่จะตัดตัวแปรออกจากโมเดล ชั้งการเลือกตัวแปรด้วยวิธี Stepwise regression มีขั้นตอนดังนี้

1. เลือกตัวแปรอิสระตัวแรกเข้าในโมเดล โดยเลือกตัวที่มีค่าสัมประสิทธิ์สหสัมพันธ์อย่างง่ายกับตัวแปรตามสูงสุด สมมติให้เป็น X_j
2. สร้างโมเดลทดสอบที่มี X_j ออยู่ด้วย และทดสอบอิทธิพลของ X_j โดยกำหนดสมมติฐานของการทดสอบเป็น

$$H_0 : \beta_j = 0 \quad vs. \quad H_2 : \beta_j \neq 0$$

- หากยอมรับ H_0 นั่นคือ $F_c < F_{IN}$ จะหยุดพิจารณาเลือกตัวแปรอิสระเข้าในโมเดล
 - หากปฏิเสธ H_0 นั่นคือ $F_c \geq F_{IN}$ จะรับเอา X_j เข้าในโมเดลทดสอบ และต้นหาตัวแปรอิสระตัวถัดไป โดยทำต่อในขั้นที่ 3
3. เลือกตัวแปรอิสระตัวใหม่เข้าในสมการ โดยเลือกตัวแปรที่ให้ค่าสัมประสิทธิ์สหสัมพันธ์บางส่วน หรือค่าสัมประสิทธิ์ตัวกำหนดบางส่วนกับตัวแปรตาม Y เมื่อกำหนดให้ตัวแปรที่ถูกเลือกก่อนหน้านี้อยู่ในโมเดลด้วย มีค่าสูงสุด สมมติให้ตัวแปรที่พิจารณาเข้าในโมเดลตัวถัดไป คือ X_ℓ
 4. สร้างโมเดลทดสอบที่มีทั้ง X_j และ X_ℓ รวมอยู่ด้วย และทดสอบอิทธิพลของตัวแปรอิสระที่อยู่ในโมเดลที่ลงตัว เมื่อกำหนดให้ตัวแปรอื่นยังคงอยู่ในโมเดลด้วย นั่นคือ ทดสอบอิทธิพลของ X_ℓ เมื่อมี X_j รวมอยู่ในโมเดลด้วย โดยกำหนดสมมติฐานของการทดสอบเป็น

$$H_0 : \beta_\ell = 0 \quad vs. \quad H_2 : \beta_\ell \neq 0$$

คำนวณ Partial F -test นั่นคือ

$$F_c = \frac{MSR(X_\ell | X_j)}{MSE(X_j, X_\ell)}$$

- หากยอมรับ H_0 แสดงว่า X_ℓ ไม่มีอิทธิพลต่อ Y เมื่อมี X_j ออยู่ด้วย จะตัด X_ℓ ออกไป
- หากปฏิเสธ H_0 จะรับเอา X_ℓ เข้าในโมเดลทดสอบ และทดสอบอิทธิพลของ X_j เมื่อมี X_ℓ รวมอยู่ในโมเดลด้วย โดยกำหนดสมมติฐานของการทดสอบเป็น

$$H_0 : \beta_j = 0 \quad vs. \quad H_2 : \beta_j \neq 0$$

คำนวณ Partial F-test นั้นคือ

$$F_c = \frac{MSR(X_j | X_{\ell})}{MSE(X_j, X_{\ell})}$$

- หากยอมรับ H_0 แสดงว่า X_j ไม่มีอิทธิพลต่อ Y เมื่อมี X_{ℓ} อยู่ด้วย จะตัด X_j ออกไป
- หากปฏิเสธ H_0 จะเก็บ X_j ไว้ในโมเดลลดถอยต่อไป

5. การพิจารณาเลือกตัวแปรตั้งกล่าวจะทำไปเรื่อย ๆ จนกระทั่งไม่สามารถหาตัวแปรอิสระอื่นเพิ่มเข้ามาในโมเดลได้อีก และขณะเดียวกันก็ไม่สามารถตัดตัวแปรอิสระที่อยู่ในโมเดลออกได้ นั้นคือ ตัวแปรอิสระทุกตัวที่อยู่ในโมเดลมีค่า $F_c \geq F_{OUT}$

ตัวอย่างที่ 7.4 จากข้อมูลในตัวอย่างที่ 7.1 จะเลือกตัวแปรอิสระเข้าในโมเดลโดยใช้วิธี Stepwise selection

วิธีทำ

ขั้นที่ 1 พิจารณาค่าสัมประสิทธิ์สหสัมพันธ์อย่างง่ายระหว่าง Y กับตัวแปรอิสระแต่ละตัว

$$r_{Y1} = 0.8066, \quad r_{Y2} = 0.4761,$$

$$r_{Y3} = -0.1434, \quad r_{Y4} = 0.8177$$

จะเห็นได้ว่า r_{Y4} มีค่าสูงสุด ดังนั้นตัวแปร X_4 จะถูกเลือกเข้าในโมเดลเป็นตัวแรก

ขั้นที่ 2 สร้างสมการลดถอยที่มี X_4 อยู่ในสมการได้ดังนี้

$$\hat{Y} = 85.3615 + \frac{25.8571X_4}{(12.444)} \quad (5.0482)$$

โดยที่ $SSR(X_4) = 12,247$, $SSE(X_4) = 6,068.5434$ และ $SST = 18315$

ทดสอบอิทธิพลของ X_4 ที่มีต่อตัวแปรตาม Y โดยกำหนดสมมติฐานของการทดสอบเป็น

$$H_0 : \beta_4 = 0 \quad vs. \quad H_1 : \beta_4 \neq 0$$

คำนวณสถิติทดสอบ

$$F_c = \frac{SSR(X_4)}{SSE(X_4)} = \frac{12,247}{466.8110} = 26.24$$

ค่าวิกฤติ คือ $F_{IN} = F_{1,13}(0.05) = 4.67$

สรุปผล ปฏิเสธ H_0 นั่นคือ X_4 มีอิทธิพลต่อ Y อย่างมีนัยสำคัญ ที่ $\alpha = 0.05$ ดังนั้นจะรับเอา X_4 เข้าในสมการทดถอย

ขั้นที่ 3 เลือกตัวแปรอิสระตัวใหม่เข้าในสมการ โดยพิจารณาค่าสัมประสิทธิ์ตัวกำหนดบางส่วนระหว่างตัวแปรอิสระแต่ละตัวกับ Y เมื่อ X_4 อยู่ในโมเดลด้วย ซึ่งได้จากตัวอย่างที่ 7.2 ดังนี้

$$R_{Y1.4}^2 = 0.2984, \quad R_{Y2.4}^2 = 0, \quad R_{Y3.4}^2 = 0.0012$$

เนื่องจาก $R_{Y1.4}^2$ มีค่าสูงสุด ดังนั้น X_1 เป็นตัวแปรอิสระตัวถัดไปที่ถูกพิจารณาเข้าในโมเดลที่มี X_4 อยู่ในโมเดลแล้ว

ขั้นที่ 4 สร้างสมการทดถอยที่มีตัวแปร (X_1, X_4) อยู่ในสมการได้ดังนี้

$$\hat{Y} = 74.3541 - 12.1859X_1 + 15.9098X_4 \quad (7.14)$$

การทดสอบอิทธิพลของ X_1 ที่มีต่อตัวแปรตาม Y เมื่อให้ X_4 อยู่ในโมเดลแล้ว ทำได้โดยกำหนดสมมติฐานของการทดสอบเป็น

$$H_0 : \beta_1 = 0 \quad vs. \quad H_1 : \beta_1 \neq 0$$

คำนวณ Partial F -test

$$\begin{aligned} F_c &= \frac{MSR(X_1 | X_4)}{MSE(X_1, X_4)} \\ &= 5.1049 \end{aligned}$$

ค่าวิกฤติ คือ $F_{IN} = F_{1,12}(0.05) = 4.75$

สรุปผล ปฏิเสธ H_0 นั่นคือ X_1 มีอิทธิพลต่อ Y อย่างมีนัยสำคัญ ที่ $\alpha = 0.05$ เมื่อให้ X_4 อยู่ในโมเดลแล้ว

จากนั้นทดสอบอิทธิพลของ X_4 ที่มีต่อตัวแปรตาม Y เมื่อให้ X_1 อยู่ในโมเดลแล้ว โดยกำหนดสมมติฐานของการทดสอบเป็น

$$H_0 : \beta_4 = 0 \quad vs. \quad H_1 : \beta_4 \neq 0$$

คำนวณ Partial F-test

$$\begin{aligned}
 F_c &= \frac{MSR(X_4 | X_1)}{MSE(X_1, X_4)} \\
 &= \frac{[SSR(X_1, X_4) - SSR(X_1)]/1}{SSE(X_1, X_4)/12} \\
 &= \frac{(14,058 - 11,741)/1}{4,257.0398/12} \\
 &= 6.5313
 \end{aligned}$$

ค่าวิเคราะห์ คือ $F_{OUT} = F_{1,12}(0.05) = 4.75$

สรุปผล ปฏิเสธ H_0 นั่นคือ X_4 มีอิทธิพลต่อ Y อย่างมีนัยสำคัญ ที่ $\alpha = 0.05$ เมื่อให้ X_1 อยู่ในโมเดลแล้ว ดังนั้นจะรับเอาทั้ง X_1 และ X_4 เข้าในโมเดล

ข้อที่ 5 ค้นหาตัวแปรอิสระตัวใหม่ใส่เข้าในโมเดลที่มี (X_1, X_4) อยู่ในโมเดลแล้ว โดยพิจารณาจากค่าสัมประสิทธิ์ตัวกำหนดบางส่วนที่ได้จากตัวอย่างที่ 7.2 ดังนี้

$$R_{Y2.14}^2 = 0.0016, \quad R_{Y3.14}^2 = 0.0195$$

เนื่องจาก $R_{Y3.14}^2$ มีค่าสูงสุด ดังนั้น X_3 เป็นตัวแปรอิสระตัวถัดไปที่ถูกพิจารณาเข้าในโมเดลที่มี (X_1, X_4) อยู่ในโมเดลแล้ว

ข้อที่ 6 ทดสอบอิทธิพลของ X_3 ที่มีต่อตัวแปรตาม Y เมื่อให้ (X_1, X_4) อยู่ในโมเดลแล้ว โดยกำหนดสมมติฐานของการทดสอบเป็น

$$H_0 : \beta_3 = 0 \quad vs. \quad H_1 : \beta_3 \neq 0$$

คำนวณ Partial F-test

$$\begin{aligned}
 F_c &= \frac{MSR(X_3 | X_1, X_4)}{MSE(X_1, X_3, X_4)} \\
 &= 0.2187
 \end{aligned}$$

ค่าวิเคราะห์ คือ $F_{IN} = F_{1,11}(0.05) = 4.84$

สรุปผล ไม่สามารถปฏิเสธ H_0 ได้ นั่นคือ X_3 ไม่มีอิทธิพลต่อ Y อย่างมีนัยสำคัญ ที่ $\alpha = 0.05$ เมื่อให้ (X_1, X_4) อยู่ในโมเดลแล้ว ดังนั้นจะหยุดการเลือกตัวแปรอิสระเข้าในโมเดล และรับเอาโมเดล

ที่มี (X_1, X_4) เป็นโมเดลสุดท้าย ได้สมการพยากรณ์ดังนี้

$$\hat{Y} = 74.3541 - 12.1859X_1 + 15.9098X_4$$

โดยมีค่า $R^2 = 0.7676$ และ $R^2_{adj} = 0.7288$

ซึ่งจะเห็นได้ว่าสอดคล้องกับโมเดลที่ได้จากวิธี Forward selection และ Backward elimination

หมายเหตุ วิธีการเลือกตัวแปรทั้ง 4 วิธี อาจให้โมเดลสุดท้ายที่แตกต่างกัน เนื่องจากตัวแปรอิสระอาจมีความสัมพันธ์ต่อกันและมีอิทธิพลต่อกันของการเพิ่มและตัดออกจากโมเดล ซึ่งนักวิเคราะห์บางท่านแนะนำให้ใช้วิธีในการเลือกตัวแปรทั้ง 4 วิธี แล้วพิจารณาผลที่ได้ว่าสอดคล้องกันหรือไม่ หรือพิจารณาโครงสร้างของข้อมูลที่อาจถูกมองข้ามโดยการใช้วิธีใดวิธีหนึ่งเพียงอย่างเดียวในการเลือกตัวแปร

ข้อดีของการเลือกตัวแปรด้วยวิธี Forward selection, Backward elimination และ Stepwise regression ก็คือ สะดวก รวดเร็ว และง่ายต่อการใช้งาน แต่ข้อเสียก็คือ สมการสุดท้ายที่ได้อาจไม่ใช่สมการที่ดีที่สุด ที่สอดคล้องกับเกณฑ์มาตรฐานของการพิจารณาเลือกตัวแปร กรณีที่มีจำนวนตัวแปรอิสระมากเกินกว่าที่ใช้วิธี All possible regressions ได้ Montgomery และ Peck (1992) แนะนำให้ทำการเลือกตัวแปร 2 ขั้นตอน คือ คัดตัวแปรอิสระ (Screen) ในเบื้องต้นก่อน โดยใช้วิธี Forward selection, Backward elimination หรือ Stepwise regression แล้วจึงตรวจสอบตัวแปรอิสระที่ได้ด้วยวิธี All possible regressions ซึ่งนักวิเคราะห์จะต้องมีความรู้เกี่ยวกับตัวแปรที่กำลังพิจารณาประกอบด้วย นอกจากเกณฑ์ที่ต้องพิจารณาในการคัดเลือกตัวแปรแล้ว นักวิเคราะห์ควรที่จะตอบคำถามต่อไปนี้ได้

- สมการที่ได้สมเหตุสมผลหรือไม่
- สมการที่ได้มีประโยชน์ตามวัตถุประสงค์ของการศึกษาหรือไม่
- ค่าสัมประสิทธิ์ถูกต้องมีขนาดและทิศทางสอดคล้องกับข้อเท็จจริงหรือไม่ และความคลาดเคลื่อนมาตรฐานของประมาณเมื่อค่าน้อยผิดปกติหรือไม่
- มีการตรวจสอบความเหมาะสมของโมเดลหรือไม่

ดังนั้นการเลือกตัวแปรเข้าในโมเดลควรที่จะต้องอาศัยประสบการณ์และการพิจารณาอย่างมีเหตุผลประกอบการตัดสินใจเลือกตัวแปรเสนอ

แบบฝึกหัดบทที่ 7

1. ในการศึกษาความสัมพันธ์ระหว่างตัวแปรต่อไปนี้

Y = ราคาขายบ้าน / 1000 หน่วย

X_1 = ภายนอก / 1000 หน่วย

X_2 = ขนาดพื้นที่ (sq ft x 1000)

X_3 = จำนวนห้องทั้งหมด

X_4 = จำนวนห้องนอน

X_5 = อายุของบ้าน (ปี)

| Y | X_1 | X_2 | X_3 | X_4 | X_5 |
|------|--------|-------|-------|-------|-------|
| 25.9 | 4.9176 | 3.472 | 7 | 4 | 42 |
| 29.5 | 5.0208 | 3.531 | 7 | 4 | 62 |
| 27.9 | 4.5429 | 2.275 | 6 | 3 | 40 |
| 25.9 | 4.5573 | 4.050 | 6 | 3 | 54 |
| 29.9 | 5.0597 | 4.455 | 6 | 3 | 42 |
| 29.9 | 3.8910 | 4.455 | 6 | 3 | 56 |
| 30.9 | 5.8980 | 5.850 | 7 | 3 | 51 |
| 28.9 | 5.6039 | 9.520 | 6 | 3 | 32 |
| 35.9 | 5.8282 | 6.435 | 6 | 3 | 32 |
| 31.5 | 5.3003 | 4.988 | 6 | 3 | 30 |
| 31.0 | 6.2712 | 5.520 | 5 | 2 | 30 |
| 30.9 | 5.9592 | 6.666 | 6 | 3 | 32 |
| 30.0 | 5.0500 | 5.000 | 5 | 2 | 46 |
| 36.9 | 8.2464 | 5.150 | 8 | 4 | 50 |
| 41.9 | 6.6969 | 6.902 | 7 | 2 | 22 |
| 40.5 | 7.7841 | 7.102 | 6 | 2 | 17 |

- 1.1 จงเลือกตัวแปรอิสระด้วยวิธี All possible regressions พร้อมทั้งเขียนสมการที่ได้ในขั้น สุดท้าย
- 1.2 จงเลือกตัวแปรอิสระด้วยวิธี Forward selection ให้แสดงวิธีทำเป็นขั้น ๆ เมื่อกำหนดให้ค่า $\alpha = 0.10$ เป็นค่า α ที่ใช้ในการคัดเลือกตัวแปรใส่เข้าไปในสมการ พร้อมทั้งเขียนสมการที่ได้ในขั้น สุดท้าย
- 1.3 จงเลือกตัวแปรอิสระด้วยวิธี Backward elimination ให้แสดงวิธีทำเป็นขั้น ๆ เมื่อกำหนดให้ค่า $\alpha = 0.10$ เป็นค่า α ที่ใช้ในการตัดตัวแปรออกจากสมการ พร้อมทั้งเขียนสมการที่ได้ในขั้นสุดท้าย
- 1.4 จงเลือกตัวแปรอิสระด้วยวิธี Stepwise regression ให้แสดงวิธีทำเป็นขั้น ๆ เมื่อกำหนดให้ค่า $\alpha = 0.10$ เป็นค่า α ที่ใช้ในการคัดเลือกตัวแปรใส่เข้าไปในสมการ และตัดตัวแปรออกจากสมการ พร้อมทั้งเขียนสมการที่ได้ในขั้นสุดท้าย

- 1.5 จงเปรียบเทียบสมการที่ได้จากข้อ 1.1, 1.2, 1.3 และ 1.4 และสรุปผล
2. ข้อมูลต่อไปนี้ได้จากการศึกษาผลของธาตุเหล็ก (X_1) อัลูมิเนียม (X_2) และระดับ pH ในดิน (X_3) ที่มีต่อการดูดซึมฟอสฟे�ตในดิน (Y)
- | X_1 | X_2 | X_3 | Y |
|-------|-------|-------|-----|
| 57 | 15 | 7.5 | 8 |
| 171 | 23 | 7.5 | 22 |
| 107 | 26 | 6.6 | 18 |
| 120 | 25 | 7.1 | 22 |
| 126 | 66 | 4.9 | 30 |
| 169 | 40 | 5.5 | 30 |
| 165 | 35 | 5.6 | 25 |
| 165 | 63 | 5.0 | 34 |
| 12 | 41 | 6.1 | 32 |
| 240 | 73 | 5.5 | 40 |
| 253 | 114 | 4.2 | 69 |
| 329 | 90 | 4.3 | 66 |
| 195 | 56 | 6.0 | 44 |
- 2.1 จงเลือกตัวแปรอิสระด้วยวิธี All possible regressions พร้อมทั้งเขียนสมการที่ได้ในขัน สุดท้าย
- 2.2 จงเลือกตัวแปรอิสระด้วยวิธี Forward selection ให้แสดงวิธีทำเป็นขั้น ๆ เมื่อกำหนดให้ค่า $\alpha = 0.10$ เป็นค่า α ที่ใช้ในการคัดเลือกตัวแปรใส่เข้าไปในสมการ พร้อมทั้งเขียนสมการที่ได้ในขัน สุดท้าย
- 2.3 จงเลือกตัวแปรอิสระด้วยวิธี Backward elimination ให้แสดงวิธีทำเป็นขั้น ๆ เมื่อกำหนดให้ค่า $\alpha = 0.10$ เป็นค่า α ที่ใช้ในการตัดตัวแปรออกจากสมการ พร้อมทั้งเขียนสมการที่ได้ในขัน สุดท้าย
- 2.4 จงเลือกตัวแปรอิสระด้วยวิธี Stepwise regression ให้แสดงวิธีทำเป็นขั้น ๆ เมื่อกำหนดให้ค่า $\alpha = 0.10$ เป็นค่า α ที่ใช้ในการคัดเลือกตัวแปรใส่เข้าไปในสมการ และตัดตัวแปรออกจากสมการ พร้อมทั้งเขียนสมการที่ได้ในขัน สุดท้าย
- 2.5 จงเปรียบเทียบสมการที่ได้จากข้อ 2.1, 2.2, 2.3 และ 2.4 และสรุปผล
3. ข้อมูลต่อไปนี้ได้จากการศึกษาผลกระทบของอุณหภูมิ (X_1) และระดับความชื้น (X_2) ที่มีต่อความ บริสุทธิ์ของกระบวนการทางเคมี (Y)
- 3.1 จงเลือกตัวแปรอิสระด้วยวิธี Forward selection ให้แสดงวิธีทำเป็นขั้น ๆ เมื่อกำหนดให้ค่า $\alpha = 0.10$ เป็นค่า α ที่ใช้ในการคัดเลือกตัวแปรใส่เข้าไปในสมการ พร้อมทั้งเขียนสมการที่ได้ในขัน สุดท้าย
- 3.2 จงเลือกตัวแปรอิสระด้วยวิธี Backward elimination ให้แสดงวิธีทำเป็นขั้น ๆ เมื่อกำหนดให้ค่า $\alpha = 0.10$ เป็นค่า α ที่ใช้ในการตัดตัวแปรออกจากสมการ พร้อมทั้งเขียนสมการที่ได้ในขัน สุดท้าย

| X_1 | X_2 | Y |
|-------|-------|------|
| 85.68 | 43.7 | 16.0 |
| 83.68 | 44.8 | 18.0 |
| 84.38 | 44.1 | 18.5 |
| 86.18 | 45.0 | 18.0 |
| 85.08 | 44.9 | 18.0 |
| 83.68 | 45.1 | 17.8 |
| 85.98 | 44.7 | 18.2 |
| 85.78 | 44.8 | 18.0 |
| 85.58 | 44.7 | 17.8 |
| 86.18 | 44.0 | 18.0 |
| 83.38 | 45.4 | 17.8 |
| 85.68 | 44.2 | 18.2 |
| 85.78 | 44.5 | 18.7 |
| 84.08 | 44.9 | 18.0 |

3.3 จงเลือกตัวแปรอิสระตัวใดตัวหนึ่ง Stepwise regression ให้แสดงวิธีทำเป็นขั้น ๆ เมื่อกำหนดให้ค่า $\alpha = 0.10$ เป็นท่า α ที่ใช้ในการคัดเลือกตัวแปรใส่เข้าไปในสมการ และตัดตัวแปรออกจากสมการ พร้อมทั้งเขียนสมการที่ได้ในขั้นสุดท้าย

3.4 จงเปรียบเทียบสมการที่ได้จากข้อ 3.1, 3.2 และ 3.3 และสรุปผล