

บทที่ 2

ทฤษฎีที่เกี่ยวข้องกับการสกัดความรู้

ทฤษฎีต่าง ๆ ที่นำมาใช้ในการสกัดความรู้เพื่อให้สามารถสกัดความรู้ที่อยู่ในรูปของกฎ “ถ้า-แล้ว” ประกอบด้วย แผนที่การจัดกลุ่มเอง (Self-Organizing Map) หลักเอ็นโทรปีค่าต่ำสุด (Minimization Entropy Principle) ฟัซซีเซต (Fuzzy Set) และราฟเซต (Rough Set) รายละเอียดดังต่อไปนี้

2.1 แผนที่การจัดกลุ่มเอง (Self-Organizing Map)

แผนที่การจัดกลุ่มเองเป็นโครงข่ายประสาทเทียมประเภทหนึ่งที่มีการเรียนรู้แบบไม่มีผู้สอน ซึ่งเป็นเทคนิคหนึ่งของการทำเหมืองข้อมูล โดยทำการจัดกลุ่มข้อมูลที่มีลักษณะเหมือนกันให้อยู่ในกลุ่มเดียวกัน และทำการลดมิติข้อมูลให้อยู่ที่ 1 มิติ หรือ 2 มิติ มีประโยชน์คือทำให้สามารถเข้าใจลักษณะของข้อมูลในภาพรวมได้ ซึ่งในส่วนถัดไปจะกล่าวถึงการเรียนรู้ของแผนที่การจัดกลุ่มเองที่เป็นการเรียนรู้แบบแข่งขัน (Competitive Learning) การทำงานของแผนที่การจัดกลุ่มเอง ฟังก์ชันเพื่อนบ้าน (Neighborhood Function) และอัตราการเรียนรู้ (Learning Rate) โดยมีรายละเอียดดังนี้

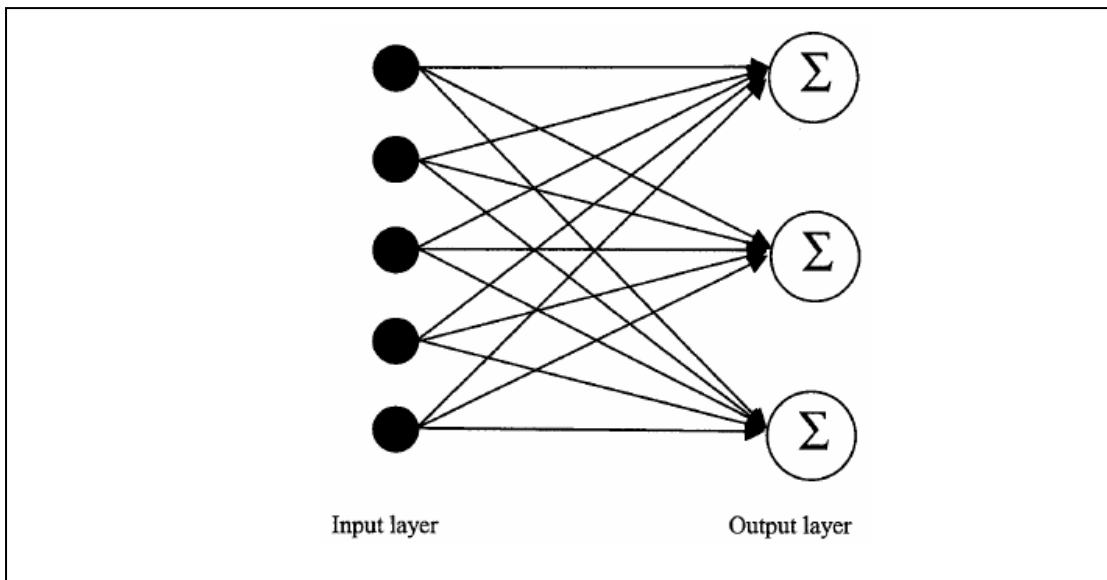
2.1.1 การเรียนรู้แบบแข่งขัน (Competitive Learning)

การเรียนรู้แบบแข่งขันเป็นการเรียนรู้ที่ไม่มีผู้สอน โดยที่ไม่จำเป็นต้องมีตัวอย่างในการสอน การเรียนรู้แบบแข่งขันประกอบด้วยโครงข่ายประสาทเทียมชั้นข้อมูลเข้า (Input Layer) 1 ชั้น และชั้นผลลัพธ์ (Output Layer) 1 ชั้น ดังตัวอย่างภาพประกอบ 2.1 [28]

เวกเตอร์ข้อมูลเข้าในชั้นข้อมูลเข้าของโครงข่ายการเรียนรู้แบบแข่งขันถูกเชื่อมต่อกับชั้นผลลัพธ์ด้วยเวกเตอร์น้ำหนัก (Weight Vector) ระหว่างการเรียนรู้นั้นเวกเตอร์ข้อมูลเข้าจะถูกแทนเข้าไปในโครงข่ายและมีการคำนวณหาผลผลิตที่มีลักษณะใกล้เคียงกับเวกเตอร์ข้อมูลเข้ามากที่สุด หรือเป็นนิรอนที่ชนะในการแข่งขัน ซึ่งคำนวณจากระยะห่างที่น้อยที่สุดระหว่างเวกเตอร์ข้อมูลเข้ากับเวกเตอร์น้ำหนักโดยใช้หลักการของ Euclidean Distance หลังจากนั้นนิรอนผลลัพธ์ที่เป็นผู้ชนะจะทำการปรับค่าเวกเตอร์น้ำหนักเพื่อให้ใกล้เคียงกับเวกเตอร์ข้อมูลเข้า ซึ่งการปรับค่าเวกเตอร์น้ำหนักนี้จะเรียกว่า “Winner-Takes-All Learning”

กำหนดให้ X คือ เวกเตอร์ข้อมูลเข้า, W คือ เวกเตอร์น้ำหนักของแต่ละนิรอนผลลัพธ์ ดังนั้นระยะห่างระหว่างเวกเตอร์ข้อมูลเข้า X และ เวกเตอร์น้ำหนักของนิรอนผลลัพธ์ตัวที่ i โดยใช้หลักการของ Euclidean Distance ดังสมการ (2.1)

$$\|X(t) - W_i(t)\| \quad (2.1)$$



ภาพประกอบ 2.1 โครงข่ายของการเรียนรู้แบบแข่งขัน (The competitive learning network)


ดังนั้นนิวรอนผลลัพธ์ตัวที่ c ที่มีระยะห่างน้อยที่สุดจะเป็นผู้ชนะ ซึ่ง W_c คือ นิวรอนผลลัพธ์ที่มีระยะห่างน้อยที่สุด ดังสมการ (2.2)

$$\|X(t) - W_c(t)\| = \min_i \{\|X(t) - W_i(t)\|\} \quad (2.2)$$

หลังจากหานิวรอนผลลัพธ์ที่มีระยะห่างน้อยที่สุดได้แล้ว เวกเตอร์น้ำหนักของนิวรอนผลลัพธ์นั้น จะทำการปรับค่าน้ำหนักใหม่เพื่อให้ใกล้เคียงกับเวกเตอร์ข้อมูลเข้า X ซึ่ง W_{new} คือ เวกเตอร์น้ำหนักใหม่, W_{old} คือ เวกเตอร์น้ำหนักเก่า และ α คือ อัตราการเรียนรู้ ดังสมการ (2.3)

$$W_{new} = W_{old} + \alpha[X - W_{old}] \quad (2.3)$$

ตัวอย่างภาพประกอบ 2.2 แสดงให้เห็นเวกเตอร์น้ำหนักใหม่ (W_{new}) ของนิวรอนผลลัพธ์ที่มีระยะห่างน้อยที่สุดเคลื่อนที่เข้าหาเวกเตอร์ข้อมูลเข้า X

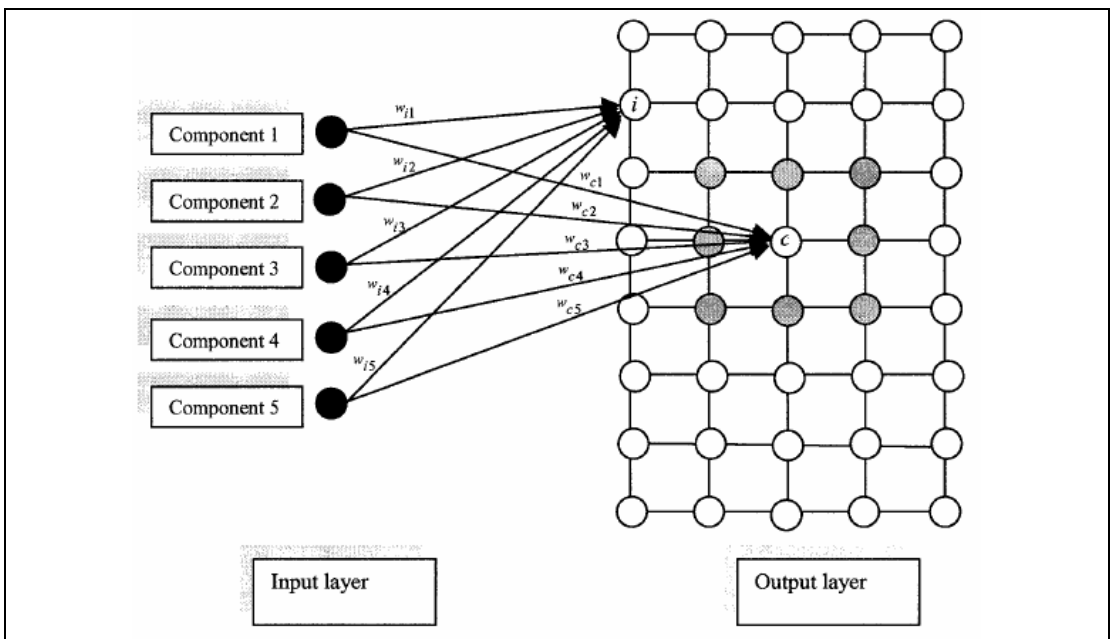


ภาพประกอบ 2.2 การปรับค่าเวกเตอร์น้ำหนักของนิวรอนที่มีระยะห่างน้อยที่สุด

2.1.2 การทำงานของแผนที่การจัดกลุ่มเอง

แผนที่การจัดกลุ่มเอง ประกอบด้วยชั้นข้อมูลเข้าและชั้นผลลัพธ์ ดัง

ตัวอย่างภาพประกอบ 2.3



ภาพประกอบ 2.3 ภาพจำลองแผนที่การจัดกลุ่มเอง

จากภาพประกอบ 2.3 มีเวกเตอร์ข้อมูลเข้า 5 มิติ ซึ่งแทนด้วยวงกลมสีดำ โดยที่จำนวนนิวรอนข้อมูลเข้านั้นขึ้นอยู่กับมิติของเวกเตอร์ข้อมูลเข้า วงกลมสีขาวที่อยู่ในชั้นผลลัพธ์แทนด้วยนิวรอนผลลัพธ์ที่อยู่บนตารางแผนที่ 2 มิติ สำหรับวงกลมสีเทาแสดงให้เห็นถึงเพื่อนบ้าน (Neighborhood) ของนิวรอน c บนตารางแผนที่

นิวรอนผลลัพธ์แต่ละตัวถูกเชื่อมกับเวกเตอร์ข้อมูลเข้าด้วยเวกเตอร์น้ำหนัก เช่นเวกเตอร์น้ำหนักของเวกเตอร์ข้อมูลเข้าตัวที่ 1 ที่เชื่อมกับนิวรอนผลลัพธ์ตัวที่ i ถูกแทนด้วย W_{i1} ดังนั้นมิติของเวกเตอร์น้ำหนักจะเท่ากับมิติของเวกเตอร์ข้อมูลเข้า จากภาพประกอบ 2.3 เวกเตอร์น้ำหนัก คือ เส้นลูกศร

สำหรับแผนที่การจัดกลุ่มเองนั้น ในชั้นข้อมูลเข้าจะแทนด้วยเวกเตอร์ข้อมูลเข้าซึ่งกำหนดให้ X คือ เวกเตอร์ข้อมูลเข้า, n คือ จำนวนมิติของข้อมูลเข้า และ t คือ รอบของการเรียนรู้ ดังสมการ (2.4)

$$X(t) = [x_1(t), x_2(t), \dots, x_n(t)] \quad (2.4)$$

สำหรับชั้นผลลัพธ์จะเป็นตารางแผนที่ 1 มิติ หรือ 2 มิติ โดยที่นิวรอนผลลัพธ์ที่อยู่บนตารางแผนที่จะเชื่อมต่อกับเวกเตอร์ข้อมูลเข้าด้วยเวกเตอร์น้ำหนัก ซึ่งกำหนดให้ $W_i(t)$ คือเวกเตอร์น้ำหนักของนิวรอนผลลัพธ์ตัวที่ i ของรอบที่ t โดยที่ $1 \leq i \leq l$ ซึ่ง l คือ จำนวนนิวรอนผลลัพธ์ทั้งหมดบนตารางแผนที่ ดังสมการ (2.5)

$$W_i(t) = [w_{i1}(t), w_{i2}(t), \dots, w_{in}(t)] \quad (2.5)$$

การเรียนรู้ของแผนที่การจัดกลุ่มเองนั้น มีการเรียนรู้แบบแข่งขัน (Competitive Learning) โดยแต่ละรอบของการเรียนรู้จะมีการเลือกนิวรอนที่ชนะ โดยใช้วิธีการ Euclidean Distance ในการคำนวณหาระยะห่างระหว่างเวกเตอร์ข้อมูลเข้ากับเวกเตอร์น้ำหนักของแต่ละนิวรอนผลลัพธ์ ดังสมการ (2.6)

$$\|X(t) - W_i(t)\| = \sqrt{\sum_{j=1}^n (x_j - w_{ij})^2} \quad (2.6)$$

สำหรับนิวรอนผลลัพธ์ตัวใดที่มีเวกเตอร์น้ำหนักใกล้เคียงกับเวกเตอร์ข้อมูลเข้าแล้วจะเรียกว่า Best Matching Unit (BMU) หรือเป็นนิวรอนผลลัพธ์ที่ชนะในการเรียนรู้แบบแข่งขันของแต่ละรอบเวลา t กำหนดให้ $W_c(t)$ คือ นิวรอนผลลัพธ์ตัวที่ c ที่มีเวกเตอร์น้ำหนักใกล้เคียงกับเวกเตอร์ข้อมูลเข้า หรือเป็น BMU ดังสมการ (2.7)

$$\|X(t) - W_c(t)\| = \min_i \{\|X(t) - W_i(t)\|\} \quad (2.7)$$

หลังจากหา BMU ได้แล้ว เวกเตอร์น้ำหนักของ BMU และเวกเตอร์น้ำหนักเพื่อนบ้านของ BMU จะมีการปรับค่าน้ำหนักใหม่เพื่อให้ใกล้เคียงกับเวกเตอร์ข้อมูลเข้า ซึ่งกำหนดให้ $W_i(t+1)$ คือ ค่าเวกเตอร์น้ำหนักใหม่, $\alpha(t)$ คือ อัตราการเรียนรู้ และ $h_{ci}(t)$ คือ ฟังก์ชันเพื่อนบ้าน (Neighborhood Function) ดังสมการ (2.8)

$$W_i(t+1) = W_i(t) + \alpha(t)h_{ci}(t)[X(t) - W_i(t)] \quad (2.8)$$

หลังจากที่ได้ปรับค่าน้ำหนักใหม่ของ BMU และเพื่อนบ้านของ BMU แล้ว เวกเตอร์ข้อมูลเข้าตัวถัดไปจะถูกแทนเข้าไปในชั้นข้อมูลเข้าและทำการหา BMU ต่อไป สำหรับขั้นตอนการเรียนรู้ของแผนที่มีการจัดกลุ่มเอง จะหยุดจัดกลุ่มก็ต่อเมื่อจำนวนรอบการทำงานเกินกว่าที่กำหนดไว้แล้ว

สรุปขั้นตอนการเรียนรู้ของแผนที่มีการจัดกลุ่มเอง ดังนี้

ขั้นตอนที่ 1 : กำหนดค่าเริ่มต้นให้กับเวกเตอร์น้ำหนักของนิวรอนผลลัพธ์ทุก ๆ ตัวที่อยู่บนตารางแผนที่, กำหนดฟังก์ชันเพื่อนบ้าน (Neighborhood Function) และกำหนดอัตราการเรียนรู้ (Learning Rate)

ขั้นตอนที่ 2 : พิจารณาเงื่อนไขของการหยุดจัดกลุ่ม ถ้ายังไม่หยุดจัดกลุ่ม ให้ทำขั้นตอนที่ 3 ถึง ขั้นตอนี่ 6

ขั้นตอนที่ 3 : แต่ละรอบของการเรียนรู้ t ทำการสุ่มเวกเตอร์ข้อมูลเข้า $X(t)$

- คำนวณหาระยะห่างระหว่างเวกเตอร์ข้อมูลเข้ากับเวกเตอร์น้ำหนักของทุก ๆ นิวรอนผลลัพธ์

$$\|X(t) - W_i(t)\| = \sqrt{\sum_{j=1}^n (x_j - w_{ij})^2}$$

- หา Best Matching Unit (BMU)

$$\|X(t) - W_c(t)\| = \min_i \{\|X(t) - W_i(t)\|\}$$

- ปรับค่าน้ำหนักใหม่ของเวกเตอร์น้ำหนักของ BMU และเวกเตอร์น้ำหนักเพื่อนบ้านของ BMU เพื่อให้ใกล้เคียงกับเวกเตอร์ข้อมูลเข้า

$$W_i(t+1) = W_i(t) + \alpha(t)h_{ci}(t)[X(t) - W_i(t)]$$

ขั้นตอนที่ 4 : ลดอัตราการเรียนรู้

ขั้นตอนที่ 5 : ลดขนาดของฟังก์ชันเพื่อนบ้าน

ขั้นตอนที่ 6 : พิจารณาเงื่อนไขของการหยุดจัดกลุ่ม ถ้ายังไม่เป็นตามเงื่อนไขที่ต้องการ ให้ไปทำซ้ำขั้นตอนที่ 3

2.1.3 ฟังก์ชันเพื่อนบ้าน (The Neighborhood Function)

ฟังก์ชันเพื่อนบ้าน ($h_{ci}(t)$) ของแผนที่การจัดกลุ่มเองที่ใช้โดยทั่วไป มี 2 ชนิด คือ ฟังก์ชันเพื่อนบ้านแบบบับเบิล (The Bubble-based Neighborhood) และฟังก์ชันเพื่อนบ้านแบบเกาส์เซียน (Gaussian-based Neighborhood)

2.1.3.1 ฟังก์ชันเพื่อนบ้านแบบบับเบิล (The Bubble-based Neighborhood)


กำหนดให้ $N_c(t)$ คือ กลุ่มเพื่อนบ้านของนิวรอนที่เป็น BMU หรือนิวรอนตัวที่ c ในรอบเวลา t และ $N_c(t)$ จะลดลงตามอัตราการเรียนรู้ สำหรับฟังก์ชันเพื่อนบ้านแบบบับเบิลแสดงได้ดัง สมการ (2.9)

$$h_{ci}(t) = \begin{cases} 1; & i = N_c(t) \\ 0; & i \neq N_c(t) \end{cases} \quad (2.9)$$

เวกเตอร์น้ำหนักของนิวรอนที่เป็นผู้ชนะหรือเรียกว่า BMU และนิวรอนเพื่อนบ้านของ BMU มีการปรับค่าโดยตรง ส่วนนิวรอนที่ไม่ใช่เพื่อนบ้านของ BMU ก็จะไม่มีการปรับค่าใหม่ ดังสมการ (2.10)

$$W_i(t+1) = \begin{cases} W_i(t) + \alpha(t)[X(t) - W_i(t)]; & i = N_c(t) \\ W_i(t); & i \neq N_c(t) \end{cases} \quad (2.10)$$

สำหรับฟังก์ชันเพื่อนบ้านแบบนี้ ค่าเวกเตอร์น้ำหนักของกลุ่มเพื่อนบ้านจะมีการปรับค่าน้ำหนักตามอัตราการเรียนรู้ ดังตัวอย่างภาพประกอบ 2.4



ภาพประกอบ 2.4 การปรับค่าของนิวรอนโดยใช้ฟังก์ชันเพื่อนบ้านแบบบับเบิล

จากภาพประกอบ 2.4 เป็นการปรับค่านิวรอนผลลัพธ์เมื่อค่ารัศมีของ $N_c(t)$ มีค่าเท่ากับ 3 โดยที่จุดสีขาว คือ นิวรอนที่อยู่บนตารางแผนที่ และจุดสีดำ คือ นิวรอนที่ได้มีการปรับค่าแล้ว


2.1.3.2 ฟังก์ชันเพื่อนบ้านแบบเกาส์เซียน (The Gaussian-based Neighborhood)

สำหรับฟังก์ชันเพื่อนบ้านแบบเกาส์เซียนนี้จะมีการปรับค่าเวกเตอร์น้ำหนักของทุกๆ นิวรอนผลลัพธ์ระหว่างการเรียนรู้ โดยที่นิวรอนเพื่อนบ้านที่ใกล้เคียงกับ BMU จะมีการปรับค่าเวกเตอร์น้ำหนักมากกว่าหรือมีผลกระทบมากกว่านิวรอนตัวอื่นๆ ที่ไกลจาก BMU ออกไป

กำหนดให้ d_i คือ ตำแหน่งของนิวรอนบนตารางแผนที่ และ d_c คือ ตำแหน่งของนิวรอนที่เป็น BMU บนตารางแผนที่ ดังนั้น $\|d_c - d_i\|$ คือระยะทางระหว่างนิวรอนตัวที่ c ที่เป็น BMU และนิวรอนเพื่อนบ้านตัวที่ i บนตารางแผนที่ และ $\sigma(t)$ คือ ค่าความแปรปรวนของนิวรอนเพื่อนบ้านในรอบเวลา t ซึ่งเป็นตัวควบคุมขนาดของนิวรอนเพื่อนบ้านสำหรับฟังก์ชันเพื่อนบ้านแบบเกาส์เซียนเป็นดังสมการ (2.11)

$$h_{ci} = e^{-\frac{\|d_c - d_i\|^2}{2\sigma^2(t)}} \quad (2.11)$$

ภาพประกอบ 2.5 แสดงให้เห็นฟังก์ชันเพื่อนบ้านแบบเกาส์เซียนและระยะทางระหว่างนิวรอนตัวที่ c ที่เป็น BMU และนิวรอนเพื่อนบ้านตัวที่ i บนตารางแผนที่



ภาพประกอบ 2.5 ฟังก์ชันเพื่อนบ้านแบบเกาส์เซียนและระดับค่าความแปรปรวน ($\sigma(t)$)

จะเห็นว่าในตอนแรกขนาดเพื่อนบ้านของ BMU มีขนาดใหญ่ และจะลดลงไปเรื่อยๆ ตามระดับค่าความแปรปรวน และในตอนสุดท้ายเพื่อนบ้านที่อยู่ใกล้เคียงกับ BMU มากที่สุดเท่านั้นจะมีการปรับค่า

2.1.4 อัตราการเรียนรู้ (Learning Rate)

สำหรับการกำหนดอัตราการเรียนรู้ ($\alpha(t)$) เริ่มต้น ควรกำหนดให้มีค่าใกล้ๆ 1 หลังจากนั้นในแต่ละรอบการเรียนรู้ให้ลดค่าอัตราการเรียนรู้ไปเรื่อยๆ จนถึงรอบการเรียนรู้สุดท้าย โดยส่วนมากอัตราการเรียนรู้จะอยู่ระหว่าง $0 < \alpha(t) \leq 1$

สำหรับการลดค่าอัตราการเรียนรู้นี้อาจเป็นแบบเอ็กซ์โพเนนเชียล กำหนดให้ α_0 คือ อัตราการเรียนรู้เริ่มต้น, t คือ รอบเวลาการเรียนรู้ และ N คือ จำนวนรอบที่กำหนดไว้สำหรับการเรียนรู้ ดังสมการ (2.12)

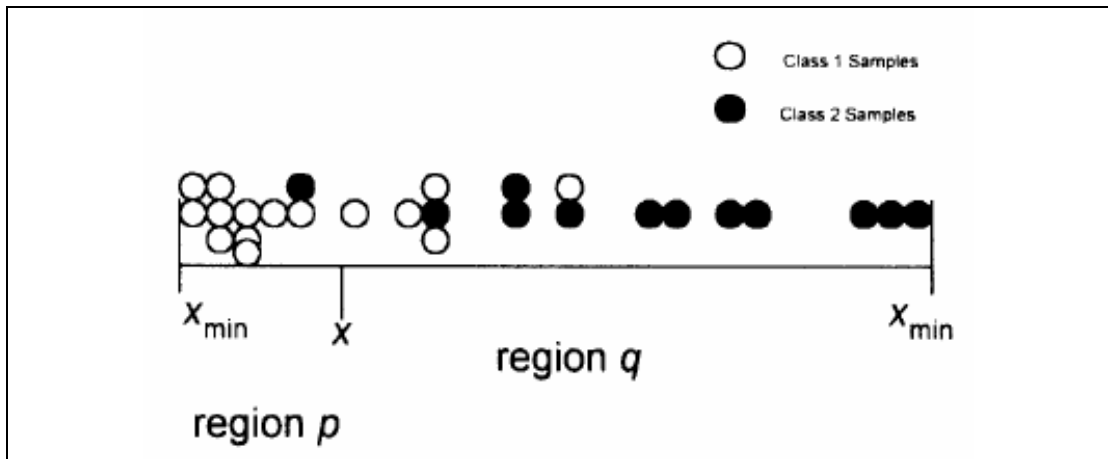
$$\alpha(t) = \alpha_0 e^{-\left(\frac{t}{N}\right)} \quad (2.12)$$

2.2 หลักเอ็นโทรปีค่าต่ำสุด (Minimization Entropy Principle)

สำหรับแนวคิดเบื้องต้นของหลักเอ็นโทรปีที่เกี่ยวข้องกับการจัดกลุ่ม คือ การหาสิ่งที่ทำให้กลุ่มที่เรากำลังสนใจอยู่มีความแตกต่างจากกลุ่มอื่น หรือหาขอบเขตที่ทำให้เกิดการแบ่งแยกกลุ่มได้ชัดเจนที่สุด [29]

หลักเอ็นโทรปีค่าต่ำสุด เป็นค่าที่บอกถึงความคาดหวังของข้อมูล ซึ่งถ้ามีข้อมูลหรือมีเนื้อหาเกี่ยวกับสิ่งนั้นๆ อยู่แล้ว ก็ไม่จำเป็นต้องใช้ข้อมูลอื่นๆ เพิ่มเติมเพื่อการตัดสินใจมากนัก เนื่องจากมีข้อมูลที่เพียงพออยู่แล้วสำหรับการตัดสินใจ

หลักเอ็นโทรปีค่าต่ำสุดเป็นหลักการที่นำมาใช้ในการสร้างฟังก์ชันความเป็นสมาชิกแบบอัตโนมัติ โดยทำการเลือกจุดแบ่งที่ดีที่สุดที่ใช้ในการแบ่งข้อมูลออกเป็น 2 กลุ่ม และจุดแบ่งที่ถูกเลือกมาต้องมีค่าเอ็นโทรปีค่าต่ำที่สุด ซึ่งจุดแบ่งเหล่านี้จะเป็นตัวกำหนดช่วงค่าของฟังก์ชันความเป็นสมาชิก



ภาพประกอบ 2.6 การคำนวณหาเอ็นโทรปีค่าต่ำสุดของจุดแบ่งข้อมูล

จากภาพประกอบ 2.6 ต้องการหาจุดแบ่งที่ดีที่สุดในการแบ่งข้อมูลออกเป็น 2 กลุ่ม กำหนดให้จุดแบ่งข้อมูล คือ x ถ้าต้องการหาจุดแบ่งข้อมูลที่ดีที่สุดซึ่งอยู่ระหว่างข้อมูลตัวอย่างที่อยู่ในช่วงค่า x_{min} กับ x_{max} โดยการคำนวณหาค่าเอ็นโทรปีของแต่ละจุดแบ่งข้อมูล (x) ระหว่างขอบเขต $p[x_{min}, x]$ และขอบเขต $q[x, x_{max}]$ ดังสมการ (2.13)

$$S(x) = p(x)S_p(x) + q(x)S_q(x) \quad (2.13)$$

จากสมการ (2.13) $p(x)$ คือ สัดส่วนของข้อมูลทั้งหมดในขอบเขต p , $q(x)$ คือ สัดส่วนของข้อมูลทั้งหมดในขอบเขต q โดยที่ $p(x) + q(x) = 1$ เสมอ

โดยแต่ละขอบเขตสามารถกำหนดค่าเอ็นโทรปีของแต่ละขอบเขตได้ กำหนดให้ $S_p(x)$ คือ ค่าเอ็นโทรปีของขอบเขต p และ $S_q(x)$ คือ ค่าเอ็นโทรปีของขอบเขต q ซึ่งสามารถคำนวณได้จากสมการ (2.14) และ (2.15) ตามลำดับ

$$S_p(x) = -(p_1(x) \ln p_1(x) + p_2(x) \ln p_2(x)) \quad (2.14)$$

$$S_q(x) = -(q_1(x) \ln q_1(x) + q_2(x) \ln q_2(x)) \quad (2.15)$$

โดยที่ค่า $p_k(x)$ คือ ความเป็นไปได้ที่ข้อมูลกลุ่ม k ที่อยู่ในขอบเขต p และ $q_k(x)$ คือ ความเป็นไปได้ที่ข้อมูลกลุ่ม k อยู่ในขอบเขต q คำนวณได้ดังสมการ (2.16) ถึง (2.19) ตามลำดับ

$$p_k(x) = \frac{n_k(x)+1}{n(x)+1} \quad (2.16)$$

$$p(x) = \frac{n(x)+1}{n+1} \quad (2.17)$$

$$q_k(x) = \frac{m_k(x)+1}{m(x)+1} \quad (2.18)$$

$$q(x) = \frac{m(x)+1}{n+1} \quad (2.19)$$

โดยที่ $n_k(x)$ คือ จำนวนข้อมูลกลุ่ม k ที่อยู่ในขอบเขต p , $m_k(x)$ คือ จำนวนข้อมูลกลุ่ม k ที่อยู่ในขอบเขต q , $n(x)$ คือ จำนวนข้อมูลทั้งหมดที่อยู่ในขอบเขต p , $m(x)$ คือ จำนวนข้อมูลทั้งหมดที่อยู่ในขอบเขต q , และ n คือ จำนวนข้อมูลทั้งหมดที่อยู่ในขอบเขต p และขอบเขต q รวมกัน

2.3 ฟัซซีเซต (Fuzzy Set)

ฟัซซีเซตเป็นเซตที่แสดงถึงความสัมพันธ์ของสมาชิกภายในกลุ่มแต่ละตัวกับค่าจำกัดความของเซตนั้น ๆ โดยความสัมพันธ์นี้จะถูกแสดงอยู่ในลักษณะของระดับความเป็นสมาชิกที่มีค่าอยู่ในช่วง $[0, 1]$ แทนที่จะแสดงว่าสมาชิกตัวใดเป็นสมาชิกหรือไม่เป็นสมาชิกของเซตนั้นอย่างเซตธรรมดา ที่มีค่าเป็น $\{0, 1\}$ [22]

ตัวแปรฟัซซีเซต (Fuzzy Variable) หรือเรียกว่าตัวแปร Linguistic ซึ่งเป็นฟัซซีเซตใด ๆ ของระบบที่เราสนใจ เช่น ถ้าพิจารณา “ความกว้างของกลีบดอกไม้ม” ซึ่งเป็นตัวแปรฟัซซีและถ้าค่าของตัวแปรของเซตนี้ คือ {เล็ก, กลาง, ใหญ่} ซึ่งจะเรียกค่าของตัวแปรนี้ว่า เทอมเซต (Term Set) ซึ่งในส่วนถัดไปจะกล่าวถึงการแทนข้อมูลด้วยฟัซซีเซต และฟังก์ชันความเป็นสมาชิก

2.3.1 การแทนข้อมูลด้วยฟัซซีเซต


เพื่อให้สามารถเข้าใจความหมายของฟัซซีเซตได้ชัดเจน จะทำการเปรียบเทียบการแทนข้อมูลของฟัซซีเซตกับเซตธรรมดา สำหรับเซตธรรมดา การแปลงข้อมูลเพื่อคำนวณหาค่าความเป็นสมานั้นจะต้องมีการกำหนดค่าเทรชโฮลด์ (Threshold) เพื่อตัดสินว่าสมาชิกตัวใดอยู่ในเซตที่เรากำลังพิจารณาอยู่บ้าง

ตัวอย่างเช่น กำหนดให้เซต A คือ เซตอุณหภูมิของประเทศหนึ่งอยู่ในช่วง $2 - 40$ องศาเซลเซียส และ x_i คือ อุณหภูมิของบริเวณที่ i

ในกรณีของเซตธรรมดาจะต้องมีการกำหนดค่าเทรชโฮลด์ (Threshold) ซึ่งในที่นี้กำหนดให้เท่ากับ 30 องศาเซลเซียส คือ ถ้าอุณหภูมิมีค่ามากกว่าหรือเท่ากับ 30 องศาเซลเซียส แสดงว่าอุณหภูมิในบริเวณนั้นร้อน (เป็นสมาชิกของเซต A) ซึ่งสามารถเขียนเป็นฟังก์ชันคุณลักษณะหรือฟังก์ชันความเป็นสมาชิก ได้ดังสมการ (2.20)

$$\mu_A(x_i) = \{x_i \geq 30\} \quad (2.20)$$

จากสมการข้างต้นสามารถนำมาเขียนเป็นกราฟของความเป็นสมาชิกได้ ดังภาพประกอบ 2.7




ภาพประกอบ 2.7 ค่าความเป็นสมาชิกของเซต A ในกรณีที่เป็นเซตธรรมดา

จากภาพประกอบ 2.7 แกน x คือ อุณหภูมิ (องศาเซลเซียส) และแกน y คือ ค่าระดับความเป็นสมาชิกที่มีค่าเป็น 0 (ไม่เป็นสมาชิกของเซต A) และ 1 (เป็นสมาชิกของเซต A) จะเห็นได้ว่าอุณหภูมิที่มากกว่าหรือเท่ากับ 30 องศาเซลเซียส ถือว่าเป็นอุณหภูมิที่สูง

ในกรณีของฟัซซี่เซต ฟังก์ชันความเป็นสมาชิกจะมีความยืดหยุ่นมากกว่า และสอดคล้องกับความเป็นจริงมากกว่าเซตธรรมดา ดังสมการ (2.21)

$$\mu_A(x_i) = \begin{cases} \frac{1}{(30-20)}(x_i - 20); 20 \leq x_i \leq 30 \\ 1; x_i > 30 \\ 0; \text{กรณีอื่นๆ} \end{cases} \quad (2.21)$$

จากสมการ (2.21) เป็นการกำหนดค่าความเป็นสมาชิกให้กับเทอมเซตของอุณหภูมิสูง และภาพประกอบ 2.8 แสดงกราฟระดับความเป็นสมาชิกของสมการ (2.21) ดังนี้



ภาพประกอบ 2.8 ค่าความเป็นสมาชิกของเซต A ในกรณีที่เป็นฟuzzyเซต

เมื่อเปรียบเทียบฟังก์ชันความเป็นสมาชิกจากภาพประกอบ 2.7 กับภาพประกอบ 2.8 จะเห็นว่ากราฟที่แสดงความเป็นสมาชิกของฟuzzyเซตจะมีความต่อเนื่องในค่าระดับความเป็นสมาชิกในช่วง $[0, 1]$ เช่น อุณหภูมิที่บริเวณหนึ่งเป็น 25 องศาเซลเซียส แสดงว่าเป็นอุณหภูมิที่สูงเช่นกัน แต่จะมีระดับความเป็นสมาชิกของเซตอุณหภูมิสูง คือ 0.5 แต่ถ้าเป็นเซตธรรมดาแล้ว อุณหภูมิ 25 องศาเซลเซียส จะไม่เป็นสมาชิกของเซต A หรือแม้แต่อุณหภูมิ 29 องศาเซลเซียส ก็จะไม่ถือว่าเป็นอุณหภูมิสูงเช่นกัน ซึ่งไม่ตรงกับความเป็นจริง แต่สำหรับการแทนข้อมูลด้วยฟuzzyเซตจะถือว่าอุณหภูมิ 29 องศาเซลเซียสเป็นเซตของอุณหภูมิสูงด้วยค่าความเป็นสมาชิกเท่ากับ 0.9

2.3.2 ฟังก์ชันความเป็นสมาชิก (Membership Function)

ฟังก์ชันความเป็นสมาชิกแบบต่างๆ ที่ใช้ในการประมาณค่าระดับความเป็นสมาชิกของแต่ละเทอมเซตแบบประมาณค่าเชิงเส้น เช่น รูปสามเหลี่ยม, รูปสี่เหลี่ยมคางหมู ซึ่งมีรายละเอียด ดังนี้

2.3.2.1 รูปสามเหลี่ยม

การกำหนดฟังก์ชันความเป็นสมาชิกโดยใช้รูปสามเหลี่ยม เทอมเซตที่กำหนดโดยฟังก์ชันนี้จะต้องมีค่าที่เหมาะสมที่สุดอยู่เพียงค่าเดียวที่ทำให้ค่าความเป็นสมาชิกเท่ากับ 1 ส่วนค่าอื่นๆ จะมีค่าความเป็นสมาชิกลดลงเรื่อยๆ ถ้ากำหนดให้ $a \leq b \leq c$ เมื่อ a , b , และ c เป็นเลขจำนวนจริงใดๆ ดังนั้นฟังก์ชันความเป็นสมาชิกของรูปสามเหลี่ยมสามารถกำหนดได้ดังสมการ (2.22)

$$\mu_A(x_i) = \begin{cases} \frac{1}{b-a}(x_i - a); a \leq x_i \leq b, a \neq b \\ \frac{1}{c-b}(c - x_i); b < x_i \leq c, b \neq c \\ 0 ; \text{กรณีอื่นๆ} \end{cases} \quad (2.22)$$


2.3.2.2 รูปสี่เหลี่ยมคางหมู

การกำหนดฟังก์ชันความเป็นสมาชิกโดยใช้รูปสี่เหลี่ยมคางหมู เทอมเซตที่กำหนดโดยฟังก์ชันนี้จะต้องมีช่วงค่าที่เหมาะสมมากที่สุดอยู่กลุ่มหนึ่งที่ทำให้ค่าความเป็นสมาชิกของเทอมเซตนั้นๆ มีค่าเท่ากับ 1 ส่วนค่าอื่นๆ จะมีค่าความเป็นสมาชิกลดลงเรื่อยๆ ถ้ากำหนดให้ $a \leq b \leq c \leq d$ เมื่อ a, b, c และ d เป็นเลขจำนวนจริงใดๆ ดังนั้นฟังก์ชันความเป็นสมาชิกของรูปสี่เหลี่ยมคางหมูสามารถกำหนดได้ดังสมการ (2.23)

$$\mu_A(x_i) = \begin{cases} \frac{1}{b-a}(v_r - a); a \leq v_r \leq b, a \neq b \\ 1 ; b < x_i \leq c \\ \frac{1}{d-c}(d - v_r); c < v_r \leq d, c \neq d \\ 0 ; \text{กรณีอื่นๆ} \end{cases} \quad (2.23)$$

2.4 ราวเฟเซต (Rough Set)

ราวเฟเซตเป็นวิธีการที่ใช้จัดการเรื่องความคลุมเครือและความไม่แน่นอนของข้อมูล โดยมีการนำเรื่องการประมาณค่าขอบเขตล่าง (Lower Approximation) และการประมาณค่าขอบเขตบน (Upper Approximation) มาประยุกต์ใช้ในการจัดการเรื่องความไม่แน่นอน [25] แนวคิดของราวเฟเซตอธิบายได้ดังภาพประกอบ 2.9



ภาพประกอบ 2.9 แนวคิดของกราฟเซต

กำหนดให้ U เป็นเซตอนันต์ X เป็นสับเซตของเซตอนันต์ การประมาณค่าขอบเขตล่าง (Lower Approximation) หมายถึง สมาชิกทุกตัวของเซต B อยู่ในเซต X ดังสมการ (2.24)

$$\underline{B}X = \{x \in U : B(x) \subseteq X\} \quad (2.24)$$

การประมาณค่าขอบเขตบน (Upper Approximation) หมายถึง สมาชิกบางตัวของเซต B อยู่ในเซต X ดังสมการ (2.25)

$$\overline{B}X = \{x \in U : B(x) \cap X \neq \emptyset\} \quad (2.25)$$