

บทที่ 2

ทฤษฎีและสถิติที่เกี่ยวข้อง

ในบทนี้จะกล่าวถึงการเปรียบเทียบวิธีถดถอยพหุคูณในการวิเคราะห์ความถดถอยพหุคูณด้วยวิธีวิเคราะหฐานและวิธีที่ใช้หลักการของ โครงข่ายประสาทเทียม ซึ่งรายละเอียดต่างๆ มีดังนี้

วิธีวิเคราะหฐาน

เราสามารถเขียนตัวแบบทั่วไปในการวิเคราะห์ความถดถอยพหุคูณเชิงเส้นได้ดังนี้

$$(2.1) \quad \underline{y} = \underline{X} \underline{\beta} + \underline{\varepsilon}$$

เมื่อ \underline{y} คือ เวกเตอร์ของตัวแปรตามขนาด $n \times 1$

\underline{X} คือ เมทริกซ์ของตัวแปรอิสระขนาด $n \times (p+1)$

$\underline{\beta}$ คือ เวกเตอร์ของสัมประสิทธิ์การถดถอยพหุคูณขนาด $(p+1) \times 1$

$\underline{\varepsilon}$ คือ เวกเตอร์ค่าความคลาดเคลื่อนที่เกิดขึ้นขนาด $n \times 1$

โดยที่ $E(\underline{\varepsilon}) = \underline{0}$, $\text{cov}(\underline{\varepsilon}) = \sigma^2 I_n$

n คือ ขนาดตัวอย่าง

และ p คือ จำนวนตัวแปรอิสระ

จากตัวแบบทั่วไป มักนิยมใช้วิธีกำลังสองน้อยสุดในการประมาณค่าสัมประสิทธิ์การถดถอยพหุคูณ ซึ่งอยู่ในรูปของ

$$(2.2) \quad \underline{\hat{\beta}} = (\underline{X}' \underline{X})^{-1} \underline{X}' \underline{y}$$

เมื่อ $\underline{\hat{\beta}}$ เป็นตัวประมาณไม่เอนเอียงที่มีค่าความคลาดเคลื่อนกำลังสองเฉลี่ยต่ำสุดเมื่อเปรียบเทียบกับตัวประมาณไม่เอนเอียงตัวอื่นๆ แต่ในกรณีที่ตัวแปรอิสระมีความสัมพันธ์กัน คือมีสภาพที่ไม่เหมาะสม (ill-condition) ซึ่งเกิดขึ้นบ่อยครั้งในทางปฏิบัติ และทำให้การประมาณ $\underline{\beta}$ ด้วยวิธีกำลังสองน้อยสุดไม่ได้ค่าความคลาดเคลื่อนกำลังสองเฉลี่ยต่ำสุด ดังนั้นจึงควรตรวจสอบประสิทธิภาพของตัวประมาณที่ได้

ซึ่งในการพิจารณาประสิทธิภาพของตัวประมาณค่า $\underline{\beta}$ แบ่งการพิจารณาเป็นสองส่วน คือเมทริกซ์ความแปรปรวนร่วมของตัวประมาณ $\underline{\beta}$ และค่าเฉลี่ยกำลังสองระยะทางจาก $\underline{\hat{\beta}}$ ไปยัง $\underline{\beta}$ เราสามารถเขียนเมทริกซ์ความแปรปรวนร่วมของ $\underline{\hat{\beta}}$ ได้ดังนี้

$$(2.3) \quad \text{cov}(\underline{\hat{\beta}}) = \sigma^2 (X'X)^{-1}$$

ให้ L_1 คือ ระยะทางจาก $\underline{\hat{\beta}}$ ไปยัง $\underline{\beta}$ ดังนั้น

$$(2.4) \quad L_1^2 = (\underline{\hat{\beta}} - \underline{\beta})' (\underline{\hat{\beta}} - \underline{\beta})$$

และได้ค่าเฉลี่ยกำลังสองระยะทางจาก $\underline{\hat{\beta}}$ ไปยัง $\underline{\beta}$ อยู่ในรูปของ

$$(2.5) \quad \begin{aligned} E(L_1^2) &= \sigma^2 \text{trace}(X'X)^{-1} \\ &= E [(\underline{\hat{\beta}} - \underline{\beta})' (\underline{\hat{\beta}} - \underline{\beta})] \\ &= E [\underline{\hat{\beta}}' \underline{\hat{\beta}} - 2\underline{\hat{\beta}}' \underline{\beta} + \underline{\beta}' \underline{\beta}] \\ &= E(\underline{\hat{\beta}}' \underline{\hat{\beta}}) - \underline{\beta}' \underline{\beta} \end{aligned}$$

$$(2.6) \quad E(\underline{\hat{\beta}}' \underline{\hat{\beta}}) = \underline{\beta}' \underline{\beta} + \sigma^2 \text{trace}(X'X)^{-1}$$

เมื่อ $\underline{\beta}$ มีการแจกแจงปกติ จะได้ว่า

$$(2.7) \quad \text{Var}(L_1^2) = 2\sigma^4 \text{trace}\{(X'X)^{-2}\}$$

จากสมการ (2.3), (2.5) และ (2.7) เราจะเห็นได้ว่า $\text{cov}(\underline{\hat{\beta}})$, $E(L_1^2)$ และ $\text{Var}(L_1^2)$ ต่างก็ขึ้นฟังก์ชัน $(X'X)^{-1}$ อยู่ในสมการเช่นเดียวกัน ดังนั้นเพื่อความสะดวกเราจะแปลงฟังก์ชัน $(X'X)^{-1}$ ให้อยู่ในรูปของฟังก์ชันค่าเฉพาะ (eigenvalue function) โดยใช้คุณสมบัติของค่าเฉพาะ กล่าวคือ

ถ้า λ_i เป็นค่าเฉพาะของเมทริกซ์ $X'X$ แล้ว $\sum_{i=1}^p \lambda_i = \text{trace}(X'X)$; $i = 1, 2, \dots, p$
เมื่อ p เป็นจำนวนตัวแปรอิสระ

กำหนดให้ค่าเฉพาะของเมทริกซ์ $X'X$ มีค่าดังนี้

$$(\lambda_{\max} = \lambda_1) \geq \lambda_2 \geq \lambda_3 \geq \dots \geq (\lambda_p = \lambda_{\min}) > 0$$

จากสมการ (2.5) สามารถเขียนให้อยู่ในรูปฟังก์ชันค่าเฉพาะได้ดังนี้

$$(2.8) \quad E(L_i^2) = \sigma^2 \sum_{i=1}^p \left(\frac{1}{\lambda_i} \right)$$

จากสมการ (2.7) และคุณสมบัติของค่าเฉพาะ เราสามารถเขียนให้อยู่ในรูปฟังก์ชันค่าเฉพาะได้ดังนี้

$$(2.9) \quad \text{Var}(L_i^2) = 2\sigma^4 \sum_{i=1}^p \left(\frac{1}{\lambda_i} \right)^2$$

ในกรณีที่ความแปรปรวนมีความสัมพันธ์กันสูงจะทำให้ $|X'X|$ มีค่าเข้าใกล้ศูนย์ เนื่องจาก $|X'X|$ มีค่าเท่ากับผลคูณของค่าเฉพาะของเมทริกซ์ $X'X$ จึงส่งผลให้ค่าเฉพาะบางค่าของเมทริกซ์ $X'X$ มีค่าน้อยมาก ทิศทางสมการ (2.8) และ (2.9) จะเห็นได้ว่าค่า $E(L_i^2)$ และ $\text{Var}(L_i^2)$ มีค่าสูงตามไปด้วย นั่นคือ การประมาณค่า β ด้วยวิธีกำลังสองน้อยสุดจะให้ค่าเฉลี่ยกำลังสองที่สูงขึ้นและ $\hat{\beta}$ เป็นตัวประมาณที่ไม่เหมาะสม

ในปี ค.ศ. 1970 โฮเอรีน (Hoerl) และ เคนนาร์ด (Kennard) ได้เสนอวิธีรีดจิเรชันเพื่อใช้ในการวิเคราะห์ความถดถอยพหุคูณในกรณีที่เกิดพหุสัมพันธ์ในตัวแปรอิสระ โดยการบวกค่าคงที่มากกว่าศูนย์กับสมาชิกทุกตัวในแนวทแยงมุมของเมทริกซ์ $X'X$ เพื่อลดค่าเฉลี่ยความคลาดเคลื่อนกำลังสองของการประมาณ $\hat{\beta}$ และให้ค่าที่ต่ำกว่าวิธีกำลังสองน้อยสุด

ให้ $\hat{\beta}_R$ เป็นตัวประมาณสัมประสิทธิ์การถดถอยพหุคูณด้วยวิธีรีดจิเรชัน เราสามารถเขียนได้ดังนี้

$$(2.10) \quad \hat{\beta}_R = (X'X + kI)^{-1} X' y \quad ; \quad k > 0$$

$$(2.11) \quad = W X' y \quad ; \quad W = (X'X + kI)^{-1}$$

ในการศึกษานี้จะใช้การประมาณค่า k ด้วยวิธีค้นหาลำดับ (binary search) ซึ่งจะได้กล่าวถึงในลำดับต่อไป

จากสมการปกติของวิธีกำลังสองน้อยสุด $X'X\tilde{\beta} = X'y$ เราสามารถเขียนตัวประมาณ $\tilde{\beta}_R$ ในรูปของตัวประมาณ $\tilde{\beta}$ ได้ดังนี้

$$(2.12) \quad \tilde{\beta}_R = [I + k(X'X)^{-1}]^{-1} \tilde{\beta}$$

$$(2.13) \quad = Z\tilde{\beta} \quad ; \quad Z = [I + k(X'X)^{-1}]^{-1}$$

คุณสมบัติที่จำเป็นของ $\tilde{\beta}_R$, W และ Z เพื่อใช้ในการเปรียบเทียบค่าความคลาดเคลื่อนกับวิธีกำลังสองน้อยสุด มีดังนี้

1) ให้ $\xi_i(W)$ และ $\xi_i(Z)$ เป็นค่าเฉพาะของ W และ Z ตามลำดับ ซึ่งคำนวณได้จากสมการลักษณะเฉพาะ (characteristic equations)

$$|W - \xi_i I| = 0$$

และ $|Z - \xi_i I| = 0$

เราจะได้ค่าเฉพาะของ W และ Z ซึ่งอยู่ในรูปของ

$$\xi_i(W) = \frac{1}{(\lambda_i + k)}$$

และ $\xi_i(Z) = \frac{1}{(\lambda_i + k)}$

2) ซึ่งสามารถจัดรูป Z ให้อยู่ในรูปของ W ได้ดังนี้

$$Z = I - k(X'X + kI)^{-1}$$

$$= I - kW$$

3) $\hat{\beta}_R$ มีค่าน้อยกว่า $\hat{\beta}$ เมื่อ $k > 0$ กล่าวคือ

$$\hat{\beta}_R' \hat{\beta}_R < \hat{\beta}' \hat{\beta}$$

พิจารณาตัวประมาณ $\hat{\beta}_R$ จากสมการ (2.13) เมทริกซ์ $X'X$ และ Z มีคุณสมบัติเป็นบวกแน่นอน (symmetric positive definite) จะได้ว่า

$$\hat{\beta}_R' \hat{\beta}_R \leq \xi_{\max}^2(Z) \hat{\beta}' \hat{\beta}$$

เมื่อ $\xi_{\max}(Z) = \frac{\lambda_i}{(\lambda_i + k)}$ โดยที่ λ_i เป็นค่าเฉพาะที่มีค่าสูงสุดของเมทริกซ์ $X'X$

พิจารณา คุณสมบัติในข้อ 1) และ 2) ของ Z จะได้ว่า $Z = I$ เมื่อ $k = 0$ และ Z มีค่าเข้าใกล้ 0 เมื่อ $k \rightarrow \infty$

ถ้าให้ $\phi(\hat{\beta})$ เป็นผลบวกความคลาดเคลื่อนกำลังสองของตัวประมาณ $\hat{\beta}$ จะได้ว่า

$$(2.14) \quad \phi(\hat{\beta}) = \underline{y}' \underline{y} - \hat{\beta}' X' \underline{y}$$

ให้ $\phi(\hat{\beta}_R)$ เป็นผลบวกความคลาดเคลื่อนกำลังสองของตัวประมาณ $\hat{\beta}_R$ จะได้ว่า

$$\phi(\hat{\beta}_R) = (\underline{y} - X \hat{\beta}_R)' (\underline{y} - X \hat{\beta}_R)$$

เราสามารถเขียน $\phi(\hat{\beta}_R)$ ในรูปของ $\underline{y}' \underline{y}$ และ $X' \underline{y}$ ได้ดังนี้

$$(2.15) \quad \begin{aligned} \phi(\hat{\beta}_R) &= \underline{y}' \underline{y} - \hat{\beta}' X' \underline{y} - k \hat{\beta}_R' \hat{\beta}_R \\ &= \phi(\hat{\beta}) - k \hat{\beta}_R' \hat{\beta}_R \end{aligned}$$

จากสมการ (2.15) เราสามารถสรุปได้ว่าผลบวกความคลาดเคลื่อนกำลังสองที่ได้จากวิธีวิธีเกรดชัน มีค่าน้อยกว่าผลบวกความคลาดเคลื่อนกำลังสองที่ได้จากวิธีกำลังสองน้อยสุด



คุณสมบัติของค่าความคลาดเคลื่อนกำลังสองเฉลี่ยของวิธีลดวีการชัน

ในการประมาณค่าสัมประสิทธิ์การถดถอยพหุคูณ β ด้วยวิธีกำลังสองน้อยสุด จะได้ค่าความคลาดเคลื่อนกำลังสองเฉลี่ยดังนี้

$$\begin{aligned}MSE(\hat{\beta}) &= \text{cov}(\hat{\beta}) \\ &= \sigma^2 (X'X)^{-1}\end{aligned}$$

เนื่องจาก $E(\hat{\beta}) = \beta$ ดังนั้นการประมาณค่าพารามิเตอร์ β ด้วยวิธีกำลังสองน้อยสุด จะได้ตัวประมาณ $\hat{\beta}$ ที่ไม่เอนเอียง แต่การประมาณค่าพารามิเตอร์ β_R ในวิธีลดวีการชันจะได้ตัวประมาณ $\hat{\beta}_R$ ที่เอนเอียง กล่าวคือ $E(\hat{\beta}_R) = Z\beta$ และมีค่าความคลาดเคลื่อนกำลังสองเฉลี่ยดังนี้

$$\begin{aligned}E[L_1^2(k)] &= E[(\hat{\beta}_R - \beta)'(\hat{\beta}_R - \beta)] \\ &= E[(\hat{\beta} - \beta)'Z'Z(\hat{\beta} - \beta)] + (Z\beta - \beta)'(Z\beta - \beta) \\ &= \sigma^2 \text{trace}[(X'X)^{-1}Z'Z] + \beta'(Z - I)'(Z - I)\beta \\ &= \sigma^2 [\text{trace}(X'X + kI)^{-1} - k \text{trace}(X'X + kI)^{-2}] \\ &\quad + k^2 \beta'(X'X + kI)^{-2}\beta \\ &= \sigma^2 \sum_{i=1}^p \frac{\lambda_i}{(\lambda_i + k)^2} + k^2 \beta'(X'X + kI)^{-2}\beta \\ &= \gamma_1(k) + \gamma_2(k)\end{aligned}$$

โดยที่ $\gamma_2(k)$ เป็นระยะทางจาก $Z\beta$ ไปยัง β มีค่าเป็นศูนย์เมื่อ $k = 0$ และ Z เป็นเมทริกซ์เอกตึกขณ์ ดังนั้นอาจพิจารณาเทอม $\gamma_2(k)$ เป็นค่าเอนเอียงกำลังสองของตัวประมาณ $\hat{\beta}_R$ เมื่อ $k > 0$ ส่วนเทอม $\gamma_1(k)$ เป็นผลรวมความแปรปรวนของการประมาณพารามิเตอร์ β สามารถเขียนในรูปของ y ได้ดังนี้

$$\begin{aligned}\hat{\beta}_R &= Z \hat{\beta} \\ &= Z(X'X)^{-1} X' y\end{aligned}$$

ดังนั้น

$$\begin{aligned}\text{Var}(\hat{\beta}_R) &= Z(X'X)^{-1} X' \text{Var}(y) X(X'X)^{-1} Z' \\ (2.16) \quad &= \sigma^2 Z(X'X)^{-1} Z'\end{aligned}$$

เราสามารถเขียน Z และ $(X'X)^{-1}$ ในรูปของค่าเฉพาะได้ดังนี้

$$\begin{aligned}\text{trace}(X'X)^{-1} &= \sum_{i=1}^p \frac{1}{\lambda_i} \\ \text{trace}(Z) &= \sum_{i=1}^p \frac{\lambda_i}{\lambda_i + k}\end{aligned}$$


จากสมการ (2.16) จะได้ว่า

$$\sigma^2 \text{trace} Z(X'X)^{-1} Z' = \sigma^2 \sum_{i=1}^p \frac{\lambda_i}{(\lambda_i + k)^2}$$

ดังนั้น

$$E [L_1^2(k)] = \text{Var}(\hat{\beta}_R(k)) + [\text{Bias}(\hat{\beta}_R(k))]^2$$

สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย



รูปที่ 2.1 แสดงลักษณะความสัมพันธ์ระหว่างความแปรปรวน ความเอนเอียงกำลังสอง และ พารามิเตอร์ k

(ที่มา : Authur E. Hoerl and Robert W. Kennard. "Ridge Regression : Biased Estimation for Nonorthogonal Problems." *Technometrics*, February 1970., page 61.)

จากรูปที่ 2.1 จะเห็นได้ว่าเมื่อ k มีค่าเพิ่ม ความแปรปรวนจะมีค่าลดลง คือ ค่าพารามิเตอร์ k ผกผันกับความแปรปรวนของตัวประมาณ $\hat{\beta}_R$ และแปรผันตามค่าความเอนเอียงกำลังสองของตัวประมาณ $\hat{\beta}_R$

พิจารณาที่กราฟเส้นประ และกราฟเส้นตรง จะเห็นว่ามีค่า k บางค่าที่ทำให้ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองของตัวประมาณ $\hat{\beta}_R$ มีค่าน้อยกว่าค่าความคลาดเคลื่อนกำลังสองเฉลี่ยของตัวประมาณ $\hat{\beta}$

เราสามารถหาขีดจำกัดของความแปรปรวนและความเอนเอียงกำลังสองของตัวประมาณ $\hat{\beta}_x$ โดยการหาขีดจำกัดของอนุพันธ์อันดับที่ 1 ของฟังก์ชัน $\gamma_1(k)$ และ $\gamma_2(k)$ เทียบกับค่าพารามิเตอร์ k ได้ดังนี้

$$\lim_{k \rightarrow 0^+} \left(\frac{\partial \gamma_1}{\partial k} \right) = -2\sigma^2 \sum_{i=1}^p \frac{1}{\lambda_i^2}$$

$$\lim_{k \rightarrow 0^+} \left(\frac{\partial \gamma_2}{\partial k} \right) = 0$$

ดังนั้นฟังก์ชัน $\gamma_1(k)$ มีอนุพันธ์เป็นลบมีค่าเข้าสู่ $-2\sigma^2 \sum_{i=1}^p (1/\lambda_i^2)$ เมื่อ $k \rightarrow 0^+$ และ $X'X$ เป็นเมทริกซ์เชิงคังฉาก และมีค่าเข้าสู่ $-\infty$ เมื่อ $X'X$ มีสภาพไม่เหมาะสม คือตัวแปรอิสระมีความสัมพันธ์กัน ส่วนฟังก์ชัน $\gamma_2(k)$ มีอนุพันธ์เท่ากับศูนย์ เมื่อ $k \rightarrow 0^+$ กล่าวคือ เมื่อ $k > 0$ จะมีความเอนเอียงกำลังสองของตัวประมาณ $\hat{\beta}_x$ เล็กน้อย แต่ความแปรปรวนของตัวประมาณ $\hat{\beta}_x$ จะมีค่าลดลงมาก จึงทำให้ค่าความคลาดเคลื่อนกำลังสองเฉลี่ยของวิธีวัดจักรมาตรันมีค่าลดลงและมีค่าน้อยกว่าค่าความคลาดเคลื่อนกำลังสองเฉลี่ยที่ได้จากวิธีกำลังสองน้อยสุด

การประมาณค่าพารามิเตอร์ k

ในการวิจัยของจิราวุธ ชูมนตรี (2534) ได้เปรียบเทียบการประมาณค่าพารามิเตอร์ k ด้วยวิธี HKB, TZE และการค้นหาแบบทวิ (Binary Search) ผลสรุปที่ได้ คือวิธีการค้นหาแบบทวิจะให้ค่าการประมาณพารามิเตอร์ k คีที่ที่สุด แต่ในงานวิจัยของ ชันชากร คันชดจันท์ (2538) ได้ชี้ให้เห็นความไม่เหมาะสมของวิธีนี้ เนื่องจากวิธีค้นหาแบบทวิมีข้อจำกัด คือจะใช้ได้กับข้อมูลที่มีลักษณะแบบไม่ต่อเนื่อง และใช้ในการค้นหาที่มีลักษณะเรียงลำดับเท่านั้น ซึ่งชันชากร คันชดจันท์ ได้นำเสนอวิธีการประมาณค่าพารามิเตอร์ k แบบลำดับ (Sequential Search) ซึ่งเป็นการค้นหาข้อมูลในทางคอมพิวเตอร์ เช่นเดียวกับวิธีค้นหาแบบทวิ แต่สามารถใช้ได้กับข้อมูลที่มีลักษณะทั้งแบบต่อเนื่อง และแบบไม่ต่อเนื่อง และข้อมูลที่จะค้นหาจะเรียงลำดับหรือไม่เรียงลำดับก็ได้ แต่ข้อเสียของวิธีการนี้ คือ อาจใช้เวลานาน ถ้า k ที่เหมาะสมอยู่ลำดับไกล แต่ในทางปฏิบัติค่า k จะอยู่ช่วง $(0,1)$ และจากคุณสมบัติของค่าความคลาดเคลื่อนกำลังสองเฉลี่ยของตัวประมาณ $\hat{\beta}_x$ เราจะได้ว่า k ที่เหมาะสมจะอยู่ห่างจากศูนย์ไม่มาก ผู้วิจัยจึงได้ใช้วิธีการค้นหาแบบลำดับในการประมาณค่าพารามิเตอร์ k

การประมาณค่าพารามิเตอร์ k โดยวิธีค้นหาด้วย¹

กำหนดให้ k_{opt} คือ ค่า k ที่ทำให้ $MSE(\hat{\beta}_R(k))$ มีค่าต่ำสุด $\hat{\beta}_R$

k_{min} คือ ค่า k ณ จุดเริ่มต้นในการค้นหาข้อมูล

k_0 คือ ค่า k ณ ที่มีการเว้นช่วงห่างของค่า k เท่ากับ d

k_{BEST} คือ ค่า k ณ จุดที่อยู่ก่อนค่า k ที่เหมาะสม มีการเว้นช่วงห่างของค่า k เท่ากับ d

k_{ASTD} คือ ค่า k ณ จุดที่อยู่หลังค่า k ที่เหมาะสม มีการเว้นช่วงห่างของค่า k เท่ากับ d

และ k_{STOP} คือ ค่า k ที่ใช้ตรวจสอบการหยุดค้นหาค่า k ที่เหมาะสมเมื่อทำการค้นหาข้อมูล
ทางด้านขวาของค่า k ที่เหมาะสม

ขั้นที่ 1 กำหนดให้ค่า $k_{min} = 0.0$ และค่า $d = 0.01$

ขั้นที่ 2 คำนวณค่า $k_{01} = k_{min} + d$

ขั้นที่ 3 คำนวณหา $MSE(\hat{\beta}_R(k_{min}))$ และหาค่า $MSE(\hat{\beta}_R(k_{01}))$ แล้วทำการเปรียบเทียบ

ก) ถ้า $MSE(\hat{\beta}_R(k_{01})) > MSE(\hat{\beta}_R(k_{min}))$

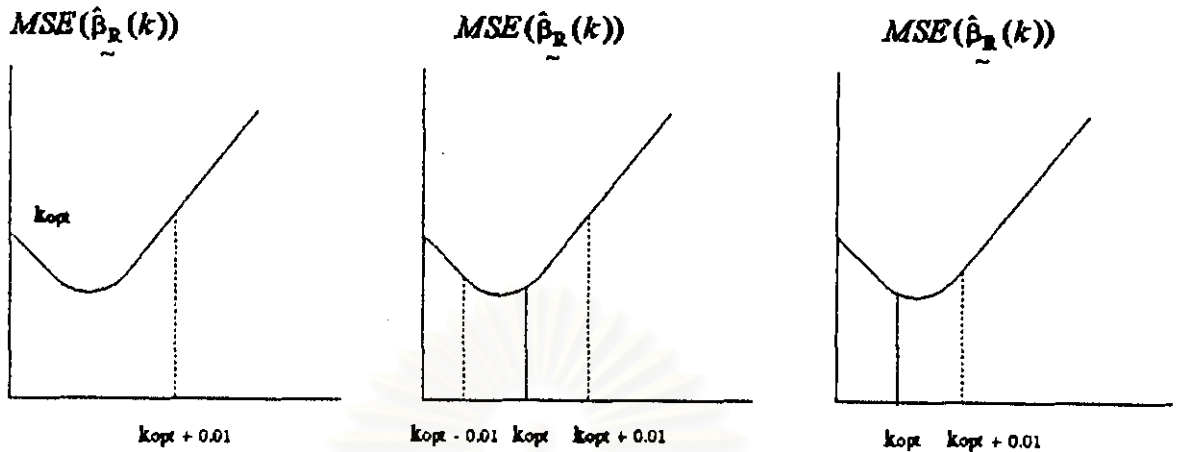
จะได้ว่า $k_{01} = k_{min}$ ยุติการประมวลผล

ข) ถ้า $MSE(\hat{\beta}_R(k_{01})) \leq MSE(\hat{\beta}_R(k_{min}))$ เราจะกำหนดให้ $k_{min} = k_{01}$ และทำการ

วิเคราะห์ขั้นที่ 2 ใหม่จนกว่าจะเป็นดังกรณี ก)

เนื่องจากลักษณะของ $MSE(\hat{\beta}_R(k))$ เป็นรูปโค้งหงาย การหาจุดที่ต่ำสุดจึงขึ้นอยู่กับ การกำหนดช่วงห่างของค่า k ซึ่งลักษณะความเป็นไปได้ของการพบจุดที่ต่ำสุดของช่วงห่างที่ไม่ละเอียดพอ ซึ่งแสดงได้ดังกรณีที่ 1-3

¹ อ้นชากร คันทรจันน์, "การเปรียบเทียบการประมาณค่าสัมประสิทธิ์การถดถอยพหุโดยวิธีกำลังสองน้อยที่สุด วิธีคิดเชิงเรขาคณิต และวิธีที่ใช้หลักการของรีดจ์และสโตน ในกรณีที่เกิดพหุสัมพันธ์ระหว่างตัวแปรอิสระ" (วิทยานิพนธ์ปริญญาโท สาขาวิชาสถิติ บัณฑิตวิทยาลัย จุฬาลงกรณ์มหาวิทยาลัย, 2538), หน้า 216.



กรณีที่ 1

กรณีที่ 2

กรณีที่ 3

กรณีที่ 1 ถ้าเรากำหนดช่วง d ห่างเกินไป จุดที่จะได้จุดต่ำสุดอาจเป็นจุดเริ่มแรกที่กำหนดให้ $k_{opt} = 0.0$ ซึ่งในกรณีนี้แก้ปัญหาก็ได้โดยให้มีการกำหนดช่วงห่างของการค้นหาให้ละเอียดขึ้น และทำการค้นหาข้อมูลแบบลำดับจากจุดเริ่มต้น $k_{opt} = 0.0$ จนถึงจุดที่ $k_{opt} = 0.0 + 0.01$ ใหม่อีกครั้ง โดยใช้ช่วงห่างของการคำนวณเป็น $d = 0.001$

กรณีที่ 2 ถ้าจุดของค่า k ที่ค้นหาได้ติดอยู่หลังค่า k ที่เหมาะสมจริงๆ จึงจะเกิดกรณีนี้ขึ้น แก้ปัญหาโดยการเพิ่มช่วงห่างของการค้นหาให้ละเอียดขึ้นและจะค้นหาข้อมูลทางด้านซ้ายของค่า k_{opt} อีกครั้งโดยการค้นหาข้อมูลแบบลำดับจากจุด $k_{opt} - 0.01$ ไปจนถึงจุด k_{opt} โดยใช้ช่วงห่างของการค้นหาเป็น $d = 0.001$

กรณีที่ 3 ถ้าจุดของค่า k ที่ค้นหาติดอยู่ก่อนหน้า k ที่เหมาะสมจริงๆ จึงจะเกิดกรณีนี้ แก้ปัญหาโดยการเพิ่มช่วงห่างของการค้นหาให้ละเอียดขึ้น และจะค้นหาข้อมูลทางด้านขวาของค่า k_{opt} อีกครั้ง โดยจะค้นหาข้อมูลแบบลำดับจากจุด k_{opt} ไปจนถึงจุด $k_{opt} + 0.01$ โดยใช้ช่วงห่างของการค้นหาเป็น $d = 0.001$

ดังนั้นจะทำการค้นหาค่า k ที่เหมาะสมอีกครั้งโดยกำหนดช่วงความห่างของการค้นหาใหม่ คือ $d = 0.001$ โดยการตรวจสอบก่อนว่าค่า k_{opt} ที่ได้มีค่าเท่ากับศูนย์หรือไม่ ถ้ามีค่าเท่ากับศูนย์ก็คือกรณีที่ 1 และทำการค้นหาข้อมูลแบบลำดับเฉพาะทางด้านขวาของค่า k_{opt} แต่ถ้าค่า k_{opt} ไม่เท่ากับศูนย์ จะทำการค้นหาข้อมูลแบบลำดับทางซ้ายของค่า k_{opt} อีกครั้งซึ่งขั้นตอนต่างๆ ในการค้นหาครั้งนี้

ให้ $d = 0.001$

ขั้นที่ 1 ตรวจสอบว่าค่า k_{opt} เท่ากับศูนย์หรือไม่

- ก) ถ้า $k_{opt} = 0$ ให้ทำการวิเคราะห์ขั้นที่ 3 (ค้นหาทางด้านขวาของค่า k_{opt})
- ข) ถ้า $k_{opt} \neq 0$ (มากกว่า 0) ให้ทำการวิเคราะห์ขั้นที่ 2 (ค้นหาทางด้านซ้ายของค่า k_{opt})

ขั้นที่ 2 ให้ $k_{BEP01} = k_{opt} - 0.01$

ก) ให้ $k_{001} = k_{BEP01} + d$ เปรียบเทียบค่า k_{001} กับ k_{opt}

ถ้า $k_{001} \geq k_{opt}$ ให้ทำการวิเคราะห์ขั้นที่ 3

ถ้า $k_{001} < k_{opt}$ คำนวณหา $MSE(\hat{\beta}_R(k_{BEP01}))$ และหา

$MSE(\hat{\beta}_R(k_{001}))$ แล้วทำการเปรียบเทียบ

ถ้า $MSE(\hat{\beta}_R(k_{001})) > MSE(\hat{\beta}_R(k_{BEP01}))$

จะได้ว่า $k_{opt} = k_{BEP01}$ ยุติการประมวลผล

ถ้า $MSE(\hat{\beta}_R(k_{001})) \leq MSE(\hat{\beta}_R(k_{BEP01}))$

เราจะกำหนด $k_{BEP01} = k_{001}$ แล้วทำการวิเคราะห์ข้อ ก) ในขั้นที่ 2 จนกว่า

จะเข้ากรณีที่ $k_{001} \geq k_{opt}$ หรือ $MSE(\hat{\beta}_R(k_{001})) > MSE(\hat{\beta}_R(k_{BEP01}))$

ขั้นที่ 3 ให้ $k_{STOP} = k_{opt} + 0.01$

ก) ให้ $k_{001} = k_{opt}$

ข) ให้ $k_{AFT01} = k_{001} + d$ เปรียบเทียบค่า k_{AFT01} กับ k_{STOP}

ถ้า $k_{AFT01} \geq k_{STOP}$ ให้ยุติการประมวลผล

ถ้า $k_{AFT01} < k_{STOP}$ เราจะคำนวณหา $MSE(\hat{\beta}_R(k_{AFT01}))$ และคำนวณหา

$MSE(\hat{\beta}_R(k_{001}))$ แล้วทำการเปรียบเทียบ

ถ้า $MSE(\hat{\beta}_R(k_{AFT01})) > MSE(\hat{\beta}_R(k_{001}))$

จะได้ว่า $k_{opt} = k_{001}$ และยุติการประมวลผล

ถ้า $MSE(\hat{\beta}_R(k_{AFT01})) \leq MSE(\hat{\beta}_R(k_{001}))$

เราจะกำหนด $k_{001} = k_{AFT01}$ และทำการวิเคราะห์ข้อ ข) ในขั้นที่ 3 จนกว่า


จะเข้ากรณีที่ $k_{AFT01} \geq k_{STOP}$ หรือ $MSE(\hat{\beta}_R(k_{AFT01})) > MSE(\hat{\beta}_R(k_{001}))$

เนื่องจาก ณ จุดที่ค่า $d = 0.001$ และ $d = 0.0001$ จะให้ค่า $MSE(\hat{\beta}_R(k))$ ที่มีค่าใกล้เคียงกัน

ดังนั้นผู้วิจัยจึงไม่ทำการขยายช่วงค่า d จาก $d = 0.001$ เป็น $d = 0.0001$

วิธีโครงข่ายประสาทเทียม

โครงข่ายประสาทเทียมเป็นอีกแนวทางหนึ่งในการแก้ปัญหาทางคอมพิวเตอร์ ซึ่งเป็นปัญหาซับซ้อนจนไม่สามารถสรุปเป็นขั้นตอนที่ชัดเจนได้ การนำหลักการของโครงข่ายประสาทเทียมมาใช้ทางสถิติโดยเฉพาะในการพยากรณ์ เนื่องจากโครงข่ายประสาทเทียมมีความสามารถในการจำข้อมูลเข้า และออกได้เป็นอย่างดี สามารถปรับปรุงตัวแบบที่เหมาะสมได้ด้วยตัวเอง และยังมีความสามารถในการพยากรณ์ข้อมูลที่ไม่เคยเห็นได้เป็นอย่างดี ถ้าจำนวนตัวอย่างที่นำมาฝึกสอนแก่โครงข่ายมีมาก และวิธีการสอนดีพอ ข้อแตกต่างกับวิธีทางสถิติ คือไม่มีการอธิบายตัวแบบ อธิบายการเปลี่ยนแปลงค่าของตัวแปรตามเมื่อตัวแปรอิสระเปลี่ยนแปลงไปและไม่มีการทดสอบสมมติฐานในการพยากรณ์ เนื่องจากสัมประสิทธิ์การถดถอยเป็นแบบไม่เชิงเส้น ไม่มีสัมประสิทธิ์ของตัวแปรอิสระแต่ละตัว นั่นคือโครงข่ายประสาทเทียมไม่มีพารามิเตอร์ที่มีคุณสมบัติทางสถิติ และเพื่ออำนวยความสะดวกในการทำความเข้าใจโครงข่ายประสาทเทียม จะอธิบายโดยใช้ตัวแบบโครงข่ายประสาทเทียม



รูปที่ 2.2 แสดงตัวแบบโครงข่ายประสาทเทียมหนึ่งชั้นซ่อนในรูปทั่วไป

(ที่มา : Laurene Fausett. "Fundamentals of Neural Networks : Architectures, algorithms and applications." New Torsey : Prentice - Hall, Inc., 1994. page 291.)

- เมื่อ X_i คือ นิวรอนชั้นป้อนเข้า (input layer) หน่วยที่ i ; $i = 1, 2, \dots, n$
 Z_j คือ นิวรอนชั้นซ่อน (hidden layer) หน่วยที่ j ; $j = 1, 2, \dots, p$
 Y_k คือ นิวรอนชั้นผลลัพธ์ (output layer) หน่วยที่ k ; $k = 1, 2, \dots, m$
 v_{ij} คือ ค่าถ่วงน้ำหนักในการเชื่อมนิวรอน X_i กับนิวรอน Z_j
 w_{jk} คือ ค่าถ่วงน้ำหนักในการเชื่อมนิวรอน Z_j กับนิวรอน Y_k
 v_{0j} คือ ค่าความเอนเอียงของนิวรอน Z_j
 w_{0k} คือ ค่าความเอนเอียงของนิวรอน Y_k

โครงข่ายที่เชื่อมนิวรอน Z_j ทั้งหมด แทนด้วย z_in_j : $z_in_j = v_{0j} + \sum_{i=1}^n x_i v_{ij}$

ค่าที่ส่งออกจากนิวรอน Z_j แทนด้วย z_j : $z_j = f(z_in_j)$

โครงข่ายที่เชื่อมนิวรอน Y_k ทั้งหมด แทนด้วย y_in_k : $y_in_k = w_{0k} + \sum_{j=1}^p z_j w_{jk}$

และ ค่าที่ส่งออกจากนิวรอน Y_k แทนด้วย y_k : $y_k = f(y_in_k)$

คำนวณทั่วไปอยู่ในรูปของ

$$\hat{y}_k = f\left(\sum_{j=1}^p f\left(\sum_{i=1}^n x_i v_{ij}\right) w_{jk}\right)$$

- เมื่อ \hat{y}_k คือ ค่าพยากรณ์ผลลัพธ์ของนิวรอนหน่วยที่ k
 x_i คือ ข้อมูลป้อนเข้าในนิวรอนหน่วยที่ i
 v_{ij} คือ ค่าถ่วงน้ำหนักในการเชื่อมนิวรอน X_i กับนิวรอน Z_j
 w_{jk} คือ ค่าถ่วงน้ำหนักในการเชื่อมนิวรอน Z_j กับนิวรอน Y_k

และ $f(x) = \frac{1}{1 + \exp(-x)}$ คือ Logistic Function

ในโครงข่ายประสาทเทียมมีการกระทำ 2 แบบ คือ


1. แบบการส่ง (mapping mode)
2. แบบการเรียนรู้ (learning mode)

แบบการส่ง (mapping mode)

การส่งเป็นการผ่านค่าไปข้างหน้าจากนิเวรอนในชั้นนำเข้า ไปสู่นิเวรอนในชั้นผลลัพธ์ ฟังก์ชันการส่งในโครงข่ายประสาทเทียมสามารถให้ค่าถ่วงน้ำหนักที่ถูกต้องกับฟังก์ชันรูปร่างต่างๆ จำนวนมาก หรืออาจกล่าวได้ว่าฟังก์ชันการส่งสามารถเปลี่ยนรูปร่างได้ตามเป้าหมายใดๆ ก็ได้ จนได้ชื่อว่า "a universal approximator" รวมทั้งยังได้มีการพิสูจน์ทางสถิติ² โดยใช้ฟังก์ชันซิกมอยด์ (sigmoid function) ซึ่งเป็นโครงสร้างของฟังก์ชันการส่งของโครงข่าย มีลักษณะเป็นฟังก์ชันเพิ่มทางเคียว เป็นฟังก์ชันการส่ง

ในโครงข่ายประสาทเทียมจะมีการคำนวณในชั้นซ่อนและชั้นผลลัพธ์เท่านั้น โดยคำนวณผลรวมค่าถ่วงน้ำหนักของชั้นซ่อน แทนค่าในฟังก์ชันการส่ง เพื่อให้ได้ค่าที่เหมาะสม ฟังก์ชันการส่งที่ใช้กันมากที่สุดในการข่ายประสาทเทียม คือ ฟังก์ชันโลจิสติก (logistic function) เนื่องจากสามารถหาอนุพันธ์ได้สำหรับทุกๆ ค่าของโดเมนเพื่อใช้ในการเรียนรู้ และสามารถเขียนอนุพันธ์อันดับหนึ่งให้อยู่ในรูปของฟังก์ชันเองได้ด้วย คือ

$$f'(x) = f(x)(1 - f(x))$$



รูปที่ 2.3 แสดงฟังก์ชันความหนาแน่นของฟังก์ชันโลจิสติก

² Hornik, Kurt, Maxwell Sincichombe and Halbert White, "Multilayer Feedforward Networks are Universal Approximators," *Neural Networks* 2, No.5 (1989) : 359-366.

Irie, Bunpei, and Sei Miyake, "Capabilities of Three-layered Perceptrons," *IEEE International Conference on Neural Networks, I* (1988) : 161-172.

Cybenko, G, "Approximation by Superpositions of a Sigmoidal Function," *Mathematical Control, Signals and Systems*, 2 (1989) : 303-314.

ฟังก์ชันความหนาแน่นอยู่ในรูปของ

$$f(x) = \frac{1}{1 + \exp(-x)}$$

แบบการเรียนรู้ (learning mode)

ถึงสำคัญที่มีผลกับการแพร่ย้อนกลับของความคลาดเคลื่อนในโครงข่ายประสาทเทียม คือ การเปลี่ยนแปลงของค่าถ่วงน้ำหนัก ดังนั้นเราจำเป็นต้องทราบค่าอนุพันธ์ย่อยของความคลาดเคลื่อนเมื่อเทียบกับค่าถ่วงน้ำหนัก

อนุพันธ์ย่อยของความคลาดเคลื่อนกำลังสองของโครงข่ายประสาทเทียมเทียบกับค่าถ่วงน้ำหนักของโครงข่ายประสาทเทียม โดยให้กฎลูกโซ่ (chain rule) ได้ดังนี้

$$\frac{\partial E}{\partial w_{jk}} = \frac{\partial E}{\partial y_k} \cdot \frac{\partial y_k}{\partial (y_{in_k})} \cdot \frac{\partial (y_{in_k})}{\partial w_{jk}}$$

$$\frac{\partial E}{\partial v_{0j}} = \left(\sum_{k=1}^n \frac{\partial E}{\partial y_k} \cdot \frac{\partial y_k}{\partial (y_{in_k})} \cdot \frac{\partial (y_{in_k})}{\partial z_j} \right) \cdot \frac{\partial z_j}{\partial (z_{in_j})} \cdot \frac{\partial (z_{in_j})}{\partial v_{0j}}$$

เมื่อ E คือ ความคลาดเคลื่อนกำลังสอง

v_{0j} คือ ค่าถ่วงน้ำหนักในการเชื่อมนิวรอน X_0 กับนิวรอน Z_j

w_{jk} คือ ค่าถ่วงน้ำหนักในการเชื่อมนิวรอน Z_j กับนิวรอน Y_k

v_{0j} คือ ค่าความเอนเอียงของนิวรอน Z_j

w_{0k} คือ ค่าความเอนเอียงของนิวรอน Y_k

z_{in_j} คือ โครงข่ายที่เชื่อมนิวรอน Z_j ทั้งหมด : $z_{in_j} = v_{0j} + \sum_{i=1}^n x_i v_{ij}$

z_j คือ ค่าที่ส่งออกจากนิวรอน Z_j : $z_j = f(z_{in_j})$

y_{in_k} คือ โครงข่ายที่เชื่อมนิวรอน Y_k ทั้งหมด : $y_{in_k} = w_{0k} + \sum_{j=1}^p z_j w_{jk}$

และ y_k คือ ค่าที่ส่งออกจากนิวรอน Y_k : $y_k = f(y_{in_k})$

ส่วนประกอบของอนุพันธ์เหล่านี้คำนวณโดยผ่านโครงข่ายแบบย้อนกลับ และแบบส่งค่าไปข้างหน้า แสดงได้ดังตารางต่อไปนี้

ส่งผ่านไปข้างหน้า (อ่านขึ้น)	ส่งผ่านไปข้างหลัง (อ่านลง)
$E = \frac{1}{2}(y_k - t_k)^2$	$\frac{\partial E}{\partial y_k} = (y_k - t_k)$
$y_k = f(y_{in_k})$	$\frac{\partial y_k}{\partial (y_{in_k})} = y_k(1 - y_k)$
$y_{in_k} = w_{0k} + \sum_{j=1}^p z_j w_{jk}$	$\frac{\partial (y_{in_k})}{\partial w_{jk}} = \begin{cases} 1 & j=0 \\ z_j & j=1, \dots, p \end{cases}$ $\frac{\partial (y_{in_k})}{\partial z_j} = w_{jk}$
$z_j = f(z_{in_j})$	$\frac{\partial z_j}{\partial (z_{in_j})} = z_j(1 - z_j)$
$z_{in_j} = v_{0j} + \sum_{i=1}^n x_i v_{ij}$	$\frac{\partial (z_{in_j})}{\partial v_{ij}} = \begin{cases} 1 & i=0 \\ x_i & i=1, \dots, n \end{cases}$

เมื่อ t_k คือ ผลลัพธ์เป้าหมายของนิวรอนหน่วยที่ k

กำหนดให้

$$p_k = \frac{\partial E}{\partial y_k} \cdot \frac{\partial y_k}{\partial (y_{in_k})}$$

เราจะได้ว่า

$$p_k = (y_k - t_k)y_k(1 - y_k)$$

ดังนั้นอนุพันธ์ย่อยของความคลาดเคลื่อนกำลังสองของโครงข่ายประสาทเทียบกับค่าถ่วงน้ำหนักที่เชื่อมนิวรอนในชั้นผลลัพธ์ คือ

$$\frac{\partial E}{\partial w_{jk}} = \begin{cases} p_k & ; j=0 \\ p_k z_j & ; j=1, \dots, p \end{cases}$$

กำหนดให้

$$q_j = \left(\sum_{k=1}^m \frac{\partial E}{\partial y_k} \cdot \frac{\partial y_k}{\partial (y_{in_k})} \cdot \frac{\partial (y_{in_k})}{\partial z_j} \right) \cdot \frac{\partial z_j}{\partial (z_{in_j})}$$

เราจะกล่าวได้ว่า

$$q_j = \left(\sum_{k=1}^m p_k w_{jk} \right) z_j (1 - z_j)$$

ดังนั้นอนุพันธ์ย่อยของความคลาดเคลื่อนกำลังสองของโครงข่ายประสาทเทียบกับค่าถ่วงน้ำหนักที่เชื่อมนิวรอนในชั้นซ่อน คือ

$$\frac{\partial E}{\partial v_{ij}} = \begin{cases} q_j & ; i=0 \\ q_j x_i & ; i=1, \dots, n \end{cases}$$

ขั้นตอนการเรียนรู้แบบแพร่ย้อนกลับ (Backpropagation algorithm)

1. กำหนดค่าถ่วงน้ำหนักเริ่มต้น (initial weight) ให้แก่ทุกนิวรอนในชั้นป้อนเข้า เป็นเลขสุ่มในช่วง (-1,1)
2. ในแต่ละนิวรอนป้อนเข้า (X_i , $i = 1, 2, \dots, n$) ได้รับค่า x_i และส่งค่าไปยังทุกๆ นิวรอนในชั้นซ่อน
3. แต่ละนิวรอนในชั้นซ่อน (Z_j , $j = 1, 2, \dots, p$) มีค่ารวมถ่วงน้ำหนักเท่ากับ

$$z_{in_j} = v_{0j} + \sum_{i=1}^n x_i v_{ij}$$

จากนั้นเราจะคำนวณค่าฟังก์ชันกระตุ้น (activation function) ได้ค่าส่งออกในนิวรอนชั้นซ่อนเท่ากับ

$$z_j = f(z_{in_j})$$

และส่งค่า z_j ไปยังทุกๆ นิวรอนในชั้นผลัดทิ้ง

4. แต่ละนิวรอนในชั้นผลัดทิ้ง (Y_k , $k = 1, 2, \dots, m$) มีค่ารวมถ่วงน้ำหนักเท่ากับ

$$y_{in_k} = w_{0k} + \sum_{j=1}^p z_j w_{jk}$$

จากนั้นเราคำนวณค่าฟังก์ชันกระตุ้น ได้ค่าส่งออกในนิวรอนชั้นผลัดทิ้งเท่ากับ

$$y_k = f(y_{in_k})$$

5. เปรียบเทียบผลต่างของค่า ($t_k - y_k$) ถ้ามีค่าน้อยกว่าหรือเท่ากับที่กำหนดไว้ก็จบการเรียนรู้ มิฉะนั้นทำขั้นที่ 6 ต่อ

6. แต่ละนิวรอนในชั้นผลัดทิ้งคำนวณความคลาดเคลื่อนได้เท่ากับ

$$\delta_k = (t_k - y_k) f'(y_{in_k})$$

จากนั้นเราจะคำนวณค่าถ่วงน้ำหนักที่ทำการปรับได้ ซึ่งอยู่ในรูปของ

$$\Delta w_{jk} = \alpha \delta_k z_j$$

เมื่อ α คือ อัตราการเรียนรู้ มีค่าอยู่ในช่วง (0,1)

และคำนวณค่าอนเองที่ทำการปรับได้ ซึ่งอยู่ในรูปของ

$$\Delta w_{0k} = \alpha \delta_k$$

แล้วส่งค่า δ_k ไปยังทุกๆ นิวรอนในชั้นซ่อน

7. แต่ละชั้นซ่อนมีผลรวมค่าถ่วงน้ำหนักของความคลาดเคลื่อนเท่ากับ

$$\delta_{in_j} = \sum_{k=1}^m \delta_k w_{jk}$$

จากนั้นเราจะคำนวณฟังก์ชันกระตุ้นของค่าความคลาดเคลื่อนเท่ากับ

$$\delta_j = \delta_{in_j} f'(z_{in_j})$$

และจะคำนวณค่าตัวนำหนักที่ทำการปรับได้ ซึ่งอยู่ในรูปของ

$$\Delta v_{ij} = \alpha \delta_j x_i$$

แล้วคำนวณค่าความเอนเอียงที่ทำการปรับได้ ซึ่งอยู่ในรูปของ

$$\Delta v_{0j} = \alpha \delta_j$$

8. ปรับค่าตัวนำหนักที่เชื่อมนิวรอนในชั้นซ่อนกับนิวรอนในชั้นผลลัพธ์ ด้วยค่าความคลาดเคลื่อน และค่าความเอนเอียง ได้ค่าตัวนำหนักใหม่เท่ากับ

$$w_{jk}(new) = w_{jk}(old) + \Delta w_{jk}$$

และทำการปรับค่าตัวนำหนักที่เชื่อมนิวรอนในชั้นป้อนเข้ากับนิวรอนในชั้นซ่อน ด้วยค่าความคลาดเคลื่อน และค่าความเอนเอียง ได้ค่าตัวนำหนักใหม่เท่ากับ

$$v_{ij}(new) = v_{ij}(old) + \Delta v_{ij}$$

9. กลับไปทำขั้นที่ 3

การแปลงข้อมูลโดยการแปลงที่ใช้การยกกำลัง (Power Transformation)

กรณีที่มีความคลาดเคลื่อนมีการแจกแจงแบบเบ้จะทำการแปลงข้อมูล โดยการแปลงที่ใช้การยกกำลัง เพื่อที่จะทำให้ข้อสมมติของความเป็นปกติใช้ได้ ซึ่งในปี ค.ศ. 1964 บ็อกซ์ (Box) และคอกซ์ (Cox) ได้เสนอการแปลงข้อมูลซึ่งอยู่ในรูปของ

$$y_i^{(\lambda)} = \begin{cases} \frac{y_i^{(\lambda)} - 1}{\lambda} & ; \lambda \neq 0 \\ \ln y_i & ; \lambda = 0 \end{cases}$$

ซึ่งการแปลงรูปตัวแปรตามในลักษณะนี้ทำให้ $y_i^{(\lambda)}$ มีการแจกแจงปกติโดยประมาณซึ่งขั้นตอนการแปลงรูปมีดังนี้

1) จากสมการ $\underline{y} = X\underline{\beta} + \underline{\varepsilon}$ ค่ามัธยฐานเรขาคณิต (geometric mean) ของ \underline{y} ได้จาก $G = \sqrt[n]{y_1 y_2 \dots y_n}$ มาหาร y_i $i = 1, 2, \dots, n$ ทำให้ได้ $y_{i^*} = y_i / G$; $i = 1, 2, \dots, n$ และจะได้ว่า $\sum_{i=1}^n \ln(y_{i^*}) = 0$

2) จากสมการ $\frac{y_{i^*}^{(\lambda)} - 1}{\lambda} = X\underline{\beta} + \underline{\varepsilon}$ ซึ่ง บอห์นและคอกซ์ ถือว่ากรณีเช่นนี้ $\underline{\varepsilon} \sim N(0, \sigma^2)$ ดังนั้นฟังก์ชันความหนาแน่นร่วมของ \underline{y} คือ

$$\left(\frac{1}{2\pi\sigma^2}\right)^{\frac{n}{2}} \exp\left[-\frac{1}{2\sigma^2} \sum_{i=1}^n (y_{i^*}^{(\lambda)} - X' \underline{\beta})^2\right] \cdot J$$

เมื่อ J คือ จาโคเบียนของการแปลงจากตัวแปร y_{i^*} เป็น $y_{i^*}^{(\lambda)}$ ดังนั้น

$$J = \prod_{i=1}^n y_{i^*}^{(\lambda-1)}$$

จะได้ว่า ฟังก์ชัน log-likelihood อยู่ในรูปของ

$$\ln L = \frac{n}{2} \ln(2\pi) - \frac{n}{2} \ln \sigma^2 - \frac{1}{2\sigma^2} \sum_{i=1}^n (y_{i^*}^{(\lambda)} - X' \underline{\beta})^2$$

ทำการถอดลอการิทึม $y_{i^*}^{(\lambda)}$ บน X_i และคำนวณผลรวมกำลังสองของค่าความคลาดเคลื่อน $\hat{\sigma}^2(\lambda)$ โดยที่

$$\hat{\sigma}^2(\lambda) = \frac{1}{n} (\underline{y}^{(\lambda)} - X \hat{\underline{\beta}}(\lambda))' (\underline{y}^{(\lambda)} - X \hat{\underline{\beta}}(\lambda))$$

3) เลือกค่า λ ที่ให้ค่า $\hat{\sigma}^2(\lambda)$ ที่น้อยที่สุด จะได้ λ ที่เป็น maximum likelihood ของ λ

จุฬาลงกรณ์มหาวิทยาลัย