

2 模糊線性迴歸的介紹

2.1 模糊數及其運算

現今科學所欲研究物件之結構複雜性日益增加，人類的知識語言因本身的主觀意識、不同時間、環境的變遷，使得科學家無法清楚研究物件的真實本質，因此透過建立適當的數學模式，對於一些較無確定性的資料給予一個集合，稱之為模糊數。

利用隸屬度函數可以描述模糊數的性質，他是模糊理論的最基本概念，透過隸屬度函數，我們才能對模糊數進行量化，也才有可能利用精準的數學方法，去分析和處理模糊性的資訊。通常隸屬度函數的定義方式可以分成數值及函數兩種：數值定義方式又稱為離散化(discretization)隸屬度函數，他是直接給定有限模糊集合內每個元素的隸屬度。函數定義的方式又可稱為連續化(continuous)隸屬度函數，函數定義的表現，可以是無限模糊集合的元素及其隸屬度之間的關係，也可以是有限模糊集合的元素及其隸屬度之間的關係，但在處理實際問題上僅討論有限的情況。以下是具有相同類型隸屬度函數之模糊數的運算，其定義為：

定義 2.1 設 $A = (m_a, \alpha_a, \beta_a), B = (m_b, \alpha_b, \beta_b), \lambda \in \mathbb{R}^+$ ，其中 m_a, m_b 為中心， α_a, α_b 與 β_a, β_b 分別為左右分展度，且 A 與 B 有相同類型的隸屬度函數，則我們有以下的運算：

$$1. A + B = (m_a + m_b, \alpha_a + \alpha_b, \beta_a + \beta_b)$$

$$2. \lambda A = (\lambda m_a, \lambda \alpha_a, \lambda \beta_a)$$

即兩個模糊數相加的結果，為中心與中心相加，左分展度與右分展度相加；若一個大於零的數乘上一個模糊數，則分別為中心和左右分展度分別乘上此正數。但是在此，我們無法定義出一個模糊數乘上一個小於零的實數，也因

此無法定義出模糊數之間的減法。我們需要一套尋找模糊數間距離的方法，在2.3節中將介紹常見模糊數間距離的定義。

2.2 一般模糊線性迴歸模型

考慮下列的模糊線性迴歸模型，爲了方便起見稱其爲模型I：

$$\text{模型I } y_i = A_0 + A_1x_{i1} + A_2x_{i2} + \dots + A_px_{ip}, \quad i = 1, 2, \dots, n \quad (2.1)$$

其中自變數值 x_{ij} 爲實數，應變數值 $y_i = [c_i - s_i, c_i + s_i]$ 爲模糊數，且 c_i 爲資料中心， s_i 爲資料分展度， $A_m = [a_m - r_m, a_m + r_m]$ 是模糊迴歸參數，具有和 y_i 相同的隸屬度函數。在沒有模糊數距離概念下，我們如何估計 A_m 呢？首先將 $y_{Li} = c_i - s_i, y_{Ri} = c_i + s_i$ 視爲樣本的左右端點。對左端點 $\{(y_{Li}, x_{i1}, x_{i2}, \dots, x_{ip}) | i = 1, 2, \dots, n\}$ 資料 (右端點 $\{(y_{Ri}, x_{i1}, x_{i2}, \dots, x_{ip}) | i = 1, 2, \dots, n\}$ 資料) 配置線性模型 $y = \beta_0 + \beta_1x_1 + \dots + \beta_px_p$ ，分別得到：

$$\hat{y}_{Li} = \hat{L}_0 + \hat{L}_1x_{i1} + \hat{L}_2x_{i2} + \dots + \hat{L}_px_{ip}, \quad i = 1, 2, \dots, n$$

$$\hat{y}_{Ri} = \hat{R}_0 + \hat{R}_1x_{i1} + \hat{R}_2x_{i2} + \dots + \hat{R}_px_{ip}, \quad i = 1, 2, \dots, n$$

則 $\hat{A}_m = [\hat{a}_m - \hat{r}_m, \hat{a}_m + \hat{r}_m]$ 其中 $\hat{a}_m = \frac{\hat{L}_m + \hat{R}_m}{2}$, $\hat{r}_m = \frac{|\hat{R}_m - \hat{L}_m|}{2}$ 。如此方法所得到的結果，相當直觀而且好處理，不過其缺點是太注重於左右端點值，完全忽略了隸屬度函數描述資料的功能，這樣的估計方式有失”模糊”的概念。若在使用最小平方法時，能加入模糊數間距離的概念，或許可得到模糊迴歸參數 A_m 更適當的估計。

2.3 簡單距離公式

爲了得到(2.1)式模型I中，模糊迴歸參數的最小平方估計，我們必須考慮模糊數間的距離。

定義2.2 (簡單距離公式) 設 $A = (c_a, s_a), B = (c_b, s_b)$ 是對稱形式的模糊數，其中 c_a, c_b 為中心， s_a, s_b 為分展度，則 A 與 B 間的距離 D 為：

$$D = \sqrt{(c_a - c_b)^2 + (s_a - s_b)^2} \quad (2.2)$$

若 $A = (c_a, p_a, q_a), B = (c_b, p_b, q_b)$ 是不對稱形式的模糊數，其中 c_a, c_b 為中心， p_a, p_b 為左分展度， q_a, q_b 為右分展度，則 A 與 B 之間的距離 D 為：

$$D = \sqrt{(c_a - c_b)^2 \pi_c + (p_a - p_b)^2 \pi_p + (q_a - q_b)^2 \pi_q} \quad (2.3)$$

其中 π_c, π_p 與 π_q 分別為任意正的比重。

在上述的距離公式中，若模糊數為對稱形式，則距離為中心減去中心的平方，加上分展度減去分展度平方，再開根號。若模糊數為不對稱形式，則距離為中心減去中心的平方，加上左右分展度差的平方，並分別在中心與左右分展度處乘上一個正的比重後再開根號。在不對稱的距離公式中，需加上對模糊距離的主觀判斷，給予中心與分展度一個適當的比重。由於上述模糊數間的距離公式，只考慮到模糊數的中心與分展度，稱其為簡單距離公式，以便和3.1節中Yang和Ko的距離公式做一區隔。

在有了模糊數的距離定義後，可考慮用最小平方法對(2.1)式的傳統模糊線性迴歸進行參數估計。假設 $y_i = (c_i, s_i)$ 與 $A_m = (a_m, r_m)$ 具有相同的隸屬度函數，且經過適當的平移後可使得所有 $x_{ij} > 0$ 。(2.1)式可表示為：

$$(c_i, s_i) = (a_o, r_o) + (a_1, r_1)x_{i1} + (a_2, r_2)x_{i2} + \dots + (a_p, r_p)x_{ip}$$

在(2.2)式的簡單距離定義下， a_i, r_i 的最小平方估計，即為使 D^2 最小之 a_i, r_i 值：

$$D^2 \equiv \sum_{i=1}^n (c_i - (a_o + a_1 x_{i1} + \dots + a_p x_{ip}))^2 + (s_i - (r_o + r_1 x_{i1} + \dots + r_p x_{ip}))^2$$

令 $\|v\|$ 表示向量 v 的長度，上述式子若以向量及矩陣表達，在處理上會更方便，經改寫後可得：

$$D^2 = \|Xa - C\|^2 + \|Xr - S\|^2$$

其中 $X = (x_{ij})$ 是 $n \times (p+1)$ 的自變數值矩陣且 $a = (a_0, a_1, \dots, a_p)'$, $r = (r_0, r_1, \dots, r_p)'$, $C = (c_1, c_2, \dots, c_n)'$, $S = (s_1, s_2, \dots, s_n)'$ 。令 $\frac{\partial D^2}{\partial a} = 0$ 與 $\frac{\partial D^2}{\partial r} = 0$ ，可得 a 與 r 的解如下：

$$\begin{aligned}\hat{a} &= (X'X)^{-1}X'C \\ \hat{r} &= (X'X)^{-1}X'S\end{aligned}\quad (2.4)$$

簡單的說，這種處理方式相當於對中心和分展度分別做迴歸，所獲得的估計結果自然和隸屬度函數無關，但實例分析上又呈現出這種估計結果較其他方法為佳。

2.4 對稱和不對稱雙重模糊線性迴歸模型

在模型 I 的架構下，若使用最小平方方法與簡單距離公式，所獲得最小平方估計的結果是中心與分展度分別做迴歸，該結果顯示中心與分展度無任何關聯，但 D'Urso 和 Gastaldi (2000) 認為模糊數之中心與其分展度，常存在一些相關性，因此提出以下雙重模糊線性迴歸模型 (簡稱模型 II)，並將應變數 $y_i = [c_i - s_i, c_i + s_i]$ 考慮為對稱三角形模糊數。

$$\text{模型 II} \quad C = C^* + \varepsilon_c \quad C^* = Xa \quad (2.5)$$

$$S = S^* + \varepsilon_s \quad S^* = C^*b + \mathbf{1}d \quad (2.6)$$

其中 $C = (c_1, c_2, \dots, c_n)'$, $S = (s_1, s_2, \dots, s_n)'$, a 是 $(p+1) \times 1$ 的參數向量， $\mathbf{1}$ 是每一分量皆為 1 的 $n \times 1$ 向量， b, d 是第二迴歸模型參數。模型 II 的結構是先對中心的部份建立起核心迴歸模型 (core regression model)，再利用核心迴歸模型，對分展度的部份建立起與中心有關的分展度迴歸模型 (spread regression model)。

D'Urso 和 Gastaldi 利用最小平方方法以及 (2.2) 的簡單距離公式，求參數 a, b, d 使誤差平方和

$$\begin{aligned}D^2 &\equiv \|C - C^*\|^2 + \|S - S^*\|^2 \\ &= C'C - 2C'Xa + a'X'Xa(1 + b^2) + S'S \\ &\quad - 2S'Xab - 2S'\mathbf{1}d + 2a'X'\mathbf{1}bd + nd^2\end{aligned}$$

最小。令 $\frac{\partial D^2}{\partial a} = 0$, $\frac{\partial D^2}{\partial b} = 0$ 與 $\frac{\partial D^2}{\partial d} = 0$ 可得下列的方程式：

$$\begin{aligned}\frac{\partial D^2}{\partial a} &= -X'C + X'Xa(1+b^2) - X'Sb + X'\mathbf{1}bd = 0 \\ \frac{\partial D^2}{\partial b} &= a'X'Xab - S'Xa + a'X'\mathbf{1}d = 0 \\ \frac{\partial D^2}{\partial d} &= -S'\mathbf{1} + a'X'\mathbf{1}b + nd = 0\end{aligned}\quad (2.7)$$

並由上述的方程式，求得 a, b 與 d 的遞迴關係式如下：

$$\begin{aligned}a &= \frac{1}{1+b^2}((X'X)^{-1}X'(C + rb - \mathbf{1}bd)) \\ b &= (a'X'Xa)^{-1}(r'Xa - a'X'\mathbf{1}d) \\ d &= \frac{1}{n}(r'\mathbf{1} - a'X'\mathbf{1}b)\end{aligned}\quad (2.8)$$

事實上，我們可由 (2.7) 式解出 a, b, d 的通解，其過程如下：

由 (2.7) 的第 1 個方程式知 $a = \frac{1}{1+b^2}((X'X)^{-1}X'(C + Sb - \mathbf{1}bd))$ ，將其代入 (2.7) 的第 2 及第 3 個方程式，可得：

$$\|\hat{C}\|^2 b + C'\hat{S}b^2 - n\bar{C}b^2d - S'\hat{C} - \|\hat{S}\|^2 b + 2n\bar{S}bd + n\bar{C}d - nbd^2 = 0 \quad (2.9)$$

$$b\bar{C} - \bar{S} + d = 0 \quad (2.10)$$

其中 $X(X'X)^{-1}X'C = \hat{C}$, $X(X'X)^{-1}X'S = \hat{S}$, $\frac{1}{n}\mathbf{1}'C = \bar{C}$, $\frac{1}{n}\mathbf{1}'S = \bar{S}$ 。由 (2.10) 可得 $d = \bar{S} - b\bar{C}$ ，再將其代回 (2.9) 式中，則可以簡化成一個 b 的二次方程式：

$$M_1b^2 + M_2b + M_3 = 0$$

其中 $M_1 = C'\hat{S} - n\bar{C}\bar{S}$, $M_2 = \|\hat{C}\|^2 - \|\hat{S}\|^2 + n\bar{S}^2 - n\bar{C}^2$, $M_3 = n\bar{C}\bar{S} - S'\hat{C}$ 。解上述二次方程式可得：

$$\hat{b} = \frac{-M_2 \pm \sqrt{M_2^2 - 4M_1M_3}}{2M_1}$$

所對應的 a, d 為：

$$\begin{aligned}\hat{d} &= \bar{S} - \hat{b}\bar{C} \\ \hat{a} &= \frac{1}{1+\hat{b}^2}((X'X)^{-1}X'(c + r\hat{b} - \mathbf{1}\hat{b}\hat{d}))\end{aligned}$$

亦有兩組解，將兩組 $\hat{a}, \hat{b}, \hat{d}$ 之值代回 D^2 中，找出使誤差平方和 D^2 較小的即為最小平方估計。由 a, b, d 的估計式可看出，無論應變數部份是何種形態的模糊數，所獲得的參數估計結果都相同，因此在簡單距離公式下所得到的最小平方估計，無法適度反映模糊數的形態。

在模糊應變數 $y_i = [c_i - q_i, c_i + p_i]$ 為非對稱三角形的情況下，D'Urso(2001) 提出以下的模糊線性迴歸模型，為了方便起見稱其為模型 III：

$$\begin{aligned} \text{模型 III} \quad C &= C^* + \varepsilon & C^* &= Xa \\ p &= p^* + \lambda & p^* &= C^*b + \mathbf{1}d \\ q &= q^* + \rho & q^* &= C^*g + \mathbf{1}h \end{aligned} \quad (2.11)$$

式中 $C = (c_1, c_2, \dots, c_n)'$, $p = (p_1, p_2, \dots, p_n)'$, $q = (q_1, q_2, \dots, q_n)'$, a 是 $(p+1) \times 1$ 的參數向量， $\mathbf{1}$ 是每一分量皆為 1 的 $n \times 1$ 向量， b, d, g, h 是第二迴歸模型參數。模型 III 可稱為不對稱的雙重模糊線性迴歸模型。

D'Urso 在 (2.3) 的簡單距離公式下，利用最小平方法，導出 a, b, d, g, h 的最小平方估計滿足下面的遞迴關係式：

$$\begin{aligned} a &= \frac{1}{\pi_c + b^2\pi_p + g^2\pi_q} [(X'X)^{-1}X'(c\pi_c + (p - \mathbf{1}d)b\pi_p) + (q - \mathbf{1}h)g\pi_q] \\ b &= (a'X'Xa)^{-1}(a'X'p - a'X'\mathbf{1}d) \\ d &= \frac{1}{n}(p'\mathbf{1} - a'X'\mathbf{1}b) \\ g &= (a'X'Xa)^{-1}(a'X'q - a'X'\mathbf{1}h) \\ h &= \frac{1}{n}(q'\mathbf{1} - a'X'q - a'X'\mathbf{1}h) \end{aligned} \quad (2.12)$$

由 (2.12) 的遞迴關係式，可看出模型 III 的參數估計和 π_c, π_p, π_q 權重的選取有密切關係，這不是一套客觀的處理方式，同時由 (2.12) 也可看出參數估計的結果和隸屬度函數無關，因此在下一章中，我們將設法獲得客觀並與隸屬度函數有關聯的最小平方估計。