

## บทที่ 2

### ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

บทนี้จะแบ่งเนื้อหาออกเป็น 2 ส่วนด้วยกัน โดยเนื้อหาในส่วนแรกจะกล่าวถึงทฤษฎีพื้นฐานของซัพพอร์ตเวกเตอร์แมชชีนทั้งกรณีปัญหาที่เป็นแบบเชิงเส้นและไม่เป็นเชิงเส้น และทฤษฎีสารสนเทศในส่วนที่นำมาใช้ช่วยแก้ปัญหาการจำแนกแบบหลายประเภท สำหรับเนื้อหาในส่วนที่สองจะกล่าวถึงงานวิจัยที่เกี่ยวข้องกับปัญหาการจำแนกแบบหลายประเภทด้วยซัพพอร์ตเวกเตอร์แมชชีน

#### 2.1 ทฤษฎีที่เกี่ยวข้อง

##### 2.1.1 ซัพพอร์ตเวกเตอร์แมชชีน

แนวคิดหลักในการจำแนกข้อมูล ของซัพพอร์ตเวกเตอร์แมชชีนก็คือ การสร้างระนาบหลายมิติที่ใช้ในการแบ่งข้อมูลออกเป็นสองประเภท

###### 2.1.1.1 ซัพพอร์ตเวกเตอร์แมชชีนแบบเชิงเส้น (Linear support vector machine)

สมมติมีเซตของข้อมูล  $D$  ที่ประกอบด้วยตัวอย่างจำนวน  $l$  ตัวในปริภูมิอันดับ  $n$  ที่มี 2 ประเภท (+1 และ -1)

$$D = \{(x_k, y_k) \mid k \in \{1, \dots, l\}, x_k \in \mathcal{R}^n, y_k \in \{+1, -1\}\} \quad (1)$$

ระนาบหลายมิติในปริภูมิอันดับ  $n$  ถูกกำหนดโดย  $(w, b)$  เมื่อ  $w$  คือเวกเตอร์ในปริภูมิอันดับ  $n$  ที่ตั้งฉากกับระนาบหลายมิติและ  $b$  คือค่าคงที่ที่ระนาบหลายมิติ  $(w \cdot x) + b$  จะแบ่งข้อมูลได้ก็ต่อเมื่อ

$$\begin{aligned} (w \cdot x_i) + b &> 0 & \text{if } y_i = +1 \\ (w \cdot x_i) + b &< 0 & \text{if } y_i = -1. \end{aligned} \quad (2)$$

ถ้าเราต้องการค่า  $w$  และ  $b$  ที่ทำให้จุดที่อยู่ใกล้ระนาบหลายมิติมากที่สุดมีระยะห่าง  $1/|w|$  แล้วจะได้

$$\begin{aligned} (w \cdot x_i) + b &\geq 1 & \text{if } y_i = +1 \\ (w \cdot x_i) + b &\leq -1 & \text{if } y_i = -1 \end{aligned} \quad (3)$$

ซึ่งเท่ากับ

$$y_i [(w \cdot x_i) + b] \geq 1 \quad \forall i. \quad (4)$$

ในการค้นหาระนาบหลายมิติที่ใช้แบ่งข้อมูลดีที่สุดจะต้องค้นหาระนาบหลายมิติที่มีระยะห่างระหว่างข้อมูลที่ใช้สอนกับระนาบหลายมิติที่น้อยที่สุดมีค่ามากที่สุด (ดูรูปที่ 1) ระยะห่างระหว่างข้อมูลตัวอย่างสองตัวจากประเภทที่แตกต่างกันมีค่าเท่ากับ

$$d(w, b) = \min_{(x, y=1)} \frac{(w \cdot x_i) + b}{|w|} - \max_{(x, y=-1)} \frac{(w \cdot x_i) + b}{|w|} \quad (5)$$


จากสมการที่ (3) ค่าที่น้อยที่สุดและมากที่สุดที่เหมาะสมคือ  $\pm 1$  ดังนั้นจำเป็นต้องเพิ่มค่าของฟังก์ชัน

$$d(w, b) = \frac{1}{|w|} - \frac{-1}{|w|} = \frac{2}{|w|} \quad (6)$$

ให้สูงที่สุด ดังนั้นปัญหานี้จึงเท่ากับ

- ลดค่าของ  $|w|^2/2$  ให้ต่ำที่สุดโดยขึ้นกับเงื่อนไขต่อไปนี้

$$(1) y_i[(w \cdot x_i) + b] \geq 1 \quad \forall i.$$



รูปที่ 1 ตัวอย่างของการจำแนกข้อมูลสองประเภทด้วยซัพพอร์ตเวกเตอร์แมชชีน

สำหรับกรณีที่ไม่สามารถแบ่งข้อมูลได้โดยเงื่อนไขข้างต้นจะต้องปรับเงื่อนไขใหม่โดยเพิ่มพจน์ค่าปรับซึ่งประกอบด้วยผลรวมของความคลาดเคลื่อน  $\xi_i$  จากขอบเขตเข้าไปในเงื่อนไข ดังนั้นปัญหานี้คือ

- ลดค่าของ  $\frac{|w|^2}{2} + C \sum_{i=1}^l \xi_i$  ให้ต่ำที่สุด โดยขึ้นกับเงื่อนไขต่อไปนี้

$$(1) y_i[(w \cdot x_i) + b] \geq 1 - \xi_i$$

$$(2) \xi_i \geq 0 \quad \forall i.$$

พจน์ค่าปรับสำหรับตัวอย่างข้อมูลสอนที่ทำนายผิดพลาดถูกเพิ่มน้ำหนักโดยค่าคงที่  $C$  การเลือกค่า  $C$  สูงจะมีผลให้เพิ่มค่าของความคลาดเคลื่อน  $\xi_i$  และเพิ่มการคำนวณโดยทำให้การค้นหานทางที่จะลดจำนวนตัวอย่างข้อมูลสอนที่ทำนายผิดพลาดเพิ่มขึ้น นำลากรองเกรียนมาใช้กับปัญหานี้ สามารถแปลงปัญหาเป็น

- ลดค่าของฟังก์ชันนี้ให้ต่ำที่สุด

$$L(\mathbf{w}, b, \alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j (\mathbf{x}_i \cdot \mathbf{x}_j) \quad (7)$$

โดยขึ้นกับเงื่อนไขต่อไปนี้

$$(1) 0 \leq \alpha_i \leq C, \forall i$$

$$(2) \sum_{i=1}^l \alpha_i y_i = 0$$

เมื่อ  $\alpha_i$  เรียกว่าตัวคูณลากรอง ตัวอย่างข้อมูลสอนแต่ละตัวจะมีตัวคูณลากรองหนึ่ง ตัวอย่างที่มีค่า  $\alpha_i > 0$  เรียกว่า ซัพพอร์ตเวกเตอร์ และเป็นซัพพอร์ตเวกเตอร์ที่ทำให้ค่าทางขวามือของสมการที่ (4) เท่ากับ 1 ส่วนตัวอย่างอื่นที่มี  $\alpha_i = 0$  สามารถตัดออกไปจากเซตของตัวอย่างข้อมูลสอนได้ โดยไม่มีผลกระทบใด ๆ ต่อผลลัพธ์ของระนาบหลายมิติ

ให้  $\alpha^0$  ซึ่งเป็นเวกเตอร์ในปริภูมิอันดับ  $l$  แทนค่าต่ำสุดของ  $L(\mathbf{w}, b, \alpha)$  ถ้า  $\alpha_i^0 > 0$  แล้ว  $\mathbf{x}_i$  เป็นซัพพอร์ตเวกเตอร์ของระนาบหลายมิติที่แบ่งแยกดีสุด  $(\mathbf{w}^0, b^0)$  สามารถเขียนในเทอมของ  $\alpha^0$  และข้อมูลสอนโดยเฉพาะอย่างยิ่งในเทอมของซัพพอร์ตเวกเตอร์ได้ดังนี้

$$\mathbf{w}^0 = \sum_{i=1}^l \alpha_i^0 y_i \mathbf{x}_i = \sum_{\text{support vectors}} \alpha_i^0 y_i \mathbf{x}_i. \quad (8)$$

$$b^0 = 1 - \mathbf{w}^0 \cdot \mathbf{x}_i \text{ for } \mathbf{x}_i \text{ with } y_i = 1 \text{ and } 0 < \alpha_i < C. \quad (9)$$

ระนาบหลายมิติที่แบ่งแยกดีสุดจะจำแนกจุดต่างๆ ตามเครื่องหมายของผลลัพธ์ของฟังก์ชัน  $f(\mathbf{x})$

$$\begin{aligned} f(\mathbf{x}) &= \text{sign}(\mathbf{w}^0 \cdot \mathbf{x} + b^0) \\ &= \text{sign}\left(\sum_{\text{support vectors}} \alpha_i^0 y_i (\mathbf{x}_i \cdot \mathbf{x}) + b^0\right). \end{aligned} \quad (10)$$

ซัพพอร์ตเวกเตอร์  $\mathbf{x}_i$  ที่มี  $\alpha_i^0 = C$  อาจจะถูกจำแนกผิดพลาดหรือไม่ก็ได้ แต่  $\mathbf{x}_i$  ตัวอื่นๆ จะจำแนกได้อย่างถูกต้อง


### 2.1.1.2 ซัพพอร์ตเวกเตอร์แมชชีนแบบไม่เชิงเส้น (Non-linear Support vector machine)

อัลกอริทึมที่ได้กล่าวมาแล้วใช้ได้กับข้อมูลที่สามารถแบ่งด้วยระนาบหลายมิติแบบเชิงเส้นเท่านั้น แต่กับข้อมูลที่ไม่อาจแบ่งแบบเชิงเส้นได้ ซัพพอร์ตเวกเตอร์แมชชีนแก้ปัญหานี้โดยแมปข้อมูลตัวอย่าง ไปยังปริภูมิอันดับสูง โดยเลือกใช้ฟังก์ชันการแมปที่ไม่เป็นเชิงเส้น นั่นคือเราเลือกฟังก์ชันในการแมป  $\Phi: \mathbb{R}^n \mapsto H$  เมื่อปริภูมิของ  $H$  มีอันดับสูงกว่าปริภูมิอันดับ  $n$  เราสามารถค้นหาระนาบที่แบ่งแยกดีที่สุดในปริภูมิอันดับสูงที่เทียบเท่ากับการแยกที่ไม่เป็นเชิงเส้นใน  $\mathbb{R}^n$  (ดูรูปที่ 2 ประกอบ)

ตัวอย่างข้อมูลสอนที่ใช้ในสมการที่ (7) อยู่ในรูปของผลคูณเชิงสเกลาร์ระหว่างเวกเตอร์ ดังนั้นในปริภูมิอันดับสูงเราสามารถจัดการกับข้อมูลในรูปของ  $\Phi(x) \cdot \Phi(x_j)$ . ถ้าปริภูมิของ  $H$  มีอันดับสูงจะทำให้ยุ่งยาก หรือใช้การคำนวณมาก อย่างไรก็ตามถ้าเรามีฟังก์ชันเคอร์เนลที่สามารถคำนวณ  $k(x, x_j) = \Phi(x) \cdot \Phi(x_j)$  แล้วเราสามารถใส่ฟังก์ชันนี้แทนที่  $x, x_j$  ทุกๆ ที่ในการคำนวณและไม่ต้องรู้ฟังก์ชันที่ใช้แมป  $\Phi$  จริงๆ ฟังก์ชันเคอร์เนลที่นิยมใช้ได้แก่

$$\text{Polynomial degree } d: \quad k(x, y) = |x \cdot y + 1|^d \quad (11)$$

$$\text{Radial basis function:} \quad k(x, y) = e^{-|x-y|^2/c} \quad (12)$$



รูปที่ 2 แนวคิดการแมปข้อมูลแบบเป็นไม่เชิงเส้นไปสู่ปริภูมิอันดับสูง

### 2.1.2 ทฤษฎีสารสนเทศ

ค่าสารสนเทศของข้อมูลขึ้นอยู่กับความน่าจะเป็นของข้อมูล [10] ซึ่งสามารถวัดอยู่ในรูปของบิตจากสูตร


$$\text{ค่าสารสนเทศของข้อมูล} = -\log_2 \text{ความน่าจะเป็นของข้อมูล} \quad (13)$$

ถ้าให้ชุดของข้อมูล  $M$  ประกอบด้วยค่าที่เป็นไปได้คือ  $\{m_1, m_2, \dots, m_n\}$  และให้ความน่าจะเป็นที่จะเกิดค่า  $m_i$  มีค่าเท่ากับ  $P(m_i)$  จะได้ว่าค่าสารสนเทศของ  $M$  หรือค่าเอนโทรปีของ  $M$  เขียนแทนด้วย  $I(M)$  คำนวณได้จากสูตร

$$I(M) = \sum_{i=1}^n -P(m_i) \log_2 P(m_i) \quad (14)$$

ความหมายของค่าสารสนเทศกรณีมีค่าน้อย หมายถึงข้อมูลในชุดนั้นมีความแตกต่างกันน้อย หรือเกือบจะเป็นประเภทเดียวกัน แต่กรณีค่าสารสนเทศสูงจะบ่งบอกว่าข้อมูลในชุดนั้นมีความแตกต่างกันมากหรือประกอบด้วยตัวอย่างหลายประเภทที่มีจำนวนใกล้เคียงกัน ตัวอย่างในการโยนหัวโยนก้อย ชุดข้อมูล  $M$  จะประกอบด้วยค่าที่เป็นไปได้ {หัว, ก้อย} จะได้ว่าค่าสารสนเทศของการโยนหัวก้อยเท่ากับ  $-P(\text{หัว}) \log_2(P(\text{หัว})) - P(\text{ก้อย}) \log_2(P(\text{ก้อย}))$

เมื่อพิจารณากรณีที่โยนออกหัวหมดหรือก้อยหมด ค่าสารสนเทศจะเป็น 0 และค่าสารสนเทศจะค่อยๆ เพิ่มขึ้นจนสูงที่สุด เมื่อความน่าจะเป็นของการเกิดหัวเท่ากับความน่าจะเป็นของการเกิดก้อยหรือสามารถแสดงได้ดังรูปที่ 3



รูปที่ 3 ความสัมพันธ์ระหว่างความน่าจะเป็นและค่าสารสนเทศ

## 2.2 งานวิจัยที่เกี่ยวข้อง

จากที่กล่าวข้างต้นการนำซัพพอร์ตเวกเตอร์แมชชีนมาแก้ปัญหาการจำแนกแบบหลายประเภทมีผู้เสนอวิธีการหลายวิธีด้วยกัน โดยส่วนใหญ่มักเป็นการนำฟังก์ชันที่จำแนกแบบสองประเภทหลายฟังก์ชันมาใช้ร่วมกันดังงานวิจัยที่เกี่ยวข้องต่อไปนี้

### 2.2.1 วิธีจำแนกแบบหนึ่งต่อที่เหลือ (One-against-the rest)

เป็นการสร้างระนาบเพื่อจำแนกข้อมูลสองส่วนโดยเปรียบเทียบข้อมูลประเภทหนึ่งกับประเภทอื่นที่เหลือทั้งหมดพร้อมกัน ดังนั้นจึงต้องสร้างระนาบหรือตัวจำแนกทั้งสิ้น  $k$  ตัว สำหรับปัญหา  $k$  ประเภท เมื่อ  $i$  คือประเภทข้อมูลใด ๆ ตัวจำแนกสำหรับประเภท ข้อมูล  $i$  เป็นไปตามเงื่อนไขต่อไปนี้

$$\begin{aligned} \min_{\mathbf{w}', b', \xi_j} \quad & \frac{1}{2}(\mathbf{w}')^T \mathbf{w}' + C \sum_{j=1}^l \xi_j' (\mathbf{w}')^T \\ & (\mathbf{w}')^T \Phi(\mathbf{x}_j) + b' \geq 1 - \xi_j', \quad \text{if } y_j = i \\ & (\mathbf{w}')^T \Phi(\mathbf{x}_j) + b' \leq -1 + \xi_j', \quad \text{if } y_j \neq i \\ & \xi_j' \geq 0, \quad j = 1, \dots, l. \end{aligned} \quad (15)$$


หลังจากหาค่าผลเฉลยของสมการ (15) จะได้ฟังก์ชันที่จำแนกสำหรับ  $k$  ประเภท ดังนี้

$$\begin{aligned} & (\mathbf{w}^1)^T \Phi(\mathbf{x}) + b^1 \\ & \vdots \\ & (\mathbf{w}^k)^T \Phi(\mathbf{x}) + b^k. \end{aligned}$$


การพิจารณาคำตอบของการจำแนกจะเลือกจากตัวจำแนกที่ให้ค่าของฟังก์ชันตัวจำแนกสูงสุดจากตัวจำแนกทั้ง  $k$  ตัว

$$\text{class of } \mathbf{x} \equiv \arg \max_{i=1, \dots, k} ((\mathbf{w}^i)^T \Phi(\mathbf{x}) + b^i). \quad (16)$$


พิจารณาดูตัวอย่างการสร้างระนาบเพื่อจำแนกข้อมูลของวิธีจำแนกแบบหนึ่งต่อที่เหลือกรณีปัญหา 4 ประเภทดังรูปที่ 4




(ก) ตัวอย่างระนาบที่แบ่งข้อมูล 2 ส่วนออกจากกัน โดยส่วนแรกคือ ประเภที่ 1 และส่วนที่สองคือ ประเภที่ 2, 3 และ 4



(ข) ตัวอย่างระนาบที่แบ่งข้อมูล 2 ส่วนออกจากกัน โดยส่วนแรกคือ ประเภที่ 2 และส่วนที่สองคือ ประเภที่ 1, 3 และ 4



(ค) ตัวอย่างระนาบที่แบ่งข้อมูล 2 ส่วนออกจากกัน โดยส่วนแรกคือ ประเภที่ 3 และส่วนที่สองคือ ประเภที่ 1, 2 และ 4



(ง) ตัวอย่างระนาบที่แบ่งข้อมูล 2 ส่วนออกจากกัน โดยส่วนแรกคือ ประเภที่ 4 และส่วนที่สองคือ ประเภที่ 1, 2 และ 3

รูปที่ 4 ตัวอย่างการสร้างระนาบของการจำแนกแบบหนึ่งต่อที่เหลือ สำหรับปัญหา 4 ประเภท

ตัวอย่างการสร้างระนาบของการจำแนกแบบหนึ่งต่อที่เหลือ กรณีปัญหา 4 ประเภท ซึ่งจะสร้างระนาบทั้งสิ้น 4 ตัว ได้แก่ระนาบที่แบ่งส่วนข้อมูลดังต่อไปนี้

1. ระนาบแบ่งระหว่างส่วนที่เป็นประเภที่ 1 และส่วนที่เป็นประเภที่ 2, 3 และ 4
2. ระนาบแบ่งระหว่างส่วนที่เป็นประเภที่ 2 และส่วนที่เป็นประเภที่ 1, 3 และ 4
3. ระนาบแบ่งระหว่างส่วนที่เป็นประเภที่ 3 และส่วนที่เป็นประเภที่ 1, 2 และ 4
4. ระนาบแบ่งระหว่างส่วนที่เป็นประเภที่ 4 และส่วนที่เป็นประเภที่ 1, 2 และ 3

จากรูปที่ 4(ข-ง) จะเห็นว่าภาระงานที่แบ่งข้อมูลออกเป็นสองส่วน โดยตัวอย่างทุกตัวตกอยู่ในด้านของระนาบที่ถูกต้องนั้นเป็นไปได้ยาก โดยไม่ว่าจะสร้างระนาบอย่างไรก็จะมีตัวอย่างบางตัวตกอยู่ในด้านที่ไม่ถูกต้องเสมอ เมื่อนำระนาบที่ได้ไปใช้ในการจำแนกข้อมูลย่อมส่งผลต่อความถูกต้องของการจำแนกด้วย ซึ่งเป็นข้อด้อยของวิธีนี้ที่นอกจากใช้เวลาในการสร้างระนาบนานแล้วอาจไม่ได้ระนาบที่ดีในการจำแนกข้อมูลอีกด้วย

### 2.2.2 วิธีแมกซ์วิน (Max Wins)


อัลกอริทึมแมกซ์วินจะทำงานโดยอาศัยฟังก์ชันพื้นฐานของการจำแนกแบบหนึ่งต่อหนึ่ง สร้างตัวจำแนกข้อมูลทั้งหมด จำนวน  $k(k-1)/2$  ตัว โดยที่  $k$  คือจำนวนประเภทข้อมูลทั้งหมด ตัวจำแนกแต่ละตัวจะถูกสอนโดยข้อมูลจาก 2 ประเภท  $i$  และ  $j$  ใดๆ ตามเงื่อนไขดังนี้

$$\min_{w^j, b^j, \xi_i^j} \frac{1}{2} (w^j)^T w^j + C \sum_i \xi_i^j (w^j)^T$$

$$(w^j)^T \Phi(x_i) + b^j \geq 1 - \xi_i^j, \quad \text{if } y_i = i$$

$$(w^j)^T \Phi(x_i) + b^j \leq -1 + \xi_i^j, \quad \text{if } y_i = j \quad \xi_i^j \geq 0. \quad (17)$$

แล้วใช้ฟังก์ชัน  $\text{sign}((w^j)^T \Phi(x) + b^j)$  จำแนกให้คำตอบว่าตัวอย่าง  $x$  ใดๆ อยู่ในประเภท  $i$  หรือ  $j$  หลังจากได้คำตอบทั้งหมดแล้ว วิธีแมกซ์วินจะนำคำตอบที่ได้จากตัวจำแนกทั้งหมด  $k(k-1)/2$  ตัว มาโหวตรวมกันโดยประเภทที่ได้ผลโหวตสูงที่สุด ก็จะเป็นคำตอบของแมกซ์วิน (ดังแสดงในรูปที่ 5) ส่วนในกรณีที่มีผลโหวตสูงที่สุดมากกว่า 1 ประเภท ก็จะทำการสุ่มคำตอบจากประเภทเหล่านั้น




รูปที่ 5 วิธีแมกซ์วินสำหรับปัญหา 4 ประเภท



### 2.2.3 วิธีดีดีเอจี้ (Decision Directed Acyclic Graph (DDAG))

Platt และคณะ [3] ได้เสนอวิธีดีดีเอจี้ โดยใช้โทโปโลยีของกราฟมาวิเคราะห์ ซึ่งนำตัวจำแนกแบบสองประเภทหลายตัวมาใช้ร่วมกันเป็นตัวจำแนกแบบหลายประเภทหนึ่งตัว สำหรับปัญหาที่มี  $k$  ประเภท ในขั้นตอนการเรียนรู้จะสร้างตัวจำแนกแบบสองประเภทจำนวน  $k(k-1)/2$  ตัว เช่นเดียวกับวิธีแมกซวิน แต่ในขั้นตอนการจำแนกจะใช้กราฟไม่มีวงแบบมีทิศทาง แต่ละโนดจะมีฟังก์ชันแบบสองประเภท ซึ่งมีทั้งหมด  $k(k-1)/2$  โหนดและมี  $k$  ใบ (ดูรูปที่ 6) แต่ละโนดคือตัวจำแนกข้อมูลของประเภทที่  $i$  และ  $j$  เมื่อต้องการจำแนกข้อมูล  $x$  จะเริ่มจากโนดราก แล้วฟังก์ชันแบบสองประเภทที่โนดจะถูกนำมาคำนวณ ถ้าได้ค่าของฟังก์ชันน้อยกว่าศูนย์ก็ออกที่กิ่งซ้าย ถ้าได้มากกว่าหรือเท่ากับศูนย์ก็ออกที่กิ่งขวา หลังจากนั้นฟังก์ชันที่โนดต่อมาจะถูกคำนวณจนถึงโนดใบซึ่งก็คือคำตอบของดีดีเอจี้

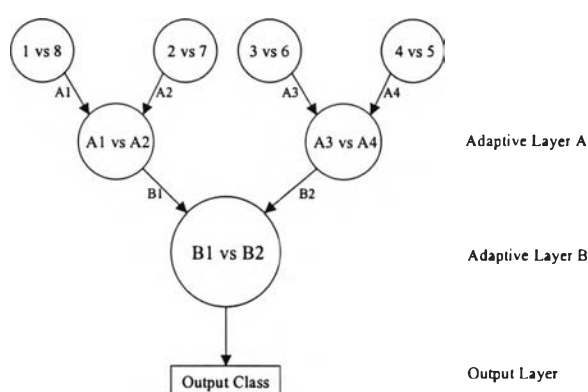


รูปที่ 6 โครงสร้างของดีดีเอจี้สำหรับปัญหา 4 ประเภท

ใน [4] ได้แสดงให้เห็นถึงข้อเสียของดีดีเอจี้ อย่างแรกก็คือ ดีดีเอจี้จะให้ผลลัพธ์ที่มีการแจกแจงความน่าจะเป็นไม่สม่ำเสมอ อันเนื่องมาจากการขึ้นอยู่กับการลำดับของตัวจำแนกในกราฟ ซึ่งมีผลต่อความน่าเชื่อถือของอัลกอริทึม นอกจากนี้ประเภทที่ถูกต้องที่วางอยู่ใกล้โนดราก จะมีข้อเสียเมื่อเปรียบเทียบประเภทที่อยู่ใกล้โนดใบ เนื่องจากจะมีโอกาสที่จะถูกจำแนกมากกว่า ทำให้โอกาสที่จะถูกจำแนกผิดมีมากขึ้น อย่างที่สองคือ จำนวนครั้งที่ประเภทที่ถูกต้องถูกจำแนกสูงทำให้มีความผิดพลาดสะสมสูง และส่งผลให้จำแนกผิดได้ เส้นทางการจำแนกของดีดีเอจี้มีค่าความลึกเท่ากับ  $k-1$  นั่นคือจำนวนครั้งที่ประเภทที่ถูกต้องถูกจำแนกกับประเภทอื่นจะแปรผันตามจำนวนประเภทข้อมูลทั้งหมด

## 2.2.4 วิธีเอดีเอจี (Adaptive Directed Acyclic Graph (ADAG))

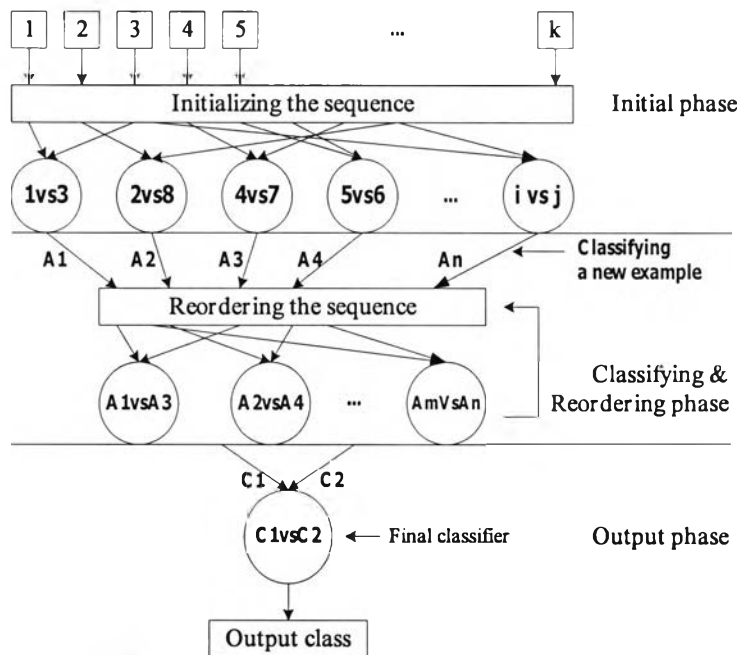
Ussivakul และ Kijisirikul [4] เสนอวิธีการที่ลดข้อเสียของวิธีดีเอจีเรียกว่า วิธีเอดีเอจี เป็นกราฟไม่มีวงแบบมีทิศทาง ที่ปรับโครงสร้างเป็นรูปคล้ายสามเหลี่ยมคว่ำ โดยจะเลือกตัวจำแนกแบบสองประเภท มาใช้จำแนกเพียง  $k-1$  ตัวในปัญหา  $k$  ประเภท ในขั้นตอนการจำแนก จะมีการแบ่งเป็นชั้น โดยในแต่ละชั้นจะเลือกตัวจำแนกแบบสองประเภทมาจำนวน  $k/2$  ตัวเพื่อจับคู่ให้ทุกประเภทข้อมูลถูกจำแนก 1 ครั้งในแต่ละชั้น และเมื่อจำแนกแล้วจำนวนประเภทข้อมูลจะลดลงเหลือครึ่งหนึ่งในแต่ละชั้นถัดมา จนเหลือประเภทเดียวในระดับล่างสุด (ดูรูปที่ 7)



รูปที่ 7 โครงสร้างของเอดีเอจีสำหรับปัญหา 8 ประเภท

จากโครงสร้างของวิธีเอดีเอจีทำให้ทุกประเภทข้อมูลมีโอกาสของจำนวนครั้งที่จะถูกจำแนกเท่ากัน จึงลดจำนวนครั้งที่ประเภทที่ถูกต้องถูกจำแนกกับประเภทอื่นจึงลดความผิดพลาดสะสมลงได้ อย่างไรก็ตามความถูกต้องของวิธีนี้ยังคงขึ้นกับลำดับการจับคู่เพื่อจำแนกของประเภทข้อมูลในแต่ละชั้น ในวิธีอาร์เอดีเอจี [5] จะเสนอวิธีการเลือกลำดับที่เหมาะสมในการจับคู่จำแนกข้อมูลในแต่ละชั้น เพื่อให้มีโอกาสจำแนกข้อมูลผิดในแต่ละชั้นน้อยที่สุด

2.2.5 วิธีอาร์เอดีเอจี (Reordering Adaptive Directed Acyclic Graph (RADAG))



รูปที่ 8 โครงสร้างการจำแนกข้อมูลของอาร์เอดีเอจี

Phetkaew, et al. [5] นำเสนอวิธีการใหม่ เรียกว่าอาร์เอดีเอจี เพื่อปรับปรุงความถูกต้องของวิธีเอดีเอจีเดิม [4] โดยในโครงสร้างของการจำแนกนั้นจะเป็นรูปคล้ายสามเหลี่ยมกว่าเหมือนวิธีเอดีเอจี แต่จะมีการเลือกลำดับที่ทำให้เกิดความผิดพลาดน้อยที่สุดของการจำแนกในแต่ละชั้นโดยวิธีการเลือกจะใช้อัลกอริทึมของการจับคู่สมบูรณ์แบบน้ำหนักน้อยที่สุด (Minimum-Weight Perfect Matching) [6] เพื่อจับคู่ให้ค่าขอบเขตความผิดพลาดรวมในแต่ละชั้นมีค่าน้อยที่สุด โดยค่าขอบเขตความผิดพลาดของฟังก์ชันแบบสองประเภทแต่ละตัวหาได้จากค่าประสิทธิภาพโดยนัยทั่วไปของซัพพอร์ตเวกเตอร์แมชชีน (Generalization Performance of Support Vector Machine) [11] และเมื่อมีการจำแนกผ่านไปสู่ชั้นใหม่ก็จะมีวิธีการเรียงลำดับการจำแนกใหม่ (Reordering) อีกจนเหลือประเภทเดียวในชั้นสุดท้ายซึ่งเป็นคำตอบของอาร์เอดีเอจี


## 2.2.6 วิธีจำแนกข้อมูลแบบแตกครึ่งแบบสมดุล (Balanced Dichotomization Classification)

Kijsirikul, et al. [7] เสนอวิธีจำแนกข้อมูลแบบแตกครึ่งแบบสมดุล (Balanced Dichotomization) ซึ่งมีแนวคิดในการจำแนกข้อมูลโดยนำตัวจำแนกแบบสองประเภทมาสร้างเป็นต้นไม้ไบนารีสำหรับการจำแนกแบบหลายประเภท หลักเกณฑ์ในการเลือกตัวจำแนกมาสร้างโนดของต้นไม้จะพิจารณาเลือกตัวจำแนกที่แบ่งประเภทข้อมูลได้สมดุลที่สุด เมื่อกล่าวถึงตัวจำแนกแบบสองประเภทซึ่งอีกนัยหนึ่งคือ ระบายหลายมิติที่แบ่งประเภทข้อมูลสองประเภทออกจากกัน การหาระนาบที่แบ่งข้อมูลได้สมดุลที่สุดคือ แบ่งแล้วให้จำนวนประเภทที่ตกอยู่แต่ละด้านของระนาบมีค่าใกล้เคียงกันมากที่สุด เทคนิคนี้ได้ใช้ฟังก์ชัน *UnBalancedScore* เป็นตัววัดค่าความสมดุลของระนาบจากสูตรต่อไปนี้

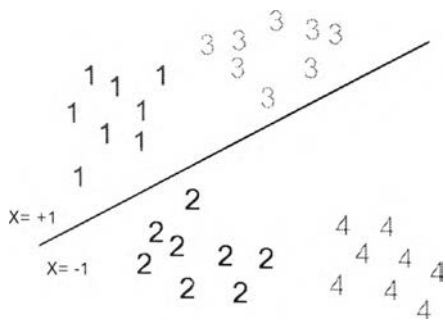
$$UnBalancedScore = CountLeft + CountRight + (0.5) |CountLeft - CountRight| \quad (18)$$

โดยที่ *CountLeft* คือจำนวนประเภทข้อมูลที่มีตำแหน่งอยู่ในฝั่งซ้ายของระนาบและ *CountRight* คือจำนวนประเภทข้อมูลที่มีตำแหน่งอยู่ในฝั่งขวาของระนาบ ซึ่งระนาบที่ได้ค่าของฟังก์ชัน *UnBalancedScore* น้อยที่สุดก็จะถูกเลือกให้เป็นระนาบที่แตกครึ่งแบบสมดุลที่สุด


ตัวอย่างหากตำแหน่งของข้อมูลกรณีปัญหาการจำแนกจำนวน 4 ประเภทเป็น ดังรูปที่ 9 เมื่อใช้วิธีการแตกครึ่งแบบสมดุล ในแต่ละรอบต้องสร้างตัวจำแนกแบบสองประเภททุกแบบที่เป็นไปได้จากนั้นจึงคำนวณค่า *UnBalancedScore* ของตัวจำแนกแต่ละตัวเพื่อใช้ในการพิจารณาเลือกมาเป็นโนดของต้นไม้สำหรับการจำแนกแบบหลายประเภท (ดูรูปที่ 10 ประกอบ)




รูปที่ 9 ตัวอย่างตำแหน่งของข้อมูลกรณีปัญหา 4 ประเภท




(ก) ตำแหน่งของข้อมูลประเภทอื่นๆ เมื่อเทียบกับตัวจำแนกประเภท 1-2




(ข) ตำแหน่งของข้อมูลประเภทอื่นๆ เมื่อเทียบกับตัวจำแนกประเภท 1-3



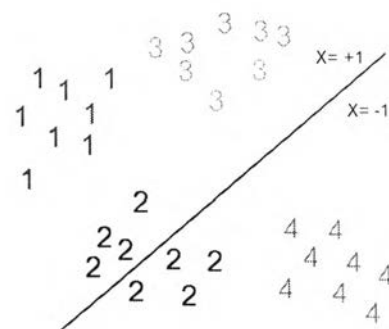
(ค) ตำแหน่งของข้อมูลประเภทอื่นๆ เมื่อเทียบกับตัวจำแนกประเภท 1-4



(ง) ตำแหน่งของข้อมูลประเภทอื่นๆ เมื่อเทียบกับตัวจำแนกประเภท 2-3



(จ) ตำแหน่งของข้อมูลประเภทอื่นๆ เมื่อเทียบกับตัวจำแนกประเภท 2-4



(ฉ) ตำแหน่งของข้อมูลประเภทอื่นๆ เมื่อเทียบกับตัวจำแนกประเภท 3-4

รูปที่ 10 การแบ่งข้อมูลด้วยตัวจำแนกแบบสองประเภททุกแบบที่เป็นไปได้ กรณีปัญหา 4 ประเภท

ค่า *UnBalancedScore* ของตัวจำแนก 1-2 =  $2 + 2 - 0.5 | 2-2 | = 4$

ค่า *UnBalancedScore* ของตัวจำแนก 1-3 =  $3 + 2 - 0.5 | 3-2 | = 4.5$

ค่า *UnBalancedScore* ของตัวจำแนก 1-4 =  $3 + 2 - 0.5 | 3-2 | = 4.5$


ค่า *UnBalancedScore* ของตัวจำแนก 2-3 =  $3 + 2 - 0.5 | 3-2 | = 4.5$

ค่า *UnBalancedScore* ของตัวจำแนก 2-4 =  $3 + 2 - 0.5 | 3-2 | = 4.5$

ค่า *UnBalancedScore* ของตัวจำแนก 3-4 =  $3 + 2 - 0.5 | 3-2 | = 4.5$

ดังนั้นตัวจำแนกที่ให้ค่า *UnBalancedScore* ต่ำสุดคือ 1-2 จึงได้ว่าโนดแรกหรือโนดรากของต้นไม้สำหรับการจำแนกแบบหลายประเภทของปัญหานี้ คือ ตัวจำแนกแบบสองประเภท 1-2 นั้นเอง

ในรอบต่อๆ มาก็ใช้วิธีการเดียวกันโดยต้นไม้สำหรับการจำแนกแบบหลายประเภทที่สร้างจากค่า *UnBalancedScore* ของข้อมูลชุดดังกล่าว กรณีที่ดีที่สุดแสดงดังรูปที่ 11



รูปที่ 11 โครงสร้างการจำแนกข้อมูลของการแตกครึ่งแบบสมดุล กรณีปัญหา 4 ประเภท

เมื่อพิจารณารูปที่ 10(ค) และ 10(ง) พบว่าตัวจำแนก 1-4 และ 2-3 แบ่งประเภทข้อมูลด้านบวกมีจำนวนประเภทเป็น 3 และด้านลบมีจำนวนประเภทเป็น 2 ทั้งคู่ โดยเมื่อไปคำนวณค่า *UnBalancedScore* จึงให้ค่าที่เท่ากัน หากพิจารณาด้วยสายตาจะพบว่าตัวจำแนก 2-3 มีแนวโน้มที่ดีกว่าเนื่องจากแบ่งข้อมูลประเภทที่ 2 แล้วมีเพียง 1 ใน 8 ที่ตกอยู่ในด้านบวกขณะที่ข้อมูลประเภทเดียวกันที่เหลือตกอยู่ในด้านลบทั้งหมด แต่ตัวจำแนก 1-4 เมื่อใช้จำแนกข้อมูลประเภทที่ 2 พบว่าข้อมูลตกอยู่ทั้งด้านบวกและด้านลบอย่างละครึ่ง ตรงจุดนี้จึงเห็นว่าฟังก์ชัน *UnBalancedScore* ไม่สามารถแยกได้ว่าตัวจำแนก 2 ตัวนี้ ตัวไหนที่มีแนวโน้มในการจำแนกประเภทได้ดีกว่ากันซึ่งนับเป็นจุดอ่อนอย่างหนึ่งของเทคนิคการแตกครึ่งแบบสมดุล

สำหรับวิธีนี้หากได้ระนาบที่แบ่งประเภทข้อมูลแล้วให้จำนวนประเภทที่ตกอยู่แต่ละด้านของระนาบมีค่าเท่ากันนั่นคือ ต้นไม้ที่ได้จะเป็นต้นไม้แบบสมดุลที่สุดและต้นไม้ต้นนั้นย่อมมีแนวโน้มที่จะให้ค่าเฉลี่ยของจำนวนครั้งในการจำแนกที่ต่ำด้วย วิธีนี้จะใช้ลดจำนวนครั้งในการจำแนกได้ดีในกรณีที่ความน่าจะเป็นในการเกิดข้อมูลแต่ละประเภทมีค่าใกล้เคียงกันซึ่งในทางปฏิบัติได้เป็นเช่นนั้นไม่ หากยังคงสร้างต้นไม้โดยเป็นต้นไม้ที่สมดุลอยู่ เมื่อนำต้นไม้นี้ไปใช้ก็จะให้จำนวนครั้งเฉลี่ยในการจำแนกประเภทข้อมูลสูงโดยไม่จำเป็น จึงเป็นที่มาของงานวิจัยชิ้นนี้ซึ่งจะได้อธิบายรายละเอียดของแนวคิดใหม่ในบทถัดไป