

บทที่ 3

การวิเคราะห์เส้นถดถอยเชิงซ้อน

(Multiple Regression Analysis)

ในบทก่อน เราได้กล่าวถึงเส้นถดถอยอย่างง่ายซึ่งเป็นความสัมพันธ์ในเชิงเศรษฐกิจระหว่าง 2 ตัวแปร $Y = f(x)$. ในกรณีตัวอย่างเส้น demand ซึ่งมีตัวแบบ $Q_d = a + bP + e$ เราได้สร้างเทคนิคในการประมาณค่า a, b , ค่าสถิติต่าง ๆ และการทดสอบเกี่ยวกับความสัมพันธ์ของมัน อย่างไรก็ตาม ความสัมพันธ์ทางเศรษฐกิจเกี่ยวข้องยุ่งยากมากกว่านี้ จำนวน demand มักจะไม่ขึ้นอยู่กับตัวแปรตัวเดียวแต่ขึ้นอยู่กับกลุ่มของตัวแปรอิสระทั้งกลุ่ม เช่น ราคาสินค้า X ราคาสินค้า Y ราคาสินค้า Z รายได้ และรสนิยม เป็นต้น ซึ่งจะเขียนเป็นฟังก์ชันได้ว่า $Q_d = f(P_x, P_y, P_z, Y, T)$ ทั้งนี้เนื่องจากค่าตัวแปรในทางเศรษฐศาสตร์เป็นค่าสังเกตที่มีใช้เกิดจากการทดลองจึงไม่สามารถควบคุมได้ การศึกษาต้องศึกษาทั้งกลุ่ม ดังนั้น จึงต้องการเทคนิคการวิเคราะห์แบบ Multiple Regression

ตัวแบบเส้นถดถอยเชิงซ้อน (Multiple Regression Model)

ตัวแบบทั่วไปเกี่ยวกับประชากร : $\mu = \alpha + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + u_i$

ตัวแบบที่ใช้ในตัวอย่าง : $Y = a + b_1 X_{1i} + b_2 X_{2i} + \dots + b_k X_{ki} + e_i (i = 1, 2, \dots, n)$

u_i เป็นตัวแปรอิสระสุ่มซึ่ง u มี mean = 0 และ Variance =

σ_u^2 , X อาจจะเป็นค่ากำหนดให้ที่ไม่สุ่ม (nonrandom) หรือไม่ก็เป็นตัวแปรสุ่ม


(random) ซึ่งมีการแจกแจงของ u เป็นอิสระ ข้อสมมุติของเส้นถดถอยเชิงซ้อนก็เหมือนกับ

ข้อสมมุติของเส้นถดถอยอย่างง่ายนอกจากแทนที่จะมีตัวแปรอิสระหรือตัวแปรภายนอกเพียงตัวเดียวเท่านั้น

ก็มีตัวแปรอิสระถึง k ตัว

สมมติความสัมพันธ์ของตัวแปร 3 ตัว ถ้านำมาเขียนกราฟ 3 มิติจะได้

ดังรูปที่ 3.1



รูปที่ 3.1 ภาพกระจายของค่าสังเกตบนพื้นระนาบ regression ที่แท้จริง

ตัวประมาณค่า a, b, c โดยวิธีกำลังสองน้อยที่สุด

เพื่อที่จะหาตัวประมาณค่าของพารามิเตอร์ในสมการถดถอยเชิงซ้อน โดยวิธีกำลังสองน้อยที่สุด สมมุติว่าพิจารณาจากสมการถดถอย 3 ตัวแปร คือ ตัวแปรภายใน Y ขึ้นอยู่กับตัวแปรภายนอก X, Z อย่างเป็นเส้นตรง

$$Y_i = a + bX_i + cZ_i + e_i \quad (i = 1, 2, \dots, n)$$

e_i เป็นส่วนคลาดเคลื่อนที่เหลือ (residual error) หรือความเบี่ยงเบนของค่าที่ประมาณได้ \hat{Y} จากค่า Y ที่แท้จริง

โดยวิธีกำลังสองน้อยที่สุด ค่า a, b, c สามารถหาได้จาก

normal equation ที่เกิดจากการ minimize $\sum e_i^2$ ดังนี้

$$\phi = \sum_1^n e_i^2 = \sum_1^n (Y_i - a - bX_i - cZ_i)^2$$

ใช้แคลคูลัส โดย differentiate ϕ มุ่งต่อ a, b, c และตั้ง derivative แต่ละอันเท่ากับ 0 จะได้สมการ 3 สมการ ซึ่งเรียกว่า normal equation

$$\sum_1^n (Y_i - a - bX_i - cZ_i) = 0$$

$$\sum_1^n (Y_i - a - bX_i - cZ_i) X_i = 0$$

$$\sum_1^n (Y_i - a - bX_i - cZ_i) Z_i = 0$$

เพราะว่า $Y_i - a - bX_i - cZ_i = e_i$ ดังนั้นสมการข้างบนจะเขียนได้เป็น

$$\sum_1^n e_i = 0, \quad \sum_1^n e_i X_i = 0, \quad \sum_1^n e_i Z_i = 0$$

เพื่อหาค่า a, b, c ในเทอมของ Y_i, X_i และ Z_i เราจึงเขียนสมการ normal equation เสียใหม่ดังนี้

$$an + b\sum_1^n X_i + c\sum_1^n Z_i = \sum_1^n Y_i \quad (1)$$

$$a\sum_1^n X_i + b\sum_1^n X_i^2 + c\sum_1^n X_i Z_i = \sum_1^n Y_i X_i \quad (2)$$

$$a\sum_1^n Z_i + b\sum_1^n X_i Z_i + c\sum_1^n Z_i^2 = \sum_1^n Y_i Z_i \quad (3)$$

สมการ (1) จะให้เราทราบว่าพื้นระนาบ $Y = a + bX + cZ$ ซึ่งตัดกับข้อมูลที่ที่สุด ต้องผ่านจุด $\bar{Y}, \bar{X}, \bar{Z}$ จะเห็นได้จากเอา n ทารสมการ (1) ตลอด จะได้ :-

$$a + b\bar{X} + c\bar{Z} = \bar{Y} \quad (1')$$

$$* \text{ สูตร } a = \bar{Y} - b\bar{X} - c\bar{Z}$$

เราสามารถจะหา b และ c โดยขจัด a จากสมการ (2) และ (3) ซึ่งทำได้โดยคูณสมการ (1) ด้วย \bar{X} แล้วนำไปหักจากสมการ (2), คูณสมการ (2) ด้วย \bar{Z} แล้วนำไปหักออกจาก (3)

$$\text{เพราะว่า } \sum_1^n X_i - n\bar{X} = 0 \quad \sum_1^n Z_i - n\bar{Z} = 0 \text{ จะได้ :-}$$

$$b(\sum_1^n X_i^2 - \bar{X}\sum_1^n X_i) + c(\sum_1^n X_i Z_i - \bar{X}\sum_1^n Z_i) = \sum_1^n Y_i X_i - \bar{X}\sum_1^n Y_i$$

และ

$$b(\sum_1^n X_i Z_i - \bar{Z}\sum_1^n X_i) + c(\sum_1^n Z_i^2 - \bar{Z}\sum_1^n Z_i) = \sum_1^n Y_i Z_i - \bar{Z}\sum_1^n Y_i$$

เพราะว่า

$$\sum_1^n X_i^2 - \bar{X} \sum_1^n X_i = \sum_1^n (X_i - \bar{X})^2,$$

$$\sum_1^n X_i Z_i - \bar{X} \sum_1^n Z_i = \sum_1^n (X_i - \bar{X})(Z_i - \bar{Z}), \quad \text{เป็นต้น}$$

สมการข้างต้นนี้จะเท่ากับสมการข้างล่างคือ

$$b \sum_1^n (X_i - \bar{X})^2 + c \sum_1^n (X_i - \bar{X})(Z_i - \bar{Z}) = \sum_1^n (X_i - \bar{X})(Y_i - \bar{Y}), \quad (2')$$

$$d \sum_1^n (X_i - \bar{X})(Z_i - \bar{Z}) + c \sum_1^n (Z_i - \bar{Z})^2 = \sum_1^n (Z_i - \bar{Z})(Y_i - \bar{Y}) \quad (3')$$

จากสมการ (2') และ (3') จะได้อ่า b และ c และเพื่อให้จำง่าย ให้

$$x_i = X_i - \bar{X} \quad z_i = Z_i - \bar{Z} \quad \text{และ} \quad y_i = Y_i - \bar{Y}$$

แล้ว $\sum_1^n (X_i - \bar{X})^2 = \sum_1^n x_i^2$, $\sum_1^n (X_i - \bar{X})(Z_i - \bar{Z}) = \sum_1^n x_i z_i$ เป็นต้น

ค่า b และ c ในเทอมของ x_i , y_i และ z_i จะเป็นดังนี้

$$\begin{aligned} * \text{ สูตร } \hat{b} &= \frac{\sum z_i^2 \sum y_i x_i - \sum x_i z_i \sum y_i z_i}{\sum x_i^2 \sum z_i^2 - (\sum x_i z_i)^2} \\ \hat{c} &= \frac{\sum x_i^2 \sum y_i z_i - \sum x_i z_i \sum y_i x_i}{\sum x_i^2 \sum z_i^2 - (\sum x_i z_i)^2} \end{aligned}$$

ตัวประมาณค่า a , b และ c โดยวิธีกำลังสองน้อยที่สุดนี้สามารถคำนวณด้วยมือได้ แต่แต่ละตัวในสมการ b และ c จะหาได้โดยตรงหรือจะหาตามวิธีข้างล่าง ซึ่งจะรวดเร็วกว่าก็ได้ แล้วไปแทนค่าในสมการ b และ c เราจะได้ค่าประมาณของ b และ c

$$\begin{aligned}\sum x^2 &= \sum X^2 - \frac{(\sum X)^2}{n} \\ \sum z^2 &= \sum Z^2 - \frac{(\sum Z)^2}{n} \\ \sum yx &= \sum XY - \frac{(\sum X)(\sum Y)}{n} \\ \sum yz &= \sum YZ - \frac{(\sum Y)(\sum Z)}{n} \\ \sum xz &= \sum XZ - \frac{(\sum X)(\sum Z)}{n}\end{aligned}$$

เมื่อได้ค่า a , b และ c แล้ว นำไปแทนในสมการถดถอย เราจะได้สมการถดถอยเชิงซ้อนที่มีความหมายและอธิบายได้ดังนี้

ตัวอย่างที่ 3.1

สมมติคำนวณสมการถดถอยเชิงซ้อนของการเสนอซื้อส้มขึ้นอยู่กับราคาส้มและรายได้ของผู้บริโภค คือ

$$Y = 15 - 2X + Z$$

โดย Y เป็นการเสนอซื้อส้ม (ก.ก.) X เป็นราคาส้ม (10 บาท/ก.ก.) Z เป็นรายได้ของผู้บริโภค (100 บาท) สมการนี้สามารถใช้พยากรณ์การเสนอซื้อส้มได้ ถ้ารู้ราคาส้ม (X) และรายได้ของผู้ซื้อ (Z) โดยแทนค่า X และ Z ลงในสมการ

ค่า a , b และ c สามารถที่จะอธิบายได้ดังนี้

a เรียกว่า ตัวคงที่ (Constant) หมายถึง เมื่อราคาส้มและรายได้ของผู้บริโภคเป็น 0 การเสนอซื้อส้มจะเท่ากับ 15 กิโลกรัม (ค่า a ไม่ใคร่มีความสำคัญ บางครั้งใช้ไม่ได้)

b เรียกว่า สัมประสิทธิ์ถดถอย หรือสัมประสิทธิ์ถดถอยบางส่วน (Partial Regression Coefficient) หมายถึง แต่ละการเพิ่มในราคาส้ม 1 หน่วยหรือ 10 บาทต่อ ก.ก. เป็นผลให้การเสนอซื้อส้มลดลง 2 กิโลกรัม โดยให้รายได้ของผู้ซื้อคงที่

c เรียกเช่นเดียวกับค่า b , c หมายถึง แต่ละการเพิ่มในรายได้ 1 หน่วยหรือ 100 บาทเป็นผลให้การเสนอซื้อเพิ่มขึ้น 1 กิโลกรัม โดยให้ราคาส้มอยู่คงที่

ค่าสถิติของสมการถดถอยเชิงซ้อน

1. ความคลาดเคลื่อนมาตรฐานของการกะประมาณ (Standard Error of Estimate : SEE, $S_{y.12}$)

จากบทที่ 2 เราเห็นว่า ถ้าการกระจายของข้อมูลห่างจากเส้นถดถอยน้อย (อยู่ใกล้เส้นถดถอย) ความคลาดเคลื่อนของการพยากรณ์ก็น้อย ความคลาดเคลื่อนหรือความแปรปรวนใน Y จะแสดงออกในรูป Standard Error of Estimate สำหรับค่า Y ในสมการถดถอยเชิงซ้อนเช่นเดียวกัน ความคลาดเคลื่อนของการ กะประมาณสำหรับค่าของ Y บนพื้นราบถดถอย อธิบายได้ดังนี้

$$SEE \text{ หรือ } S_{y.12} = \sqrt{\frac{\sum (Y_i - \hat{Y}_i)^2}{n-3}} = \sqrt{\frac{\sum e_i^2}{n-2}}$$

อาจจะใช้สูตรที่เป็นค่าเบี่ยงเบนจาก means (อักษรตัวเล็ก)

$$SEE = \sqrt{\frac{\sum y^2 - b \sum xy - c \sum yz}{n-3}}$$

หรืออีกสูตรหนึ่ง

$$SEE = \sqrt{\frac{\sum y^2 - \sum (bx + cz)^2}{n-3}}$$

ถ้าหากใช้เครื่องคำนวณ สูตรข้างล่างจะนิยมใช้มากกว่า เพราะสูตรนี้ไม่ต้องใช้ทั้งค่า \hat{Y} และค่าเบี่ยงเบนจาก means ซึ่งค่อนข้างล่าช้าสำหรับ ค่าสังเกต (n) จำนวนมาก

$$SEE = \sqrt{\frac{\sum Y^2 - a \sum Y - b \sum XY - c \sum YZ}{n-3}}$$

2. สัมประสิทธิ์การตัดสินใจ (Multiple Coefficient of Determination : R^2)

R^2 ของสมการถดถอยเชิงซ้อนมีความหมายเช่นเดียวกับของสมการถดถอยอย่างง่าย คือ การวัดอัตราส่วนของความแปรปรวนของตัวแปรตามที่ถูกอธิบายโดยสมการถดถอย ถ้าอธิบายในเชิงรูปภาพเรขาคณิต (รูปที่ 3.1) R^2 ของสมการถดถอยเชิงซ้อน คือ การวัดว่า พื้นี่ราบซึ่งแทนสมการถดถอยมีความเหมาะสม (fit) กับจุดต่าง ๆ ของข้อมูล (ค่าสังเกต) บนพื้นราบได้ดีเพียงไร สูตรของ R^2 คือ

$$\begin{aligned} R^2 &= \frac{\text{ความแปรปรวนที่อธิบายได้}}{\text{ความแปรปรวนทั้งหมด}} \\ &= \frac{\sum (\hat{Y}_i - \bar{Y})^2}{\sum (Y_i - \bar{Y})^2} \\ R^2 &= 1 - \frac{\sum e_i^2}{\sum (Y_i - \bar{Y})^2} \end{aligned}$$

อาจจะใช้สูตรที่เป็นค่าเบี่ยงเบนจาก means

$$R^2 = \frac{b \sum xy + c \sum yz}{\sum y^2}$$

$$R^2 = \frac{\sum (bx + cz)^2}{\sum y^2}$$

ถ้ามีตัวแปรอิสระมากกว่า 2 ตัวขึ้นไป การคำนวณสมการถดถอยเชิงซ้อนส่วนใหญ่จะใช้โปรแกรมสำเร็จรูปทางคอมพิวเตอร์

ตัวอย่างที่ 3.2

จากตัวอย่างสมการถดถอยของการเสนอซื้ออสังหาริมทรัพย์ขึ้นอยู่กับการราคาอสังหาริมทรัพย์และรายได้ของผู้บริโภค สมมติคำนวณได้ $R^2 = 0.92$ มีความหมายว่า ประมาณ 92 เปอร์เซ็นต์ของความแปรปรวนในการเสนอซื้ออสังหาริมทรัพย์โดยสมการถดถอยอีก 8 เปอร์เซ็นต์ (100-92%) ของความแปรปรวนของการเสนอซื้ออสังหาริมทรัพย์มาจากสาเหตุอื่นหรือตัวแปรอื่นที่ไม่ได้นำเข้ามาในสมการ นั่นคือ ราคาอสังหาริมทรัพย์และรายได้ของผู้ซื้อที่มีอิทธิพลต่อการเสนอซื้ออสังหาริมทรัพย์ 92 เปอร์เซ็นต์ (ค่า R^2 ของสมการถดถอยที่มีตัวแปรอิสระมากกว่า 1 ตัวจะสูงกว่าสมการที่มีตัวแปรอิสระเพียงตัวเดียว แสดงว่าในความเป็นจริงตัวแปรมีความสัมพันธ์กันมากกว่า 1 ตัว)

สัมประสิทธิ์การตัดสินใจปรับปรุง (\bar{R}^2)

ในสมการถดถอยเชิงซ้อน ตัวแปรอิสระจะมีมากกว่าในสมการถดถอยอย่างง่าย ถ้ายังตัวแปรอิสระเพิ่มมากขึ้นเท่าไร R^2 ยังมีค่าสูงขึ้น หรือ " ใกล้เคียง 1 " เข้าไปเท่านั้น เพราะว่าค่า $b \sum xy + c \sum yz$ ซึ่งเป็น "ความแปรปรวนที่อธิบายได้" ค่าจะเพิ่มขึ้นตามตัวแปรอิสระที่เพิ่มขึ้นแต่ $\sum y^2$ ซึ่งเป็น "ความแปรปรวนทั้งหมด" เป็นตัวหารยังมีค่าคงเดิม ($R^2 = \frac{b_1 \sum x_1 y + b_2 \sum x_2 y + \dots + b_k \sum x_k y}{\sum y^2}$) การที่ R^2 มี ค่าใกล้ 1 ไม่แสดงว่าเส้นถดถอยที่คำนวณได้

พิดกับข้อมูลที่สุด การแก้จะต้องปรับ R^2 เสียใหม่ด้วย degree of freedom ของสมการถดถอยเชิงซ้อน คือ

$$\bar{R}^2 = 1 - \frac{\sum e_i^2}{\sum y^2} \frac{(n-1)}{(n-k-1)}$$

อย่างไรก็ดี ถ้าหากว่าจำนวนค่าสังเกต (n) ที่ใช้น้อย การสร้างสมการต้องไม่ให้มีตัวแปรอิสระมากเกินไป หรืออาจจะเพิ่ม n ให้มากขึ้น แต่ก็ควรคำนวณ \bar{R}^2 อีกครั้ง เพื่อความแน่ใจในค่า R^2

4. ความคลาดเคลื่อนมาตรฐานของ a, b และ c

เนื่องจากค่าประมาณต่างๆเป็นค่าสถิติจากตัวอย่างซึ่งมักจะมีมีความคลาดเคลื่อนอันเนื่องมาจากการสุ่มตัวอย่าง (sampling error) ดังนั้นนอกจากจะคำนวณตัวประมาณค่า a, b, c แล้วเราควรต้องหาความคลาดเคลื่อนมาตรฐานของตัวประมาณค่าเหล่านี้คือ

$$S_a = \sqrt{S_a^2} = \sqrt{\frac{S^2 \sum X^2 \sum Z^2 - (\sum XZ)^2}{n[\sum x^2 \sum z^2 - (\sum xz)^2]}}$$

$$S_b = \sqrt{S_b^2} = \sqrt{\frac{S^2 \sum z^2}{\sum x^2 \sum z^2 - (\sum xz)^2}}$$

$$S_c = \sqrt{S_c^2} = \sqrt{\frac{S^2 \sum x^2}{\sum x^2 \sum z^2 - (\sum xz)^2}}$$

ช่วงความเชื่อมั่นของการประมาณค่า α และ β_1

วัตถุประสงค์ของการวิเคราะห์ถดถอยเชิงซ้อนอย่างหนึ่งคือต้องการทราบช่วงความเชื่อมั่นของสัมประสิทธิ์ถดถอยที่แท้จริง (true regression coefficient: β_1) เพราะ β_1 เป็นตัวที่วัดผลกระทบของ X_1 ที่เพิ่มขึ้น 1 หน่วยต่อค่า Y เมื่อ X_2 อยู่คงที่ และ β_2 วัดผลกระทบของ X_2 ที่เพิ่มขึ้น 1 หน่วยต่อค่า Y เมื่อ X_1 อยู่คงที่ เมื่อเราทราบความคลาดเคลื่อนมาตรฐานของสัมประสิทธิ์ถดถอยจากตัวอย่าง S_a, S_b, S_c ถ้าเราตั้งความเชื่อมั่นอยู่ที่ 100 (1 - α) เปอร์เซ็นต์ ช่วงความเชื่อมั่นของค่าคงที่ (α) และสัมประสิทธิ์ถดถอยที่แท้จริงจะหาได้ดังนี้

$$\text{ช่วงความเชื่อมั่นของค่าคงที่ที่แท้จริง} \quad \alpha = a \pm t_{\alpha/2} S_a \quad \text{ที่ d.f. } n-k-1$$

$$\text{ช่วงความเชื่อมั่นของสัมประสิทธิ์ถดถอยที่แท้จริง} \quad \beta_1 = b_1 \pm t_{\alpha/2} S_{b1} \quad \text{ที่ d.f. } n-k-1$$

$$\text{ช่วงความเชื่อมั่นของสัมประสิทธิ์ถดถอยที่แท้จริง} \quad \beta_2 = b_2 \pm t_{\alpha/2} S_{b2}$$

$$\text{ช่วงความเชื่อมั่นของสัมประสิทธิ์ถดถอยที่แท้จริง} \quad \beta_k = b_k \pm t_{\alpha/2} S_{bk}$$

5. ค่าสถิติ t และการทดสอบ (t - test)

การทดสอบสัมประสิทธิ์ถดถอยทีละตัวจะใช้ทดสอบด้วย t ถ้าเราตั้งสมมติฐานให้เป็น 0 สูตรทดสอบคือ :

$$t_a = \frac{a}{S_a}, \quad t_b = \frac{b}{S_b}, \quad t_c = \frac{c}{S_c} \quad \boxed{\text{เขตวิกฤติ ถ้า } t > t_{\alpha/2, n-k-1} \text{ และ } -t < -t_{\alpha/2, n-k-1}}$$

ตัวอย่างที่ 3.3

ให้ Y เป็นต้นทุนการผลิต (หมื่นบาท) X_1 เป็นผลผลิต (ตัน) X_2 เป็นประสิทธิภาพของผู้จัดการ (ปี) คอมพิวเตอร์ได้พิมพ์ผลของการวิเคราะห์ถดถอยจากตัวอย่าง 9 ตัวอย่างออกมาดังนี้

$$Y = 1.324 + 0.779X_1 + 0.167X_2$$

Predictor	Coef.	Stdev.	t - ratio
Constant	1.3236	0.1432	9.2430
X_1	0.7792	0.0335	23.2043
X_2	- 0.16692	0.0322	- 5.1839

ให้ใช้ผลเหล่านี้คำนวณช่วงความเชื่อมั่น 95 เปอร์เซ็นต์ของ β_1 และทดสอบสมมติฐานว่า
 $H_0 : \beta_2 = 0$, $H_a : \beta_2 \neq 0$ ณ ระดับนัยสำคัญ .05

วิธีทำ

$$\begin{aligned} \beta_1 &= b_1 \pm t_{\alpha/2, n-k-1} S_{b_1} \\ &= 0.7792 \pm t_{.05/2, 9-2-1} (.034) \\ &= 0.7792 \pm 2.447(.034) \\ &= 0.7792 \pm 0.0832 \\ &= \{ 0.6960, 0.8624 \} \end{aligned}$$

ตีความ: เมื่อผลผลิต (X_1) เพิ่มขึ้น 1 ตัน ต้นทุนการผลิต (Y) จะเพิ่มขึ้นอยู่ในช่วงระหว่าง 6,960 บาท ถึง 8,634 บาท ด้วยความเชื่อมั่น 95 เปอร์เซ็นต์

การทดสอบ (สรุปผลจากค่า t ratio ได้เลย แต่ข้างล่างแสดงการหาค่า t ให้ดู)

$H_0 : \beta_2 = 0$ (ประสิทธิภาพของผู้จัดการอธิบายความผันแปรในต้นทุนการผลิตไม่ได้)

$H_a : \beta_2 \neq 0$

$$\begin{aligned} \text{สูตร } t_{b_2} &= \frac{b_2}{S_{b_2}} \\ &= \frac{-0.16692}{0.0322} \\ &= -5.1839 \end{aligned}$$

สรุปผล: ค่าสถิติ t (-5.1839) < $-t_{.025}$ (-2.447) เราปฏิเสธสมมติฐานที่ว่า $\beta_2 = 0$ เรียกว่า β_2 มีนัยสำคัญทางสถิติ ประสิทธิภาพของผู้จัดการอธิบายความผันแปรในต้นทุนการผลิตได้ หรืออาจกล่าวได้ว่า ต้นทุนการผลิตซึ่งเป็นผลจากผู้จัดการมีประสิทธิภาพเพิ่มขึ้น 1 ปีต่างไปจาก 0 อย่างมีนัยสำคัญ นั่นคือ ประสิทธิภาพของผู้จัดการมีผลทำให้ต้นทุนการผลิตลดลงจริง

การวิเคราะห์ความแปรปรวน (Analysis of Variance)

นักสถิติได้ใช้การวิเคราะห์ความแปรปรวนเพื่อทดสอบนัยสำคัญทางสถิติทั้งหมดของสมการถดถอย กล่าวคือ ใช้ทดสอบว่า สัมประสิทธิ์ถดถอยที่แท้จริงทุกตัวในสมการเป็น 0 หรือไม่ เช่นเดียวกับที่ใช้ในสมการ ถดถอยอย่างง่ายเพื่อทดสอบค่า β

ตั้งสมมติฐาน $H_0 : \beta_1 = \beta_2 = 0$
 $H_a : \beta_1 \neq \beta_2 \neq 0$

สูตร $F = \frac{\text{ความแปรปรวนที่อธิบายได้ด้วย Regression}}{\text{ความแปรปรวนที่อธิบายไม่ได้ด้วย Regression}}$
 $= \frac{S_1^2}{S_2^2}$

เขตวิกฤติ : $F > F_\alpha$ ที่ d.f. n และ n-k-1

ตารางที่ 3.1 การวิเคราะห์ความแปรปรวน

Source of variation	degree of freedom	Sum of squares	Mean square	F ratio
Explained by Regression	k	$\sum(\hat{Y}_i - \bar{Y})^2$	$\frac{\sum(Y_i - \bar{Y})^2}{k} = S_1^2$	$\frac{S_1^2}{S_2^2}$
Unexplained By regression	n - k - 1	$\sum(Y_i - \hat{Y}_i)^2$	$\frac{\sum(Y_i - \hat{Y}_i)^2}{n - k - 1} = S_2^2$	
Total	n-1	$\sum(Y_i - \bar{Y})^2$		

ตัวอย่าง ตาราง ANOVA ที่ใช้ความแปรปรวนอีกรูปหนึ่ง

ตารางที่ 3.2 การวิเคราะห์ความแปรปรวน

S V	d.f.	S S	MS	F ratio
EV	k	$b \sum xy + c \sum yz$ หรือ $\sum (bx + cz)^2$	$\frac{b \sum xy + c \sum yz}{k}$ $= S_1^2$	
UV	n-k-1	$\sum e^2$ หรือ $\sum y^2 - b \sum xy - c \sum yz$ หรือ $\sum y^2 - \sum (bx + cz)^2$	$\frac{\sum e^2}{n-k-1}$ $= S_2^2$	$\frac{S_1^2}{S_2^2}$
TV	n-1	$\sum y^2$		

การทดสอบว่าสัมประสิทธิ์ถดถอยทุกตัวจะเป็น 0 หรือไม่ ถ้าสัมประสิทธิ์ถดถอยทุกตัวเป็น 0 จริง อัตราส่วน $\frac{S_1^2}{S_2^2}$ จะมีการแจกแจงเป็นแบบ F ซึ่งมี d.f. = k และ n - k - 1 (ในตาราง F, d.f. = k อยู่แถวบน d.f. = n - k - 1 อยู่แถวตั้ง) แต่ถ้าสัมประสิทธิ์ถดถอยไม่เท่ากับ 0 แล้วอัตราส่วนนี้มีแนวโน้มที่จะให้ตัวเลขสูง (ค่า F สูง)

การสรุปผลว่า จะปฏิเสธหรือยอมรับสมมติฐานที่ค่าวิกฤติเช่นเดียวกับในสมการถดถอยอย่างง่าย

ตัวอย่างที่ 3.4 สมการถดถอยของต้นทุนการผลิตขึ้นอยู่กับผลผลิตและประสบการณ์ของผู้จัดการ ในตัวอย่างที่ 3.3 สมมติมีค่าคำนวณ $F = 50$ ให้ทดสอบสัมประสิทธิ์ถดถอยที่แท้จริงทุกตัวว่า = 0 ตั้ง $\alpha = .05$

วิธีทำ สมการถดถอยนี้มี $n = 9$, และ $k = 2$ จำนวน degree of freedom คือ 2 กับ 6 ($k=2$ และ $n-k-1=6$) $F_{.05} = 4.76$ (จากตาราง F หายเล่ม) เนื่องจาก F ที่คำนวณได้มากกว่า 4.76 เราปฏิเสธ H_0 ที่ว่าสัมประสิทธิ์แท้จริงทุกตัวเป็น 0 แสดงว่าผลผลิตและประสบการณ์ของผู้จัดการอธิบายความผันแปรในต้นทุนการผลิตได้ นั่นคือ ตัวแปรทั้ง 3 มีความสัมพันธ์กัน ผลผลิตและประสบการณ์ของผู้จัดการมีผลต่อต้นทุนการผลิต

ตัวอย่างที่ 3.5

จงสร้างสมการเส้นถดถอยของจำนวน demand ขึ้นอยู่กับราคาและรายได้

ตั้งข้อมูลข้างล่างนี้

Q_d	100	75	80	70	50	65	90	100	110	60
P	5	7	6	6	8	7	5	4	3	9
Y	1,000	600	1,200	500	300	400	1,300	1,000	1,300	300

วิธีทำ

1. ตัวแบบ $Q_d = a + bP + cY + z$

2. การคำนวณ

เพื่อความสะดวกในการคำนวณ เราใช้ตัวแบบทั่วไปก่อนคือ $Y = a + bX + cZ$

ตารางที่ 3.3

n	Y Quantity demanded	X Price	Z Income	$y - \bar{y}$	$(x_1 - \bar{x}_1)$	$(z - \bar{z})$	y^2	x^2	z^2	yx	yz	xz
1	100	5	1,000	20	-1	200	400	1	40,000	-20	4,000	-200
2	75	7	600	-5	1	-200	25	1	40,000	-3	000	-200
3	80	6	1,200	0	0	400	0	0	160,000	0	3,000	0
4	70	6	500	-10	0	-300	100	0	90,000	0	15,000	0
5	50	8	300	-30	2	-500	900	4	250,000	-60	6,000	-1,000
6	65	7	400	-15	1	-400	225	1	160,000	-15	6,000	-400
7	90	5	1,300	10	-1	500	100	1	250,000	-10	5,000	-500
8	100	4	1,100	20	-2	300	400	4	00,000	-40	6,000	-400
9	110	3	1,300	30	-3	500	900	9	250,000	-90	15,000	-1,500
10	60	9	300	-20	3	500	400	9	250,000	-60	10,000	-1,500
n = 10	$\Sigma Y = 800$	$\Sigma X = 60$	8,000				3,650	30	1,580,000	-300	65,000	-5,900

$\bar{y} = 80, \bar{x} = 6, \bar{z} = 800.$

$$\begin{aligned}
 \hat{b} &= \frac{\Sigma z^2 \Sigma xy - \Sigma xz \Sigma yz}{\Sigma x^2 \Sigma z^2 - (\Sigma xz)^2} \\
 &= \frac{(1,580,000)(-300) - (-5,900)(65,000)}{(30)(1,580,000) - (-5,900)^2} \\
 &= \frac{-90,500}{12,590} \\
 &= -7.1882 \\
 \hat{c} &= \frac{\Sigma x^2 \Sigma yz - \Sigma xz \Sigma xy}{\Sigma x^2 \Sigma z^2 - (\Sigma xz)^2} \\
 &= \frac{(30)(65,000) - (-5,900)(-300)}{(30)(1,580,000) - (-5,900)^2} \\
 &= \frac{180}{12,590} \\
 &= 0.0143 \\
 \hat{a} &= \bar{Y} - \hat{b}\bar{X} - \hat{c}\bar{Z} \\
 &= 80 - (-7.19)(6) - (0.0143)(800) \\
 &= 111.69
 \end{aligned}$$

3. สมการ regression

$$Y = 111.69 - 7.19x + 0.0143z$$

4. สมการ demand

$$Q_d = 11.69 - 7.19 P + 0.0143 Y$$

ค่าสถิติที่จำเป็น :-

$$\begin{aligned} 1. \quad R^2 &= \frac{b \sum cxy + c \sum yz}{\sum y^2} \\ &= \frac{(-7.19)(-300) + (0.0143)(65,000)}{3,450} \\ &= 0.894 \end{aligned}$$

หรือจะใช้อีกสูตรหนึ่งคือ

$$\begin{aligned} R^2 &= 1 - \frac{\sum e^2}{y^2} \\ \sum e^2 &= y^2 - b \sum cxy - c \sum yz \\ &= 3,450 - (-7.19)(-300) - (0.0143)(65,000) \\ &= 363.5 \\ R^2 &= 1 - \frac{363.5}{3,450} \\ &= 0.894 \end{aligned}$$

$$2. \quad \bar{R}^2$$

$$\begin{aligned} \bar{R}^2 &= 1 - \frac{(n-1) \cdot e^2}{(n-k-1) y^2} \\ &= 1 - \frac{(10-1) \cdot 363.5}{(10-2-1) \cdot 3,450} = 1 - \frac{3,271.5}{24,150} \\ &= 0.86 \end{aligned}$$

$$\begin{aligned} 3. \quad \text{SEE} &= \sqrt{s^2} = \sqrt{\frac{\Sigma e^2}{n-3}} \\ &= \sqrt{\frac{363.5}{10-3}} = \sqrt{51.93} \\ &= 7.21 \end{aligned}$$

$$\begin{aligned} 4. \quad s_a &= \sqrt{\frac{s^2 \Sigma X^2 \Sigma Z^2 - (\Sigma XZ)^2}{n[\Sigma X^2 \Sigma Z^2 - (\Sigma XZ)^2]}} \\ &= \sqrt{553.69} \\ &= 23.5 \end{aligned}$$

สูตรนี้จะต้องตีช่องเพิ่มสำหรับ X^2 , Z^2 และ XZ แล้วหา Σ ของมัน
สำหรับ XZ จะต้องนำ ΣXZ ไปยกกำลังสอง

$$\begin{aligned}
 \hat{s}_b &= \sqrt{\frac{s^2 \Sigma z^2}{\Sigma x^2 \Sigma z^2 - (\Sigma xz)^2}} \\
 &= \sqrt{\frac{(51.93)(1,580,000)}{(30)(1,580,000) - (-5,900)^2}} \\
 &= \sqrt{\frac{820,494}{34,814,740}} = 2.25
 \end{aligned}$$

$$\begin{aligned}
 \hat{s}_c &= \sqrt{s_c^2} \\
 &= \sqrt{\frac{s^2 \Sigma x^2}{\Sigma x^2 \Sigma z^2 - (\Sigma xz)^2}} \\
 &= \sqrt{\frac{(51.93)(30)}{(30)(1,580,000) - (-5,900)^2}} \\
 &= \sqrt{\frac{1,557.9}{34,814,740}} = 0.01
 \end{aligned}$$

5. ค่าสถิติ t

$$\begin{aligned}
 t_a &= \frac{\hat{a}}{\hat{s}_a} \\
 &= \frac{111.69}{23.5} = 4.75
 \end{aligned}$$

$$t_b = \frac{\hat{b}}{\hat{S}_b}$$

$$= \frac{-7.19}{2.25} = -2.8$$

$$t_c = \frac{\hat{c}}{\hat{S}_c}$$

$$= \frac{0.014}{0.01} = 1.28$$

หมายเหตุ :

ค่า t ให้ทดสอบสมมติฐานที่ระดับนัยสำคัญในตัว ในสมการเชิงซ้อน โดยมีสมมติฐานว่า $\alpha_1=0$ $\beta_1=0$ และ $\alpha_2=0$ $\beta_2=0$

6. ค่าสถิติ F

ตารางที่ 3 4 ANOVA Table

Source of Variation	d.f	S.S	M.S	F
Explained (by Regression)	$k = 2$	$\Sigma y^2 - \Sigma e^2$ $= 3450 - 363.5$ $= 3086.5$	$S_1^2 = \Sigma y^2 - \Sigma e^2 / 2$ $= 3,086 / 2$ $= 1,543$	$\frac{S_1^2}{S_2^2} = \frac{1,543}{51.93}$
Unexplained (error)	$n - k - 1$ $= 10 - 2 - 1 = 7$	Σe^2 $= 363.5$	$S_2^2 = \Sigma e^2 / n - k - 1$ $= 363.5 / 7$ $= 51.93$	$= 29.71$
Total Variation	$n - 1$ $10 - 1 = 9$	$\Sigma y^2 = 3,450$		

(มีนัยสำคัญ ระดับความเชื่อมั่น 99%)

หมายเหตุ:

ค่าสถิติ F ใช้ทดสอบ

1. สมประสิทธิผลันถดถอย ซึ่งมีสมมุติฐาน $\hat{b} = \hat{c} = 0$ ใช้สูตรดังในตาราง 3.3

2. ใช้ทดสอบ \bar{R}^2 ซึ่งมีสมมุติฐาน $R^2 = 0$ สูตร F คือ

$$F = \frac{R^2/2}{(1-R^2)/(n-3)}$$

แล้วนำค่าที่คำนวณได้ (ปกติค่า F ในสูตรข้อ 2 จะเท่ากับค่า F ในข้อ 1)

ไปเปรียบเทียบกับตาราง F ถ้ามากกว่า ก็สรุปว่า มีนัยสำคัญ (ปฏิเสธ $R^2 = 0$)

F-ratio ที่คำนวณได้ ถ้ามีค่าที่สูงมาก (ปฏิเสธ $R^2 = 0$) ทำให้เราแน่ใจ

ยิ่งขึ้นว่า ตัวแปร X และ Z มีความสัมพันธ์กับ Y แน่นนอน

จะได้สมการเส้น demand คือ

$$Q^d = a + bP + cY$$

$$= 111.69 - 7.19 P + 0.0143 Y \quad \frac{1/}{}$$

$$(23.5) \quad (2.25) \quad (0.01)$$

$$t \quad 4.75 \quad -2.8 \quad 1.28$$

$$R^2 = 0.874, \quad \bar{R}^2 = 0.864$$

$$SEE = 7.21$$

$$F = 29.71$$

$\frac{1/}{}$ จากสมการนี้ ความยืดหยุ่นของราคาและความยืดหยุ่นของรายได้จะหาได้โดย :


$$e_p = \frac{\partial Q \cdot P}{\partial P \cdot Q} = b \cdot \frac{\bar{P}}{\bar{Q}} = (-7.19) \frac{6}{80} = -0.60$$

$$\text{และ } e_y = \frac{\partial Q \cdot Y}{\partial Y \cdot Q} = c \cdot \frac{\bar{Y}}{\bar{Q}} = (0.0143) \frac{800}{80} = 0.14$$

ปัญหาในการวิเคราะห์เส้นถดถอย

1. ปัญหา Multicollinearity

1.1 ใน Simple Regression เรียกว่า ปัญหา Collinearity เกิดขึ้นเมื่อค่าสังเกตของตัวแปรอิสระ (X) อยู่ใกล้กันมากเกินไปหรืออยู่เป็นกระจุก มีการกระจายน้อยมาก ค่า X ทุกค่าจึงอยู่ใกล้กับ \bar{X} มาก (ดังรูปที่ 3.2) ทำให้ $(X - \bar{X}) = 0$



รูปที่ 3.2 เส้น regression ที่เกิดจากไม่มีการกระจายใน X เมื่อเป็นเช่นนี้ เราไม่สามารถคำนวณค่า b ได้เพราะ

$$\hat{b} = \frac{\sum xy}{\sum x^2}$$

$$\text{แต่ } x = (X - \bar{X}) = 0$$

$$\sum xy = 0, \quad \sum x^2 = 0$$

$$\hat{b} = 0$$

ดังนั้น เราไม่สามารถจะอธิบาย Y ได้ การที่ X ไม่มีกระจายหรือมีน้อย ทำให้เกิด เส้นถดถอยได้หลายเส้น แต่ละเส้นมีความลาดชันต่างกันแต่มีความสำคัญพอกัน เพราะ การพยากรณ์ Y ของแต่ละเส้นทำได้จำกัดด้วยค่า X ค่าเดียวกัน เส้น regression ทุกเส้นจึงพยากรณ์ค่า Y ได้ดีเท่าๆกันและให้ผลเหมือนกัน คือ $\hat{Y} = a + 0 = \frac{\sum Y}{n} = \bar{Y}$ จึงถือว่า X ไม่มีอิทธิพลต่อ Y

1.2 ใน Multiple Regression จะเกิดปัญหา Multicollinearity ซึ่งคือการที่ตัวแปรอิสระในสมการ Multiple Regression มีความสัมพันธ์ซึ่งกันและกัน เป็นเส้นตรง เช่น สมการ $Y = a + bX + cZ$ Multicollinearity เกิดขึ้นเมื่อ X และ Z มีความสัมพันธ์กัน (เช่น $X = 1.5Z$ ซึ่งปกติเราจะไม่ทราบความสัมพันธ์ที่แน่นอน เช่นนี้) R. Frish เป็นคนแรกที่เรียกความสัมพันธ์เส้นตรงระหว่างตัวแปรอิสระ 2 ตัวหรือมากกว่า 2 ตัวนี้ว่า Multicollinearity

เมื่อมี Multicollinearity เกิดขึ้น สัมประสิทธิ์ที่อยู่หน้าตัวแปรอิสระ (b, c, \dots) นั้น ๆ จะอธิบายอะไรไม่ได้เลย สัมประสิทธิ์อาจจะใหญ่มากเกินไป จนไม่มีความสำคัญหรืออาจจะเท่ากับ 0

การที่เราจะทราบว่า มี Multicollinearity หรือไม่ ดูจาก Standard Error ของสัมประสิทธิ์ ($\hat{S}_a, \hat{S}_b, \dots$) ถ้าค่าของ Standard Error สูง ตัวแปรอิสระนั้นก็อาจจะมี Multicollinearity แต่วิธีนี้ก็ไม่น่าเชื่อถือไป วิธีดูอีกวิธีหนึ่งคือ ใช้การวิเคราะห์อิทธิพลร่วม (Confluence - analysis) โดยการคำนวณ Simple Regression ของ Y ต่อตัวแปรอิสระที่สงสัยว่าจะมี Multicollinearity แล้วคำนวณ Multiple Regression ของ Y โดยนำเอาตัวแปรอิสระเข้ามาในสมการทีละตัว เช่น กรณี $Y = a + bX + cZ$ เราสงสัยว่า X และ Z จะมีความสัมพันธ์กัน เราก็คำนวณหา Simple Regression ของ Y on X , ($\hat{Y} = \hat{a} + \hat{b}X$), Y on Z ($\hat{Y} = \hat{a} + \hat{c}Z$) แล้ว Y on X on Z ($\hat{Y} = \hat{a} + \hat{b}X + \hat{c}Z$)

และแต่ละสมการจะให้ค่า \hat{b} , \hat{c} , R^2 ทั้งหมดจะได้ค่า \hat{b} และ \hat{c} อย่างละ 2 ค่า R^2 ได้ 3 ค่า แล้วมาดูว่าค่าที่ได้นี้เป็นอย่างไร ถ้า R^2 ได้เท่ากันหรือใกล้เคียงกัน โดยมีได้สูงขึ้น (ปกติถ้าเพิ่มตัวแปรอิสระเข้าไป R^2 จะค่อย ๆ สูงขึ้น) และค่า b , c แต่ละสมการต่างกัน โดยเปลี่ยนแปลงไปแทนที่จะค่อนข้างคงที่ แสดงว่ามี Multicollinearity

ทางแก้ปัญหา Multicollinearity ก็คือ ควรเก็บตัวอย่างข้อมูลให้ขนาดใหญ่ขึ้น พยายามเลือกตัวแปรอิสระที่มีความหมายพอและไม่แสดงความสัมพันธ์ระหว่างกันอย่างเห็นชัด โดยใช้เหตุผลและผลทางทฤษฎีเศรษฐศาสตร์ช่วย

2. การใช้ Dummy Variables

ตัวแปรที่เราเกี่ยวข้องในการวิเคราะห์เส้นถดถอยมาตั้งแต่ต้นล้วนเป็นตัวแปรที่วัดได้ เช่น ปริมาณซื้อ (Q_d) ราคา (P) รายได้ (Y) และการบริโภค (C) เป็นต้น ปัญหาในการวิเคราะห์เส้นถดถอยอีกอย่างหนึ่งคือ จะต้องเกี่ยวข้องกับตัวแปรที่ไม่สามารถจะวัดได้ ซึ่งมีลักษณะเป็นตัวแปรคุณภาพ (quality variable) และเราเชื่อกันว่า ตัวแปรคุณภาพนี้มีส่วนสำคัญซึ่งจะกระทบกระเทือนถึงตัวแปรอื่น ๆ ตัวอย่างเช่น ค่าใช้จ่ายในการบริโภคในครอบครัวไม่สามารถจะถูกอธิบายทั้งหมดได้โดยรายได้ของครอบครัว หรือกล่าวง่าย ๆ ว่าการบริโภคมีได้ขึ้นอยู่กับรายได้อย่างเดียว ยังมีตัวแปรอื่น ๆ เช่น เพศ ศาสนา เชื้อชาติ การศึกษาของหัวหน้าครอบครัว อาจจะกระทบกระเทือนค่าใช้จ่ายในการบริโภค ซึ่งตัวแปรเหล่านี้วัดออกมาเป็นตัวเลขไม่ได้ เราจะเอาตัวแปรเหล่านี้เข้ามารวมในโมเดลเส้นถดถอยได้อย่างไร และถ้าหากไม่นำเข้ามาพิจารณาด้วยก็จะ เป็นการไม่ถูกต้องจะทำให้ค่าพยากรณ์ผิดพลาดไป ด้วยเหตุนี้จึงมีผู้คิด "ตัวแปรหุ่น" (Dummy Variable) ขึ้นมา Dummy Variable คือ ตัวแปรที่กำหนดขึ้นมาโดยพลการแทนตัวแปรที่วัดไม่ได้ มีลักษณะเป็นตัวแปรอิสระหรือตัวแปรภายนอกทำหน้าที่เหมือนตัวแปรอิสระอื่น ๆ และอยู่ทางขวามือของสมการ คือ

$$Y_i = a + bX + c_1D_1 + c_2D_2 + \dots + c_jD_j$$

D_1, \dots, D_j คือ ตัวแปรหุ่นแทนตัวแปรคุณภาพที่วัดเป็นตัวเลขไม่ได้ ตัวแปรคุณภาพนี้ยังรวมไปถึงผลกระทบจากกฎเกณฑ์ที่เราตั้งขึ้นหรือจากเหตุการณ์ต่าง ๆ ซึ่งไม่สามารถจะวัดออกมาได้เช่นกัน เช่น ผลกระทบจากสงคราม จากการเปลี่ยนแปลงทางการเมือง จากการวางแผนพัฒนาเศรษฐกิจ, จากการค้าต่างประเทศ จากการขึ้นราคาสินค้า ภาษี การควบคุม, ข้อห้ามต่าง ๆ ฯลฯ เป็นต้น

ค่าของ Dummy Variable จะมี 2 ค่า คือ 1 และ 0 ค่า 1 จะแทนพฤติกรรมที่เหมาะสมกับกรณีหรือแทนสถานะการณที่มีผลแน่ในช่วงเวลาที่ศึกษา ส่วนพฤติกรรมที่ตรงข้ามหรือไม่มีผลก็จะกำหนดค่าให้ = 0 เช่น ให้ D เป็น Dummy Variable แทนเพศของหัวหน้าครอบครัว เราอาจกำหนดค่า 1 ถ้าหัวหน้าครอบครัวเป็นหญิง และ 0 ถ้าหัวหน้าครอบครัวเป็นชาย หัวหน้าครอบครัวเป็นหญิงมีแนวโน้มที่มีรายได้ต่ำกว่าหัวหน้าครอบครัวเป็นชาย ดังนั้นในระดับรายได้ที่กำหนดให้ ครอบครัวที่มีหัวหน้าเป็นหญิงจะบริโภคมากกว่า (ความโน้มเอียงในการบริโภคเฉลี่ย) ในการสำรวจเก็บข้อมูลตัวอย่างจะปรากฏข้อมูลเป็น 2 กลุ่ม ดังรูป 3.3

ถ้าหากเราไม่พิจารณาเพศของหัวหน้าครอบครัว จะได้เส้น regression ซึ่งมี slope ค่อนข้างราบ (เส้นประในรูป) แต่ถ้านำเพศมาพิจารณาด้วย เราจะได้ slope ที่แท้จริง แม้เส้น regression จะแยกกัน แต่ slope ก็เท่ากัน ซึ่งแสดงว่า แม้ว่าความโน้มเอียงในการบริโภคเฉลี่ยในครอบครัวที่มีหัวหน้าเป็นหญิงจะสูงกว่าชาย แต่ความโน้มเอียงในการบริโภคเพิ่ม (Marginal Propensity to Consume) จะเท่ากันหรือเหมือนกัน