

## บทที่ 6 Chemometric

ในปัจจุบัน การวัดแสง NIR เป็นเทคนิคการวิเคราะห์ ซึ่งส่วนใหญ่นำมาประยุกต์ใช้กับ Chemometric Chemometric คือการใช้คณิตศาสตร์และเทคนิคทางสถิติสำหรับการแปลผลข้อมูลจากข้อมูลที่ทำกรวิเคราะห์ กรณีนี้คือสเปกตรัม NIR [12] ทั้ง Chemometric และ เทคโนโลยี NIR เอื้อประโยชน์ซึ่งกันและกัน โครงร่างในการสร้างแบบจำลองข้อมูลทางเคมีคือ แนวความคิดที่ว่าสัญญาณที่วัดได้แสดงถึงปรากฏการณ์ทางเคมี (ข้อมูล) สามารถแบ่งได้เป็นสอง ส่วน คือ ระบบ (เกิดจากจุดเด่นทางเคมี) และ ไม่ใช่ระบบ (สัญญาณรบกวน) จากแนวความคิดนี้ทำให้สร้างแบบจำลองได้ง่ายขึ้น โดยมีพื้นฐานอยู่บนข้อมูลที่วัดได้ ซึ่งได้แก่

$$\text{ข้อมูล} = \text{แบบจำลองเคมี} + \text{สัญญาณรบกวน}$$

แบบจำลองส่วนใหญ่ที่ถูกนำมาใช้สำหรับการสอบเทียบสเปกตรัมข้อมูลคือ แบบจำลองกำลังสองน้อยที่สุด (Least Squares) ใช้ธิบายตัวแปรกับความยาวคลื่นที่เลือกมา โดยการทำให้กำลังสองของค่าความผิดพลาดน้อยที่สุด ตามปกติแบบจำลองกำลังสองน้อยที่สุดจะไม่เป็นไปตามอุดมคติ เนื่องจากการตอบสนองไม่เป็นเชิงเส้น การประมาณค่า Beer-Lambert สัญญาณรบกวนที่เกิดขึ้น ความสัมพันธ์ระหว่างตัวแปร โดยสมการทำนายนั้นสามารถเขียนได้ตามสมการที่ (6.1) [12, 13]

$$C = K_1 + K_2 \log\left(\frac{1}{R_{\lambda 1}}\right) + K_3 \log\left(\frac{1}{R_{\lambda 2}}\right) + \dots \quad (6.1)$$

โดยที่  $C$  คือค่าความเข้มข้นขององค์ประกอบที่สนใจ

$R_{\lambda 1}, R_{\lambda 2}, R_{\lambda 3}, \dots$  คือค่าการดูดกลืนที่แต่ละความยาวคลื่น ซึ่งสอดคล้องกับการประมาณค่าเชิงเส้นตามกฎ Beer-Lambert

$K_1, K_2, K_3, \dots$  คือค่าคงตัว

วิธีการเพื่อจะอธิบายการแยกข้อมูลเป็นองค์ประกอบที่ตั้งฉากกัน (Orthogonal component) โดยคำว่า Orthogonal หมายถึงไม่มีความสัมพันธ์กันโดยสิ้นเชิง ในกรณีของการสอบเทียบ ปัญหาของการทำ  $(XX')^{-1}$  ถูกเฉลยโดยการแปลง  $X$  ให้อยู่ในรูปของส่วน orthogonal ขึ้นตอนนี้ทำการแปลงให้เป็น  $XX'$  หรือทำการรวมกันของ covariance ของเมตริกซ์ หรือการสร้างเมตริกซ์ที่แยงมุม ซึ่งทำให้สามารถทำการอินเวอร์สเพื่อหาคำตอบได้ วิธีการโปรเจกชันแบบตั้งฉาก (Orthogonal projection) มีประโยชน์ในการแปลผลข้อมูล วิธีการนี้ยังเหมาะในการตรวจสอบในแบบรูปภาพ เพราะข้อมูลถูกฉายลงบน ไม่ก็แกนที่ไม่มีมีความสัมพันธ์กันและมีขอบเขต

ซึ่งง่ายในการแปลผลข้อมูลมากกว่าข้อมูลต้นแบบ ความเป็นไปได้ในการแสดงจุดเด่นของข้อมูล เป็นข้อได้เปรียบหนึ่งของเทคนิคตัวแปรพหุพจน์ (Multivariate) [12]

โดยทั่วไป การสร้างแบบจำลององค์ประกอบเด่นของสเปกตรัมกับสิ่งที่สนใจ ด้วยการสร้าง transfer function  $f(i)$  ระหว่างข้อมูลที่สังเกตได้และที่วัดได้ แบบจำลองที่เป็นไปได้คือ

$$Y = f(X) + E \quad (6.2)$$

หรือ

$$X = f(Y) + E' \quad (6.3)$$

โดยวิธีการพื้นฐานทั่วไปคือ การทำให้ผลรวมกำลังสองของเศษเหลือ ( $E, E'$ ) เกิดน้อยที่สุด ส่วนใหญ่ การสร้างแบบจำลองข้อมูลสเปกตรัม ยังคงเป็นแบบจำลองกำลังสองน้อยที่สุดเชิงเส้นตัวแปรเดียว โดยเลือกตัวแปรเดียวหรือที่ความยาวคลื่นหนึ่งมาสร้างแบบจำลองเพื่ออธิบายสิ่งที่สนใจ

## 6.1 การแปลผลข้อมูล

การแปลผลข้อมูลทำตามแนวความคิดของ Chemometric โดยใช้แบบจำลองกำลังสองน้อยที่สุด ซึ่งสามารถแยกได้เป็น 2 วิธีคือ Classical Least Squares และ Inverse Least Squares โดยตามแนวความคิดของ Classical Least Squares คือ การหาสเปกตรัมจากความเข้มข้นองค์ประกอบของตัวอย่างที่ทำกรวิเคราะห์ หรือสร้างแบบจำลองอธิบายสเปกตรัมในรูปตัวแปรความเข้มข้นขององค์ประกอบ ส่วน Inverse Least Squares เป็นการสร้างแบบจำลองอธิบายองค์ประกอบในรูปของสเปกตรัมการดูดกลืน ซึ่งจะนำมาใช้ในการแปลผลข้อมูลความชื้นจากสเปกตรัม

### 6.1.1 แบบจำลองกำลังสองน้อยที่สุด [12]

คำตอบของแบบจำลองกำลังสองน้อยที่สุดมีความน่าสนใจ เนื่องจากมีการใช้อย่างกว้างขวางในการสร้างแบบจำลองข้อมูลทางคณิตศาสตร์ แม้ว่ากำลังสองน้อยที่สุดจะถูกจัดอยู่ใน Chemometric แต่ไม่ใช่วิธี orthogonal compression ในการวัดและวิเคราะห์สเปกตรัมนั้น มีอยู่สองวิธีในการสอบเทียบข้อมูลแบบหลายตัวแปรโดยตรง คือ Classical Least Squares (CLS) และ Inverse Least Squares (ILS) ทั้งสองวิธีมีสมการทางคณิตศาสตร์ร่วมกัน แต่มีหลักการที่ต่างกันคือ การสร้างแบบจำลองเชิงเส้นเพื่อทำนาย “pure spectrum” หรือการหาค่าสัมประสิทธิ์การถดถอย ซึ่งสามารถทำนายสิ่งที่สนใจได้จากสเปกตรัม ต้นกำเนิดของทฤษฎีกำลังสองน้อยที่สุดสามารถย้อนกลับไปยัง Gauss และ Legendre (ยุค 1700)

### 6.1.1.1 Classical Least Squares (CLS)

หลักการของ Classical Least Squares (CLS) กล่าวไว้ว่า ตัวแปร  $X$  (สเปกตรัม) เป็นฟังก์ชันของสิ่งที่เราสนใจ  $Y$  (ค่าความเข้มข้นของสิ่งที่สนใจ) วิธีการคือเพื่อลดเศษเหลือใน  $X$  ให้น้อยที่สุด

$$\min([X - YK])^2$$

แบบจำลองของ CLS คือ

$$X = YK + E \quad (6.4)$$

โดยคำตอบจากกำลังสองน้อยที่สุดสามารถหาได้เป็น

$$\hat{K} = (Y^T Y)^{-1} Y^T X \quad (6.5)$$

โดย  $\hat{K}$  ประกอบด้วยส่วนที่เกี่ยวข้องกับสเปกตรัมหรือส่วนประกอบเชิงเส้นของ  $X$  เพื่อทำการวิเคราะห์  $Y$  ซึ่งหมายความว่า CLS เป็นแบบหนึ่งของแบบจำลองแฟคเตอร์ (Factor model) เนื่องจากเมตริกซ์  $X$  ถูกแยกตัวประกอบเป็น  $\hat{K}$  ได้โดย  $Y$  การทำนายในแบบจำลอง CLS สามารถทำได้โดย

$$c = (K K^T)^{-1} K^T x \quad (6.6)$$

โดยที่  $x$  คือสเปกตรัมของตัวอย่างที่ไม่รู้ค่าที่เราสนใจ  $K$  หาได้จากสมการ และ  $c$  คือความเข้มข้นของสิ่งที่เราสนใจ

ข้อดีที่เห็นได้ชัดเจนคือ ต้องรู้ค่าของสเปกตรัมและสิ่งรบกวนในการใช้วิธีนี้ โดยสมการของ CLS เหมาะในการประมาณค่าออกช่วง CLS นั้นเป็นที่รู้จักกันในชื่อ K-matrix หรือ Reverse- Direct- และ Total calibration

### 6.1.1.2 Inverse Least Squares (ILS)

ตัวอย่างของ Inverse Least Squares ที่ใช้กันเช่น สมการถดถอยหลายตัวแปร (Multiple Linear Regression) Partial Least Squares (PLS) และอื่นๆ

#### 6.1.1.2.1 สมการถดถอยหลายตัวแปร (MLR)

วัตถุประสงค์ของฟังก์ชันเพื่อจะลดเศษเหลือในตัวแปร  $Y$  ให้น้อยที่สุด โดยที่  $X$  คือเมตริกซ์ของค่าการดูดกลืน  $Y$  คือเมตริกซ์ความเข้มข้นขององค์ประกอบ ในที่นี้คือเปอร์เซ็นต์ความชื้นในแป้ง

$$\min([Y - X\beta]^2)$$

แบบจำลอง คือ

$$Y = X\beta + E \quad (6.7)$$

โดยที่  $E$  คือเมตริกซ์ของค่าความผิดพลาด ซึ่งสามารถเขียนสมการใหม่ได้เป็น

$$\begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} 1 & X_{1,2} & X_{1,3} & \cdots & X_{1,j} \\ 1 & X_{2,2} & X_{2,3} & \cdots & X_{2,j} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & X_{n,2} & X_{n,3} & \cdots & X_{n,j} \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_j \end{bmatrix} + \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_n \end{bmatrix} \quad (6.8)$$

โดยเราสามารถประมาณค่า  $\beta$  ได้ดังนี้

$$\hat{\beta} = (X^T X)^{-1} X^T Y \quad (6.9)$$

เมื่อนำเอา  $\beta$  ซึ่งคือเวกเตอร์ถดถอยมาคูณกับสเปกตรัม ทำให้เราสามารถทำนายเป้าหมายที่สนใจ  $\hat{y}$  โดยเป็นไปตามสมการ

$$\hat{y} = \beta(1)x(1) + \beta(2)x(2) + \dots + \beta(p)x(p) \quad (6.10)$$

หรือ

$$\hat{y} = x\beta \quad (6.11)$$

โดยที่  $\beta(1)$  เป็นสัมประสิทธิ์ตัวแรกของเวกเตอร์  $\beta$  และ  $x(1)$  เป็นข้อมูลสเปกตรัมความยาวคลื่นแรกของตัวอย่างที่ไม่รู้ค่าขององค์ประกอบที่เราสนใจ ILS สามารถนำมาใช้กับข้อมูลที่มีสิ่งเจือปนอื่นในตัวอย่างที่เราสนใจได้ แต่สิ่งที่เป็จุดเด่นของข้อมูลที่จะถูกทำนายนั้น คือนำมาใช้ในการสร้างแบบจำลองสอบเทียบด้วย วิธี ILS นั้น รู้จักกันเป็น P-matrix MLR Forward-Indirect- และ Partial calibration

#### 6.1.1.2.2 สหสัมพันธ์ร่วม (Co-correlation) และการอินเวอร์ส

ปัญหาหลักในการหาสัมประสิทธิ์ถดถอยเพื่อทำการวิเคราะห์ปัญหาในแบบจำลองคือ ความเกี่ยวข้องกับธรรมชาติในการอินเวอร์สเมตริกซ์ของ variance-covariance การแก้เมตริกซ์  $(XX^T)^{-1}$  เป็นกุญแจสำคัญสำหรับการสอบเทียบ ถ้าเมตริกซ์  $X$  มีสหสัมพันธ์ภายในและภายนอก (Intercorrelation, Intracorrelation) แล้ว ข้อมูลจะมีความเป็นเชิงเส้นร่วมกันสูงหรือการเป็นส่วนประกอบเชิงเส้นของกันและกัน ทำให้เกิดปัญหาในการอินเวอร์สเมตริกซ์คือ อาจไม่สามารถทำการอินเวอร์สได้ ส่วนการมีสหสัมพันธ์ร่วม (Co-correlation) นั้นทำให้เมตริกซ์มี rank เพิ่มขึ้น และเกิดตัวเลขที่ค่ามากในแนวทแยงมุม และเกือบเป็นเมตริกซ์ทแยงมุม ทำให้ค่าที่ได้จากการอินเวอร์สเกิดความไม่เสถียร คือค่าที่ได้จะมีความไวต่อสัญญาณรบกวน

แต่จากมุมมองของนักเคมีแล้ว ปัญหาจากการมีความสัมพันธ์เชิงเส้น (Co-linearity) นั้นไม่ใช่ปัญหาเพียงแค่มียังน้อยหนึ่งตัวแปรที่สามารถอธิบายองค์ประกอบที่สนใจได้ ส่วนการมีสหสัมพันธ์ร่วม (Co-correlation) แสดงว่า มีข้อมูลมากพอเพื่อใช้ในการอธิบายโดยที่ควรใช้

กระบวนการทางคณิตศาสตร์ให้ถูกต้องในการแก้ปัญหา โดยประมาณค่าที่ให้กำลังสองของค่าความผิดพลาดน้อยที่สุด โดยค่าส่วนใหญ่ที่นำมาพิจารณาใช้ในการสร้างสมการทำนายได้แก่

- Sum of Squares

$$SSR = \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2 \quad (6.12)$$

$$SST = \sum_{i=1}^n (Y_i - \bar{Y})^2 \quad (6.13)$$

โดย SSR คือ Sum of Squares of Regression เป็นค่าความแปรผันที่เกิดจากแบบจำลอง SST คือ Sum of Squares of Total เป็นค่าความแปรผันของข้อมูลกับค่าเฉลี่ยของตัวเอง  $\bar{Y}$  คือค่าเฉลี่ยของค่าที่ได้จากการทดลองตามวิธีมาตรฐาน  $\hat{Y}$  คือค่าที่ทำนายได้ และ  $Y$  คือค่าที่ได้จากการทดลองตามวิธีมาตรฐาน เราสามารถนำค่านี้มาใช้ในการหาค่า Coefficient of Determination ( $R^2$ ) หรือค่าความสัมพันธ์ระหว่างค่า  $Y$  ที่ได้จากสมการและค่าที่ได้จากวิธีมาตรฐาน โดยให้ค่าใกล้เคียงกับ 1 ให้มากที่สุด โดยสามารถหาได้จาก

$$R^2 = SSR / SST \quad (6.14)$$

ค่าที่ใช้ในการประเมินความสามารถในการทำนายของสมการ ยกตัวอย่างเช่น Standard error of calibration (SEC) ซึ่งใช้ในการประเมินความสามารถในการทำนายของสมการเมื่อใช้กับกลุ่มที่ทดลอง และ Standard error of prediction (SEP) ซึ่งใช้ในการประเมินความสามารถของสมการ เมื่อเทียบกับตัวอย่างนอกกลุ่มทดลอง โดยทั้ง SEC และ SEP ควรมีค่าน้อยที่สุด

- Standard error of calibration

$$SEC = \sqrt{\sum_{i=1}^n \frac{(\hat{Y}_i - Y_i)^2}{n - f - 1}}$$

โดยค่า  $\hat{Y}$  คือค่าที่คำนวณได้จากสมการทำนาย  $n$  คือจำนวนตัวอย่าง  $f$  คือจำนวนตัวแปรหรือจำนวนค่าการคูณที่ความยาวคลื่นต่างๆ หรือจำนวนแฟกเตอร์ในกรณี Principal Component Analysis (PCA) หรือ Partial Least Squares (PLS)

- Standard error of prediction

$$SEP = \sqrt{\sum_{i=1}^n \frac{(\hat{Y}_i - Y_i - bias)^2}{n - 1}}$$

ค่า  $bias$  นั้นคือค่าเฉลี่ยของค่าความผิดพลาด

เนื่องจากการมีความสัมพันธ์กันระหว่างสิ่งที่สนใจ  $Y$  และข้อมูลสเปกตรัม และความสัมพันธ์ระหว่างตัวแปรด้วยกันเป็นไปตามทฤษฎีของ NIR เนื่องจากจุดยอดของสเปกตรัม

นั้นกว้างและซ้อนทับกัน จึงทำให้เกิดปัญหาเกี่ยวกับทฤษฎีของ ILS ในการสอบเทียบข้อมูลกับสิ่งที่สนใจ PLS เป็นวิธีการเพื่อทำให้ค่าความแปรปรวนร่วมกำลังสองระหว่าง  $X$  และ  $Y$  มีค่าสูงสุด

$$\max_w [\text{cov}(t, y) | t = Xw \wedge \|w\| = 1]$$

โดย PLS จะทำให้  $X$  และ  $Y$  อยู่ในรูปขององค์ประกอบที่ตั้งฉาก (Orthogonal component) โดยวิธีนี้ทำให้

$$\|\beta\|_{2,PLS} < \|\beta\|_{2,ILS} \quad \text{ถ้า } a < \min(n,p) \quad (6.15)$$

จากความสัมพันธ์ จะเห็นได้ว่า สัมประสิทธิ์ถดถอยของ PLS มีความเสถียรกว่า ILS โดยที่ความสัมพันธ์นี้เป็นจริงก็ต่อเมื่อมีจำนวนน้อยกว่าจำนวนตัวแปร PLS นั้น มีอยู่สองโครงสร้างแบบจำลองแรก PLS1 สำหรับอธิบายสิ่งที่สนใจเพียงหนึ่งตัว และอีกแบบจำลอง PLS2 สำหรับหลายตัวพร้อมกัน

### 6.1.1.2.3 Partial Least Squares(PLS) [8, 12]

PLS ใช้หลักการพื้นฐานของวิธีแฟกเตอร์ ทำการแยกข้อมูลออกเป็นองค์ประกอบที่เป็นอิสระจากกัน โดยจะต่างจากวิธีของ MLR ซึ่งอาจมีปัญหาในการอินเวอร์สเพื่อแก้สมการ และสมการที่ได้อาจจะไม่มีเสถียรภาพ PLS นั้นจะทำการประมาณค่าในส่วนของทั้ง  $X$  และ  $Y$  และสร้างความสัมพันธ์ไปพร้อมกัน โดยใช้แฟกเตอร์ในการหาองค์ประกอบหลัก (Principal component) ในการแยกองค์ประกอบหลักเริ่มต้นจาก

$$w = X^T y (y^T y)^{-1} \quad (6.16)$$

โดยที่  $X = yw^T + E$  เมื่อ  $w$  คือ เวกเตอร์ถ่วงน้ำหนัก (Weights vector)  $E$  คือเศษเหลือ หลังจากนั้นทำการนอร์มอลไลซ์  $w$  และหาสกออร์แฟกเตอร์ (Score factor,  $t$ )

$$t = Xw \quad (6.17)$$

ซึ่ง  $w^T = I$  และ  $X = tw^T + E$  และหลังจากนั้นทำการสอบเทียบในส่วนของบล็อก  $Y$

$$q = y^T t (t^T t)^{-1} \quad (6.18)$$

เมื่อ  $y = tq^T + e$  โดย  $q$  คือเวกเตอร์ใช้เป็น  $y$ -loading หลังจากนั้นทำการสอบเทียบสเปกตรัมกับส่วนของสกออร์แฟกเตอร์

$$p = X^T t (t^T t)^{-1} \quad (6.19)$$

โดยที่  $X = tp^T + E$  ซึ่ง  $p$  คือตัวโหลดคั้ง (Loading) หรือองค์ประกอบบริสุทธิ์ (Pure component) หลังจากนั้น ทำการลบองค์ประกอบออกจากข้อมูล โดยสมการที่ (6.20), (6.21)

$$X = X - tp^T \quad (6.20)$$

$$y = y - tq^T \quad (6.21)$$

โดยทำต่อเนื่องไปเรื่อยๆจนกว่าจะได้จำนวนองค์ประกอบตามต้องการ ค่าสัมประสิทธิ์ของสมการเชิงเส้นนั้นสามารถหาได้จากสมการที่ (6.22) โดยอาศัยหลักการของ Inverse Least Squares

$$\hat{\beta} = W(P^T W)^{-1} Q^T \quad (6.22)$$

สมการที่ได้นั้นสามารถพิจารณาจาก PRESS (Predicted Residual Sum of Squares) RMSEC หรือ SEC RMSEP หรือ SEP และค่า Coefficient of Determination โดยค่า RMSEC RMSEP และ PRESS ควรมีค่าน้อยๆ

- PRESS

$$\sum_{i=1}^n (\hat{Y}_i - Y_i)^2$$

- Root mean square error of calibration (RMSEC)

$$\sqrt{\sum_{i=1}^n \frac{(\hat{Y}_i - Y_i)^2}{n - f - 1}}$$

- Root mean square error of prediction (RMSEP)

$$\sqrt{\sum_{i=1}^n \frac{(\hat{Y}_i - Y_i)^2}{n}}$$

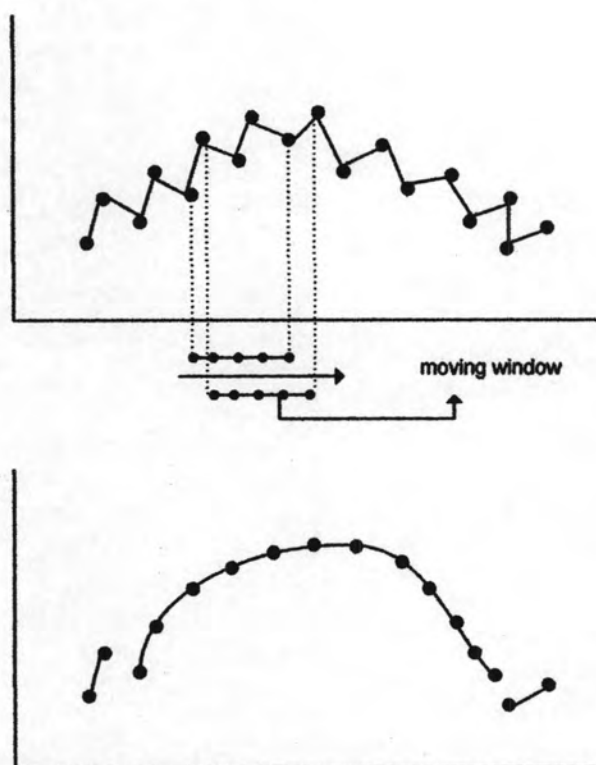
## 6.2 Digital smoothing และ Filtering methods [14]

โดยทั่วไป การเฉลี่ยถูกใช้อย่างกว้างขวางเพื่อปรับปรุง signal-to-noise ratio ของสัญญาณ ผลของสัญญาณรบกวนสามารถลดได้ เนื่องจากการกระจายแบบปกติของข้อมูล ในการเฉลี่ยกลุ่มข้อมูล  $x_i$  ค่าเฉลี่ย  $\bar{x}$  สามารถคำนวณได้โดย

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (6.23)$$

จะสังเกตได้ว่า ค่าความแปรปรวนของ  $\bar{x}$  มีค่าเป็น  $1/\sqrt{n}$  ของข้อมูลเดิม ดังนั้น การเฉลี่ยทำให้ SNR เพิ่มขึ้น เนื่องจากสเปกตรัมที่วัดได้เกิดจากการเฉลี่ยของการวัดหลายครั้ง

### 6.2.1 Moving-Window Average Smoothing Method



รูปที่ 6.1 หลักการของ moving-window average filter


วิธีการ moving-window average เป็นวิธีการดั้งเดิมและง่ายที่สุดในการทำให้เรียบ และช่วยปรับปรุงค่า SNR ด้วย หลักการของวิธีนี้แสดงในรูป 6.1 สมมติเวกเตอร์ข้อมูลดิบ  $x = [x_1, x_2, \dots, x_{n-1}, x_n]$  ในทางปฏิบัติขนาดของหน้าต่าง (window size,  $2m+1$ ) ต้องถูกกำหนดก่อนทำการคำนวณ เช่น ในการกรองข้อมูลโดยมีขนาดหน้าต่างเท่ากับ 5 ( $m=2$ ) เริ่มต้นห้าข้อมูลแรกจะถูกใช้ในการหาข้อมูล  $x_3^*$  โดยที่  $i=3$  และ  $m=2$  จากสมการ

$$x_i^* = \frac{1}{2m+1} \sum_{j=-m}^m x_{i+j} \quad (6.24)$$

โดยที่  $x_i^*$  เป็นค่าที่เกิดจากการกรอง  $x_{i+j}$  เป็นข้อมูลดิบ  $i$  และ  $j$  คือค่าคงตัว จะเห็นได้ว่า ข้อมูลสองค่าแรกไม่สามารถทำการกรองได้ และหลังจากทำ  $x_3^*$  ขึ้นคอนต่อไปคือ การหา  $x_4^*$  และทำต่อไปจนครบข้อมูลทุกค่า



### 6.2.2 Savitsky-Golay Filter



รูปที่ 6.2 หลักการของ Savitsky-Golay Filter

Savitsky-Golay Filter เป็นการกรองที่อาศัยวิธีการถดถอยพหุพจน์ แทนการใช้เทคนิคการเฉลี่ยอย่างง่าย Savitsky-Golay Filter ใช้ความสามารถของ regression fit ในการปรับปรุงผลของการกรองตามรูป จากรูปที่ 6.2 จะเห็นได้ว่า สามารถทำได้ดีกว่าวิธี moving-window average เพราะว่าได้ใช้ความสามารถในการทำให้เข้ากับข้อมูลของการถดถอยพหุนาม อย่างไรก็ตาม สูตรการคำนวณของ Savitsky-Golay Filter คล้ายกับของ moving-window average แต่สิ่งหลักที่ต่างกันคือ การให้น้ำหนักของข้อมูลที่นำมาคำนวณ

$$x_i^* = \frac{1}{2m+1} \sum_{j=-m}^m w_j x_{i+j} \quad (6.25)$$

สำหรับ Savitsky-Golay Filter ค่าถ่วงน้ำหนัก  $w_j$  สามารถหาได้โดยการใช้กำลังสองน้อยที่สุดซึ่งสามารถหาได้ตามสมการ

$$x_j^i = a_0 + a_1 j + a_2 j^2 + \dots + a_k j^k \quad (6.26)$$

$(j = -m, -m+1, \dots, m-1, m; i = 1, \dots, n)$

ตัวอย่างเช่น ถ้าขนาดหน้าต่างเท่ากับ 5 แล้วสมการจะกลายเป็น

$$x_j^i = a_0 + a_1 j + a_2 j^2 \quad (j = -2, -1, 0, 1, 2; i = 1, \dots, n) \quad (6.27)$$

โดย  $i$  แสดงถึงข้อมูลดั้งเดิม  $j$  แสดงถึงตัวแปรของขนาดหน้าต่าง เนื่องจากค่า  $x_j^i$  และ  $j$  หาค่าได้จากเทคนิคของกำลังสองน้อยที่สุด สามารถนำมาใช้เพื่อหาค่า  $a$  โดยการแทนค่าเข้าไปที่สมการ ก็จะได้กลุ่มของสมการเชิงเส้น

$$\begin{cases} x_{-2}^{i-2} = a_0 + a_1(-2) + a_2(-2)^2 \\ x_{-1}^{i-1} = a_0 + a_1(-1) + a_2(-1)^2 \\ x_0^i = a_0 + a_1(0) + a_2(0)^2 \\ x_1^{i+1} = a_0 + a_1(1) + a_2(1)^2 \\ x_2^{i+2} = a_0 + a_1(2) + a_2(2)^2 \end{cases} \quad (6.28)$$

หรือ

$$\begin{cases} x_{-2}^{i-2} = a_0 - 2a_1 + 4a_2 \\ x_{-1}^{i-1} = a_0 - a_1 + 4a_2 \\ x_0^i = a_0 \\ x_1^{i+1} = a_0 + a_1 + 4a_2 \\ x_2^{i+2} = a_0 + 2a_1 + 4a_2 \end{cases} = \begin{bmatrix} 1 & -1 & 2 \\ 1 & -1 & 1 \\ 1 & 0 & 0 \\ 1 & 1 & 1 \\ 1 & 2 & 4 \end{bmatrix} \begin{bmatrix} a_0 \\ a_1 \\ a_2 \end{bmatrix} \quad (6.29)$$

ซึ่งสามารถเขียนได้ในรูป

$$\begin{bmatrix} x_{-2}^{i-2} \\ x_{-1}^{i-1} \\ x_0^i \\ x_1^{i+1} \\ x_2^{i+2} \end{bmatrix} = \begin{bmatrix} 1 & -1 & 2 \\ 1 & -1 & 1 \\ 1 & 0 & 0 \\ 1 & 1 & 1 \\ 1 & 2 & 4 \end{bmatrix} \begin{bmatrix} a_0 \\ a_1 \\ a_2 \end{bmatrix} \quad (6.30)$$

หรือ

$$x = Ma \quad (6.31)$$

$$x = \begin{bmatrix} x_{-2}^{i-2} \\ x_{-1}^{i-1} \\ x_0^i \\ x_1^{i+1} \\ x_2^{i+2} \end{bmatrix}; M = \begin{bmatrix} 1 & -1 & 2 \\ 1 & -1 & 1 \\ 1 & 0 & 0 \\ 1 & 1 & 1 \\ 1 & 2 & 4 \end{bmatrix}; a = \begin{bmatrix} a_0 \\ a_1 \\ a_2 \end{bmatrix}$$

และสามารถเฉลยได้เป็น

$$a = (M'M)^{-1}M'x \quad (6.32)$$

โดยการแทนลงในสมการ เราสามารถทำนายค่าได้  $\hat{x}$

$$\hat{x} = M(M'M)^{-1}M'x \quad (6.33)$$

หรือในอีกรูปหนึ่งเป็น

$$\begin{cases} \hat{x}_{-2}^{i-2} = \frac{1}{35}(31x_{-2}^{i-2} + 9x_{-1}^{i-1} - 3x_0^i - 5x_1^{i+1} + 3x_2^{i+2}) \\ \hat{x}_{-1}^{i-1} = \frac{1}{35}(9x_{-2}^{i-2} + 13x_{-1}^{i-1} + 12x_0^i + 6x_1^{i+1} - 5x_2^{i+2}) \\ \hat{x}_0^i = \frac{1}{35}(-3x_{-2}^{i-2} + 12x_{-1}^{i-1} + 17x_0^i + 12x_1^{i+1} - 3x_2^{i+2}) \\ \hat{x}_1^{i+1} = \frac{1}{35}(-5x_{-2}^{i-2} + 6x_{-1}^{i-1} + 12x_0^i + 13x_1^{i+1} + 9x_2^{i+2}) \\ \hat{x}_2^{i+2} = \frac{1}{35}(3x_{-2}^{i-2} - 5x_{-1}^{i-1} - 3x_0^i + 9x_1^{i+1} + 31x_2^{i+2}) \end{cases} \quad (6.34)$$

จะเห็นได้ว่า Savitsky-Golay Filter ใช้เพียงจุดกลางในการทำให้เรียบ ดังนั้น ค่าถ่วงน้ำหนัก  $[w_{-2}, w_{-1}, w_0, w_1, w_2]$  สามารถหาได้จากสัมประสิทธิ์ของ  $x_0^i$  จากสมการข้างบน ค่าก็คือ  $\left[-\frac{3}{35}, \frac{12}{35}, \frac{17}{35}, \frac{12}{35}, -\frac{3}{35}\right]$  สำหรับขนาดหน้าต่างเท่ากับ 5 และพหุนจันอันดับ 2 โดยที่ขนาดของหน้าต่างและพหุนจันอันดับอื่นก็สามารถหาได้เช่นเดียวกัน

### 6.2.3 Numerical Differentiation

Numerical Differentiation เป็นเครื่องมือหนึ่งที่ใช้ในการวิเคราะห์สัญญาณทางเคมี เนื่องจากส่วนที่มีประโยชน์ในการแปลผลข้อมูลมักถูกซ่อนอยู่ในสัญญาณที่ทำการวัด สัญญาณที่วัดได้มักแสดงเป็นรูปร่างเคียว ที่ไม่แสดงส่วนโค้งหรือจุดยอดของสิ่งที่ป็นจุดเด่น ในการหาอนุพันธ์ทำให้สามารถหาจุดยอดหรือส่วนโค้งที่เป็นจุดเด่นที่ต้องการได้

#### 6.2.3.1 Simple Difference Method

วิธี direct-difference เป็นวิธีการหาอนุพันธ์เชิงตัวเลขของสัญญาณที่ง่ายที่สุด สำหรับข้อมูลสเปกตรัม  $x_i$  ( $i=1, \dots, n$ ) และความยาวคลื่นที่ทำการวัดสเปกตรัม  $w_i$  ( $i=1, \dots, n$ ) สมการ direct different method สามารถเขียนได้เป็น

$$y_i = \frac{x_{i+1} - x_i}{w_{i+1} - w_i} \quad (6.35)$$

โดย  $y_i$  ( $i=1, \dots, n-1$ ) คือกลุ่มข้อมูลสเปกตรัมของ  $x_i$  ที่ถูกทำการหาอนุพันธ์

direct different method เป็นวิธีที่ง่าย แต่ข้อด้อยคือ จำนวนจุดข้อมูลสเปกตรัมที่หาอนุพันธ์นั้นน้อยกว่าข้อมูลต้นฉบับหนึ่งจุด นั่นคือ ทำให้ข้อมูลสเปกตรัมที่หาอนุพันธ์เกิดการเลื่อนไปครึ่งจุดเมื่อเทียบกับข้อมูลต้นฉบับ ดังนั้น จุดสูงสุดต่ำสุดจึงไม่ตรงอย่างแน่นอน วิธีนี้จึงเป็นที่ยอมรับได้เมื่อข้อมูลที่ใช้มีความละเอียดสูง แต่ไม่เหมาะกับข้อมูลที่มีความละเอียดต่ำ

### 6.2.3.2 Moving-Window Polynomial Least-Squares Fitting Method

ในการกรองคิ้ววิธีของ Savitsky-Golay Filter นั้นเป็นวิธีที่อาศัย moving-window polynomial least squares fitting ซึ่งการกรองก็สามารถนำมาใช้ในการหาอนุพันธ์เชิงตัวเลขได้ เนื่องจากอยู่บนพื้นฐานของพหุนาม ดังนั้น จึงสามารถทำการหาอนุพันธ์โดยตรง เพื่อให้ได้ค่าถ่วงน้ำหนักที่จุดกลาง เพื่อนำมาใช้ในการหาอนุพันธ์ของสเปกตรัมได้ สิ่งที่น่าสนใจคือ การหาอนุพันธ์โดยวิธีนี้นั้น ไม่เกิดการเลื่อนของจุดข้อมูลเหมือนในกรณีของ direct different method ทุกจุดของสเปกตรัมสามารถเขียนได้เป็น

$$x_j^{i+j} = a_0 + a_1 j + a_2 j^2 + \dots + a_k j^k \quad (6.36)$$

$$(i=1, \dots, n)(j=-m, \dots, 0, \dots, m)$$

จากการหาอนุพันธ์อันดับหนึ่งโดยตรง จะได้

$$\frac{d(x_j^{i+j})}{d(j)} = a_1 + 2a_2 j + \dots + k a_k j^{k-1} \quad (6.37)$$

ที่ค่า  $j=0$  ได้เป็น

$$\frac{d(x_j^{i+j})}{d(j)} \Big|_{j=0} = a_1 \quad (6.38)$$

หมายความว่า ที่จุดกลางของหน้าต่างนั้นขึ้นอยู่กับสัมประสิทธิ์  $a_1$  เพียงค่าเดียว สำหรับอนุพันธ์อันดับสอง

$$\frac{d^2(x_j^{i+j})}{d(j)^2} = 2a_2 + \dots + k(k-1)a_k j^{k-2} \quad (6.39)$$

ที่ค่า  $j=0$  ได้เป็น

$$\frac{d^2(x_j^{i+j})}{d(j)^2} \Big|_{j=0} = 2a_2 \quad (6.40)$$

ซึ่งสามารถหารูปทั่วไปได้เป็น

$$\frac{d^k(x_j^{i+j})}{d(j)^k} \Big|_{j=0} = k! a_k \quad (6.41)$$

นั่นคือเราสามารถหาค่าถ่วงน้ำหนักของสเปกตรัมที่ทำการหาอนุพันธ์ได้จากความสัมพันธ์

$$a = (M' M)^{-1} M' x \quad (6.42)$$

หรือ

$$\begin{bmatrix} a_0 \\ a_1 \\ \vdots \\ \vdots \\ a_k \end{bmatrix} = (M' M)^{-1} M' x \quad (6.43)$$

ทำให้เราสามารถหาอนุพันธ์ที่อันดับและหน้าต่างขนาดต่างๆ กัน ได้