

บทที่ 2


ทฤษฎีและแนวคิด

การรู้จำแบบรูปมีรูปแบบทั่วไปดังแสดงในรูปที่ 2.1 วัตถุประสงค์ที่จะทำการตรวจสอบจะถูกทำการวัดโดยใช้เซ็นเซอร์ซึ่งเป็นการวัดเชิงปริมาณ ข้อมูลที่ได้จะผ่านกระบวนการก่อนหน้า (Preprocessing) เพื่อให้ข้อมูลเหมาะสมสำหรับการใช้งานมากขึ้น จากนั้นนำข้อมูลที่ได้ผ่านเข้าสู่การสกัดค่าคุณลักษณะสำคัญ (Feature extraction) เพื่อหาคุณลักษณะสำคัญ (Feature) ของข้อมูลสำหรับการตัดสินใจในการจำแนกแบบรูป และผ่านกระบวนการภายหลัง (Postprocessing) เพื่อปรับผลการตัดสินใจตามเงื่อนไขเพิ่มเติมต่าง ๆ เพื่อให้ได้ความถูกต้องมากขึ้น ในบทนี้จะกล่าวถึงกระบวนการก่อนหน้าที่ใช้กับการรู้จำตัวอักษรแบบออนไลน์ และทฤษฎีของระบบการรู้จำ 2 ชนิด คือ แบบจำลองฮิดเดนมาร์คอฟและพีชชีโลจิก


2.1 กระบวนการก่อนหน้า

ข้อมูลของตัวอักษรแบบออนไลน์เป็นจุดคู่ลำดับ (x, y) บนจอภาพ ได้มาจากกระดานอิเล็กทรอนิกส์ (tablet) หลังจากนั้นทำการแยกองค์ประกอบเป็นส่วนย่อยโดยใช้การขึ้นลงของปากกา และระยะเวลา ระหว่าง การขึ้น และลงจากนั้นจะทำการลดจุดคู่ลำดับส่วนเกิน (Redundant) โดยใช้ขั้นตอนการหาใน Nair และ Leedham [23] ซึ่งมีขั้นตอนดังต่อไปนี้

1. ลบการยกปากกาโดยบังเอิญ
2. ทำเส้นให้เรียบ (Smoothing)
3. ทำการกรองระยะทางที่สั้น (Minimum Distance Filtering)
4. ลบ ส่วนที่เกิดขึ้นโดยไม่ตั้งใจเวลาลงปากกา หรือยกปากกาขึ้น (Serif Removal)
5. ทำนอร์มอลไลซ์ (Normalization)



รูปที่ 2.1 แผนภาพการทำงานของระบบรู้จำแบบรูป



รูปที่ 2.2 ตัวอย่างตัวอักษรที่มีหาง และกรอบตัวอักษรที่ไม่รวมหาง

สำหรับการทำออร์มอลไลซ์ในภาษาไทยนั้นจะพบตัวอักษรที่มีหางเกินเส้นบรรทัด การขยายขนาดตัวอักษรให้มีความสูงเท่ากันนั้นควรจะสนใจความสูงของตัวอักษรที่ไม่รวมส่วนหาง ดังนั้นเราจึงหากรอบของตัวอักษรเดี่ยวโดยที่หางจะไม่อยู่ในกรอบ เมื่อเราพบว่าตัวอักษรมีโอกาสเป็นหางหรือจุดปลายของตัวอักษรอยู่ด้านบนขวา เราจะพิจารณากรอบด้านบนให้สูงเท่ากับจุดที่สูงที่สุดในส่วนครึ่งด้านซ้ายของตัวอักษรแทน ตัวอย่างการหากรอบตัวอักษรแสดงในรูป 2.2

2.2 แบบจำลองฮิดเดนมาร์คอฟ

เมื่อพิจารณาถึงแบบจำลองมาร์คอฟระบบหนึ่ง ซึ่งไม่สามารถระบุได้ชัดเจนว่า ในขณะหนึ่งระบบอยู่ในสถานะใด หากแต่เราสามารถสังเกตปรากฏการณ์อื่นๆ เพื่อนำมาทำนายความน่าจะเป็นของสถานะในแบบจำลองมาร์คอฟที่เวลาใดๆ ได้ เรียกแบบจำลองดังกล่าวเป็นแบบจำลองฮิดเดนมาร์คอฟ (Hidden Markov Model) [4] โดยเราจะพิจารณาถึง แบบจำลองฮิดเดนมาร์คอฟแบบไม่ต่อเนื่อง (Discrete HMM) ก่อนเพื่อทำความเข้าใจในหลักการทำงาน แล้วจะกล่าวถึงแบบจำลองฮิดเดนมาร์คอฟแบบต่อเนื่อง (Continuous HMM) ในภายหลัง

2.2.1 องค์ประกอบของแบบจำลองฮิดเดนมาร์คอฟแบบไม่ต่อเนื่อง

1. จำนวนสถานะในแบบจำลอง (N) และกำหนดตัวแปรแทนสถานะในแบบจำลองเป็น $S = \{S_1, S_2, \dots, S_N\}$
2. จำนวนของสัญลักษณ์จากการสังเกตต่อสถานะ (M) และกำหนดตัวแปรแทนสัญลักษณ์เป็น $V = \{v_1, v_2, \dots, v_M\}$
3. การกระจายความน่าจะเป็นของการเปลี่ยนสถานะ $A = \{a_{ij}\}$ โดย

$$a_{ij} = P[q_1 = S_j | q_{t-1} = S_i], \quad 1 \leq i, j \leq N \quad (2.1)$$

4. การกระจายความน่าจะเป็นของสัญลักษณ์ที่สังเกตเมื่อทราบสถานะ j , $B = \{b_j(k)\}$ โดย

$$b_j(k) = P[v_k \text{ at } t | q_t = S_j], \quad 1 \leq j \leq N, 1 \leq k \leq M \quad (2.2)$$

5. การกระจายความน่าจะเป็นของสถานะเริ่มต้น $\pi = \{\pi_i\}$ เมื่อ

$$\pi_i = P[q_1 = S_j], \quad 1 \leq i \leq N \quad (2.3)$$

การอธิบายแบบจำลองฮิดเดนมาร์คคอฟต้องระบุจำนวนสถานะ N และจำนวนสัญลักษณ์ M ของแบบจำลอง สามารถเขียนองค์ประกอบของความน่าจะเป็นรวมกันแทนแบบจำลองได้ดังนี้

$$\lambda = (A, B, \pi) \quad (2.4)$$

2.2.2 การใช้แบบจำลองฮิดเดนมาร์คคอฟในการรู้จำ

แบบจำลองฮิดเดนมาร์คคอฟนิยมนำมาประยุกต์ใช้ในการรู้จำแบบรูป [24] โดยในการรู้จำแบบรูปที่ต้องการแยกประเภทของสิ่งที่เราสังเกตออกเป็น n ชนิด แบ่งเป็น $\lambda_1, \lambda_2, \lambda_3, \dots, \lambda_n$ จากลำดับของค่าสังเกต O สิ่งที่เราต้องการจะรู้คือความน่าจะเป็นของสิ่งที่เราสังเกตจะเป็นชนิด i , $P(\lambda_i | O)$ โดยตัดสินใจว่าสิ่งที่เราสนใจเป็นชนิดที่ i เมื่อ

$$P(\lambda_i | O) \geq P(\lambda_j | O), \quad 1 \leq i, j \leq n \quad (2.5)$$

จากกฎของเบย์ (Baye's Rule) จะได้

$$P(\lambda_i | O) = \frac{P(O | \lambda_i) P(\lambda_i)}{P(O)} \quad (2.6)$$

หากตั้งสมมติฐานว่าทุกประเภทที่จะจำแนกมีโอกาสเกิดขึ้นเท่ากัน จะพบว่า

$$P(\lambda_i | O) \propto P(O | \lambda_i) \quad (2.7)$$

ดังนั้นสิ่งที่อยากทราบอันดับแรกคือ $P(O | \lambda_i)$ เมื่อทราบแบบจำลองฮิดเดนมาร์คคอฟแล้ว สิ่งที่น่าสนใจอันดับต่อไปคือลำดับของสถานะที่แท้จริงที่เกิดขึ้นตั้งแต่เวลา 1 ถึง เวลา T ($Q = q_1 q_2 \dots q_T$) เมื่อเราทราบลำดับของค่าสังเกตในช่วงเวลานั้น ($O = O_1 O_2 \dots O_T$) เนื่องจากเป็นส่วนที่ซ่อนอยู่ในแบบจำลอง อันดับสุดท้ายคือจะสร้างแบบจำลองอย่างไรเพื่อทำให้ $P(O | \lambda_i)$ มีค่ามากที่สุด ในส่วนต่อไปจะเสนอการแก้ปัญหาทั้ง 3 ประการที่ได้กล่าวมาข้างต้น

2.2.2.1 การคำนวณหาความน่าจะเป็นของลำดับของค่าสังเกตเมื่อทราบแบบจำลองแล้ว $P(O|\lambda)$

เมื่อทราบลำดับของค่าสังเกตและแบบจำลอง $O = O_1O_2 \dots O_T$ และ λ ตามลำดับ และกำหนดให้มีลำดับของสถานะดังนี้

$$P(O|Q, \lambda) = \prod_{t=1}^T P(O_t|q_t, \lambda) \quad (2.8)$$

หากเราพิจารณาในกรณีที่ชุดสังเกตแต่ละชุดเป็นอิสระต่อกันทางสถิติจะได้

$$P(O|Q, \lambda) = b_{q_1}(O_1) \cdot b_{q_2}(O_2) \cdots b_{q_T}(O_T) \quad (2.9)$$

และ

$$P(Q|\lambda) = \pi_{q_1} \cdot a_{q_1q_2} \cdot a_{q_2q_3} \cdots a_{q_{T-1}q_T} \quad (2.10)$$

จาก

$$P(O, Q|\lambda) = P(O|Q, \lambda)P(Q|\lambda) \quad (2.11)$$

จะพบว่า


$$\begin{aligned} P(O|\lambda) &= \sum_{\text{all } Q} P(O|Q, \lambda)P(Q|\lambda) \\ &= \sum_{q_1, q_2, \dots, q_T} \pi_{q_1} b_{q_1}(O_1) a_{q_1q_2} b_{q_2}(O_2) \cdots a_{q_{T-1}q_T} b_{q_T}(O_T) \end{aligned} \quad (2.12)$$

เมื่อพิจารณาสมการที่ (2.12) จะพบว่าจะต้องการคูณกันถึง $(2T - 1)N^T$ ครั้ง ดังนั้นจึงไม่นิยมนำสมการ (2.12) ไปใช้กันในทางปฏิบัติโดยตรง เนื่องจากมีกระบวนการที่ทำงานได้เร็วกว่าคือ กระบวนการไปข้างหน้าและย้อนกลับ (Forward-Backward Procedure)

กำหนดตัวแปรไปข้างหน้า (Forward Variable: $\alpha_t(i)$) ดังนี้

$$\alpha_t(i) = P(O_1O_2 \dots O_t, q_t = S_i|\lambda) \quad (2.13)$$

กระบวนการไปข้างหน้าทำได้ดังนี้



รูปที่ 2.3 (ก) แผนภูมิลำดับการคำนวณตัวแปรไปข้างหน้า (ข) แผนภูมิในการสร้างการคำนวณ

1. เริ่มต้นด้วย

$$\alpha_1(i) = \pi_i b_i(O_1), \quad 1 \leq i \leq N \quad (2.14)$$

2. คำนวณหาค่าถัดไปตามสมการ

$$\alpha_{t+1}(j) = \left[\sum_{i=1}^N \alpha_t(i) a_{ij} \right] b_j(O_{t+1}), \quad 1 \leq t \leq T-1, 1 \leq j \leq N \quad (2.15)$$

3. จะได้ผลลัพธ์สุดท้ายคือ

$$P(O|\lambda) = \sum_{i=1}^N \alpha_T(i) \quad (2.16)$$

จะพบว่า การคำนวณตามกระบวนการข้างต้นใช้การคำนวณทั้งหมดเพียง $N^2(T-1)$ ครั้ง โดยการคำนวณสามารถแสดงได้เป็นโครงสร้างผลึกตามรูปที่ 2.3 และในทำนองเดียวกันกับกระบวนการไปข้างหน้า กระบวนการย้อนกลับจะกำหนดตัวแปรย้อนกลับ (Backward Variable: $\beta_t(i)$) ดังนี้

$$\beta_t(i) = P(O_{t+1}O_{t+2}\dots O_T | q_t = S_i, \lambda) \quad (2.17)$$

1. ตั้งค่าเริ่มต้น

$$\beta_T(i) = 1 \quad (2.18)$$

2. หาค่าตัวถัดไปได้จาก

$$\beta_t(i) = \sum_{j=1}^N a_{ij} b_j(O_{t+1}) \beta_{t+1}(j), \quad t = T-1, T-2, \dots, 1; 1 \leq i \leq N \quad (2.19)$$

2.2.2.2 การหาลำดับของสถานะที่เหมาะสม

การเลือกสถานะที่เหมาะสมควรเลือกสถานะที่น่าจะเป็นไปได้ในทางสถิติมากที่สุด โดยจะตั้งตัวแปรขึ้นหนึ่งตัวซึ่งแสดงถึงความน่าจะเป็นที่จะเกิดสถานะ i ที่เวลา t เมื่อข้อมูลที่สังเกตได้คือ O ดังนี้

$$\gamma_t(i) = P(q_t = S_i | O, \lambda) \quad (2.20)$$

หรือจะเขียนได้ในอีกรูปหนึ่งเป็น

$$\gamma_t(i) = \frac{\alpha_t(i)\beta_t(i)}{P(O|\lambda)} = \frac{\alpha_t(i)\beta_t(i)}{\sum_{i=1}^N \alpha_t(i)\beta_t(i)} \quad (2.21)$$

และมีคุณสมบัติ

$$\sum_{i=1}^N \gamma_t(i) = 1 \quad (2.22)$$

เราจะตัดสินใจว่าที่เวลา t ระบบจะมีสถานะใดโดยเราจะใช้กฎในการตัดสินใจดังนี้

$$q_t = \arg \max[\gamma_t(i)], \quad 1 \leq t \leq T \quad (2.23)$$

การเลือกสถานะโดยใช้กฎตามสมการที่ (2.23) พบว่าในบางกรณีที่มีการเปลี่ยนจากสถานะหนึ่งไปอีกสถานะหนึ่งอาจเป็นไปได้ที่จะเกิดขึ้น ($a_{ij} = 0$ สำหรับบาง i หรือ j) ดังนั้นสถานะที่เลือกอาจไม่ใช่สถานะที่ถูกต้องเสมอไป ซึ่งแก้ปัญหานี้โดยใช้อัลกอริทึมของ Viterbi

ต้องการหาลำดับของสถานะที่ดีที่สุด $Q = \{q_1 q_2 \dots q_T\}$ โดยให้

$$\delta_t(i) = \max_{q_1 q_2 \dots q_{t-1}} P[q_1 q_2 \dots q_t = i, O_1 O_2 \dots O_t | \lambda] \quad (2.24)$$

พบว่า

$$\delta_{t+1}(j) = [\max_i \delta_t(i) a_{ij}] b_j(O_{t+1}) \quad (2.25)$$

การหาลำดับของสถานะที่ดีที่สุดตามขั้นตอนดังต่อไปนี้

เริ่มต้นโดย

$$\delta_1(i) = \pi_i b_i(O_1), \quad 1 \leq i \leq N \quad (2.26)$$

ทำซ้ำตามสมการด้านล่างไปทุกๆ ค่า t

$$\delta_t(j) = \max_{1 \leq i \leq N} [\delta_{t-1}(i) a_{ij}] b_j(O_t), \quad 2 \leq t \leq T, 1 \leq j \leq N \quad (2.27)$$

$$\beta_t(j) = \arg \max_{1 \leq i \leq N} [\delta_{t-1}(i) a_{ij}], \quad 2 \leq t \leq T, 1 \leq j \leq N \quad (2.28)$$

จะได้ว่า

$$P^* = \max_{1 \leq i \leq N} [\delta_T(i)] \quad (2.29)$$

$$Q^* = \arg \max_{1 \leq i \leq N} [\delta_T(i)] \quad (2.30)$$

2.2.2.3 การหาพารามิเตอร์ของแบบจำลองที่เหมาะสม

การหาค่าพารามิเตอร์ที่เหมาะสมนั้นมีหลายกระบวนการ โดยในวิทยานิพนธ์นี้จะเสนอกระบวนการที่เข้าใจง่าย และเป็นที่ยอมรับใช้กระบวนการหนึ่งคือ การประมาณค่าซ้ำของ Baum และ Welch เนื่องจากมั่นใจได้ว่าจะสามารถสร้างแบบจำลองที่เหมาะสมได้เมื่อใช้การประมาณค่าซ้ำไปจนกระทั่งได้แบบจำลองที่ดีที่สุด

เพื่ออธิบายกระบวนการนี้เราจะกำหนด $\xi_t(i, j)$ แสดงถึงความน่าจะเป็นที่จะเกิดสถานะ S_i ที่เวลา t และเกิดสถานะ S_j ที่เวลา $t + 1$ เมื่อทราบแบบจำลองและลำดับของค่าสังเกต

$$\xi_t(i, j) = P(q_t = S_i, q_{t+1} = S_j | O, \lambda) \quad (2.31)$$

จะพบว่า $\xi_t(i, j)$ มีความสัมพันธ์กับตัวแปรไปข้างหน้า ($\alpha_t(i)$) และตัวแปรย้อนกลับ ($\beta_t(j)$) ดังนี้

$$\begin{aligned} \xi_t(i, j) &= \frac{\alpha_t(i) a_{ij} b_j(O_{t+1}) \beta_{t+1}(j)}{P(O | \lambda)} \\ &= \frac{\alpha_t(i) a_{ij} b_j(O_{t+1}) \beta_{t+1}(j)}{\sum_{i=1}^N \sum_{j=1}^N \alpha_t(i) a_{ij} b_j(O_{t+1}) \beta_{t+1}(j)} \end{aligned} \quad (2.32)$$

จากในหัวข้อที่แล้ว $\gamma_t(i)$ ซึ่งแสดงถึงความน่าจะเป็นที่จะเกิดสถานะ i ที่เวลา t มีความสัมพันธ์กับ $\xi_t(i, j)$ ดังนี้

$$\gamma_t(i) = \sum_{j=1}^N \xi_t(i, j) \quad (2.33)$$

เมื่อรวม $\gamma_t(i)$ ทุกๆ เวลา t จะได้ปริมาณที่แสดงถึงค่าคาดหวัง (Expected value) ของจำนวนครั้งที่เกิดสถานะ S_i และการรวม $\xi_t(i, j)$ ทุกๆ เวลา t หมายถึงค่าคาดหวังของจำนวนครั้งที่เปลี่ยนสถานะจาก S_i ไปยังสถานะ S_j โดยจะสรุปได้ดังนี้

$$\sum_{t=1}^{T-1} \gamma_t(i) = \text{expected number of transitions from } S_i \quad (2.34ก)$$

$$\sum_{t=1}^{T-1} \xi_t(i, j) = \text{expected number of transitions from } S_i \text{ to } S_j \quad (2.34ข)$$

จากสมการดังกล่าวจะสามารถประมาณค่าของพารามิเตอร์ของแบบจำลองฮิตเดนมาร์คอฟได้ดังนี้

$$\bar{\pi}_i = \text{expected frequency in state } S_i \text{ at time } (t = 1) = \gamma_1(i) \quad (2.35ก)$$

$$\bar{a}_{ij} = \frac{\text{expected number of transitions from } S_i \text{ to } S_j}{\text{expected number of transitions from } S_i} = \frac{\sum_{t=1}^{T-1} \xi_t(i, j)}{\sum_{t=1}^{T-1} \gamma_t(i)} \quad (2.35ข)$$

$$\bar{b}_j(k) = \frac{\text{expected number of times in state } S_j \text{ and observing symbol } v_k}{\text{expected number of times in state } S_j} = \frac{\sum_{t=1}^{T-1} \gamma_t(j)}{\sum_{t=1}^{T-1} \gamma_t(j)} \quad (2.35ค)$$

เมื่อกำหนดให้สถานะปัจจุบันเป็น $\lambda = (A, B, \pi)$ และคำนวณตามสมการ (2.35ก-2.35ค) จะได้แบบจำลองที่เกิดจากการประมาณค่าเป็น $\bar{\lambda} = (\bar{A}, \bar{B}, \bar{\pi})$ และหากนำแบบจำลองที่ได้มาใหม่ $\bar{\lambda}$ ไปแทนที่ λ และนำไปคำนวณตามสมการ (2.35ก-2.35ค) ซ้ำไปเรื่อยๆ จากการพิสูจน์ของ Baum และทีมงานพบว่าแบบจำลองที่ประมาณค่าได้ยิ่งคำนวณซ้ำหลายรอบ จะมีค่ามากขึ้นจนเข้าใกล้จุดลิมิตค่าหนึ่ง ซึ่งเป็นจุดที่ $P(O|\lambda)$ จะมีค่ามากที่สุด

2.2.3 แบบจำลองฮิตเดนมาร์คอฟแบบต่อเนื่อง

จากแบบจำลองฮิตเดนมาร์คอฟแบบไม่ต่อเนื่องที่ได้กล่าวมาข้างต้นพิจารณาเพียงสัญลักษณ์แบบไม่ต่อเนื่องที่เลือกมาจากชุดสัญลักษณ์ที่มีจำนวนจำกัด ในกรณีที่ข้อมูลสังเกตเป็นสัญญาณแบบต่อเนื่องจะนำข้อมูลนั้นมาควอนไทซ์ เพื่อให้ได้รูปแบบของสัญลักษณ์ที่จำกัด ในบางครั้งการควอนไทซ์ นั้นทำให้

เกิดความผิดพลาดในการแทนสัญลักษณ์ของข้อมูลสังเกตได้ ดังนั้นการใช้แบบจำลองฮิดเดนมาร์คอฟที่มีความหนาแน่นของข้อมูลสังเกตแบบต่อเนื่องจึงให้ผลลัพธ์ที่ดีกว่า

การนำความหนาแน่นของชุดข้อมูลสังเกตแบบต่อเนื่องมาใช้งาน โดยใช้รูปแบบของฟังก์ชันความหนาแน่นความน่าจะเป็น (Probability Density Function, pdf) จะต้องมีพารามิเตอร์ที่สามารถประมาณค่าซ้ำได้ตามวิธีการที่ได้กล่าวไปแล้ว รูปแบบของฟังก์ชันความหนาแน่นความน่าจะเป็นที่นิยมใช้คือ ฟังก์ชันความหนาแน่นผสมที่ประกอบไปด้วยฟังก์ชันความหนาแน่นย่อยชนิดเดียวกันจำนวนจำกัด ดังแสดงได้ตามสมการต่อไปนี้

$$b_j(\mathbf{O}) = \sum_{m=1}^M c_{jm} \mathcal{N}[\mathbf{O}, \boldsymbol{\mu}_{jm}, \mathbf{U}_{jm}], \quad 1 \leq j \leq N \quad (2.36)$$

เมื่อ \mathbf{O} คือเวกเตอร์สังเกตที่จะนำมาจำลองแบบ c_{jm} คือ สัมประสิทธิ์ความหนาแน่นย่อยของฟังก์ชันความหนาแน่นผสมตัวที่ m ในสถานะ j และ \mathcal{N} คือฟังก์ชันความหนาแน่นย่อย ซึ่งนิยมใช้ความหนาแน่นแบบเกาส์ โดยจะต้องมี c_{jm} ที่ตรงตามข้อกำหนดของกระบวนการแฟร็กเมนต์ (stochastic) ดังนี้

$$\sum_{m=1}^M c_{jm} = 1, \quad 1 \leq j \leq N \quad (2.37ก)$$

$$c_{jm} \geq 0, \quad 1 \leq j \leq N, 1 \leq m \leq M \quad (2.37ข)$$

และฟังก์ชันความหนาแน่นความน่าจะเป็นจะถูกนอร์มัลไลซ์ ให้เป็นดังนี้

$$\int_{-\infty}^{\infty} b_j(\mathbf{x}) d\mathbf{x} = 1, \quad 1 \leq j \leq N \quad (2.38)$$

สำหรับการประมาณค่าซ้ำเพื่อหาพารามิเตอร์ของฟังก์ชันความหนาแน่นผสม c_{jm} $\boldsymbol{\mu}_{jk}$ และ \mathbf{U}_{jk} เป็นไปตามสมการเหล่านี้

$$\bar{c}_{jk} = \frac{\sum_{t=1}^T \gamma_t(j, k)}{\sum_{t=1}^T \sum_{k=1}^M \gamma_t(j, k)} \quad (2.39)$$

$$\bar{\boldsymbol{\mu}}_{jk} = \frac{\sum_{t=1}^T \gamma_t(j, k) \cdot \mathbf{O}_t}{\sum_{t=1}^T \gamma_t(j, k)} \quad (2.40)$$

$$\bar{\mathbf{U}}_{jk} = \frac{\sum_{t=1}^T \gamma_t(j, k) \cdot (\mathbf{O}_t - \boldsymbol{\mu}_{jk})(\mathbf{O}_t - \boldsymbol{\mu}_{jk})^T}{\sum_{t=1}^T \gamma_t(j, k)} \quad (2.41)$$

เมื่อ $\gamma_t(j, k)$ คือ ความน่าจะเป็นที่จะอยู่ในสถานะ j ที่เวลา t ด้วย ฟังก์ชันความหนาแน่นผสมที่อธิบาย O_t

$$\gamma_t(j, k) = \left[\frac{\alpha_t(j)\beta_t(j)}{\sum_{j=1}^N \alpha_t(j)\beta_t(j)} \right] \left[\frac{c_{jk}\mathcal{N}(O_t, \mu_{jk}, U_{jk})}{\sum_{m=1}^M c_{jm}\mathcal{N}(O_t, \mu_{jm}, U_{jm})} \right] \quad (2.42)$$

สำหรับการประมาณค่าซ้ำของ a_{ij} นั้นเหมือนกับในกรณีไม่ต่อเนื่อง

2.3 ฟัชซีโลจิก

ทฤษฎีทางฟัชซีโลจิกได้ถูกเสนอขึ้นโดย Lofti Zadeh ในปี 1965 เป็นการนำทฤษฎีของเซตมาประยุกต์ เพื่อแสดงลักษณะที่คลุมเครือของสิ่งต่างๆ ที่มีความไม่แน่นอน หรือมีความซับซ้อน ซึ่งยากต่อการสร้างแบบจำลองทางคณิตศาสตร์ ฟัชซีโลจิกถูกนำมาเพื่อสร้างแบบจำลองที่มีความใกล้เคียงความเป็นจริง โดยมีการพิจารณาลักษณะของปัญหาที่สนใจ แล้วหาค่าความเป็นสมาชิกเพื่อเป็นตัวแปรที่นำมาตัดสินใจ [25][26] ซึ่งการประยุกต์ใช้ฟัชซีโลจิกทำให้ระบบสามารถบ่งบอกถึงความไม่แน่นอน และเมื่อมีการนำมาใช้ร่วมกับการตัดสินใจทำให้มีความยืดหยุ่นในการตัดสินใจมากยิ่งขึ้น นอกจากนี้ได้มีการนำเอาวิธีทางฟัชซีโลจิกมาประยุกต์ใช้กับงานหลาย ๆ ด้านเช่น ระบบควบคุม ระบบทางชีววิทยา และระบบรู้จำ

2.3.1 นิยามฟัชซีเซต

กำหนดให้ X เป็นกลุ่มของวัตถุซึ่งแทนด้วยเซต ซึ่งเป็นได้ทั้งแบบต่อเนื่องและไม่ต่อเนื่อง ดังนั้น ฟัชซีเซต F ใน X ถูกแทนด้วยเซตของคู่ลำดับ

$$F = \{(x, \mu_x(x)) | x \in X\} \quad (2.43)$$

โดย $\mu_F(x)$ เป็นฟังก์ชันความเป็นสมาชิก หรือ ระดับความเป็นสมาชิก ของสมาชิก x ในฟัชซีเซต F และ ในฟัชซีเซต F ในช่วงค่าจำนวนจริงระหว่าง $[0, 1]$

2.3.2 ฟังก์ชันความเป็นสมาชิก

ฟังก์ชันความเป็นสมาชิกในฟัชซีเซต คือฟังก์ชันที่บ่งบอกถึงระดับของคุณลักษณะ โดยมีค่าเป็นค่าจริงอยู่ระหว่าง 0 กับ 1 ฟังก์ชันความเป็นสมาชิกเป็นได้ทั้งฟังก์ชันต่อเนื่อง และไม่ต่อเนื่อง ฟังก์ชันความเป็นสมาชิกที่ใช้กันทั่วไปมีหลายรูปทรงไม่ว่าจะเป็น สามเหลี่ยม (Triangular shape) รูปแบบเอสและพาย (S- and π - shape)

2.3.3 ตัวดำเนินการพีชชี

ตัวดำเนินการพื้นฐานของพีชชีเซตมีอยู่ 3 อย่างคือ ยูเนียน (union) อินเตอร์เซคชัน (intersection) และ คอมพลีเมนต์ (complement)

2.3.3.1 ตัวดำเนินการยูเนียน (Union Operator)

ฟังก์ชันความเป็นสมาชิก $\mu_{A \cup B}(x)$ ถูกกำหนดสำหรับทุก ๆ x ที่เป็นสมาชิกของ X โดย

$$\mu_{A \cup B}(x) = \max\{\mu_A(x), \mu_B(x)\} \quad (2.44)$$

2.3.3.2 ตัวดำเนินการอินเตอร์เซคชัน (Intersection Operator)

ฟังก์ชันความเป็นสมาชิก $\mu_{A \cap B}(x)$ ถูกกำหนดสำหรับทุก ๆ x ที่เป็นสมาชิกของ X โดย

$$\mu_{A \cap B}(x) = \min\{\mu_A(x), \mu_B(x)\} \quad (2.45)$$

2.3.3.3 ตัวดำเนินการคอมพลีเมนต์ (Complement Operator)

ฟังก์ชันความเป็นสมาชิก $\mu_{\bar{A}}(x)$ ถูกกำหนดสำหรับทุก ๆ x ที่เป็นสมาชิกของ X โดย

$$\mu_{\bar{A}}(x) = 1 - \mu_A(x) \quad (2.46)$$

2.3.4 ตัวแปรพีชชีเชิงภาษา

ส่วนที่สำคัญในแบบจำลองพีชชี คือการกำหนดตัวแปรเชิงภาษา ในวิธีเชิงภาษาจะใช้ค่าแทนค่าของตัวเลขเพื่ออธิบายเหตุการณ์ที่ซับซ้อนเกินไป หรือยากที่จะกำหนดคุณลักษณะในเชิงปริมาณ ในการเปรียบเทียบหน่วย ทำได้โดยใช้พีชชีเซตมากกว่าหนึ่งตัว เช่น “มาก” “ค่อนข้างมาก” “ค่อนข้างน้อย” “น้อย” คุณสมบัติตัวอย่าง เช่น ความกลม สามารถวัดในลักษณะ “กลมเล็กน้อย” “กลมมาก” “กลมโดยสมบูรณ์”

2.3.5 การประมาณเหตุผลด้วยพีชชี

ฟังก์ชันความเป็นสมาชิกจะเชื่อมโยงตัวแปรค่าจริงไปยังตัวแปรเชิงภาษา ดังนั้นข้อมูลสามารถประมาณสรุปได้ ในระบบพีชชีความไม่แน่นอนนี้ถูกเรียกว่าความเป็นพีชชี เพราะความไม่แน่นอนทำให้ไม่สามารถกำหนดกลุ่มสมาชิกอย่างเด็ดขาด ในการตัดสินใจด้วยกฎทางพีชชี ทำได้โดยใช้การแสดงเงื่อนไข “ถ้า ... แล้ว ...” “ถ้า x คือ A แล้ว y คือ B ” สามารถเขียนเป็นสัญลักษณ์ได้เป็น “ $A \rightarrow B$ ” โดยที่ A และ B เป็นพีชชีเซตในเอกภพสัมพัทธ์ (Universe) X ด้วยฟังก์ชันความเป็นสมาชิก μ_A และ μ_B

2.3.6 การสร้างชุดกฎทางพีชชี

การสร้างชุดกฎทางพีชชีทำได้โดยพิจารณาจากโครงสร้างของตัวอักษร ผลลัพธ์ที่ได้จากการหาคุณลักษณะ และคำนวณค่าความเป็นสมาชิกของคุณลักษณะเหล่านั้นในตัวอักษรแต่ละตัวจะมีลักษณะที่เป็นโครงสร้างเฉพาะที่ไม่ซ้ำกัน เช่น 'ด' จะมีหัวอยู่ตรงกลางตัวในทิศทางตามเข็มนาฬิกา มีจุดปลายอยู่ทางด้านขวาล่างซึ่งด้านล่าง และด้านบนไม่มีรอยหยัก หรือ 'ม' มีหัวทางด้านมุมซ้ายบนในทิศทางตามเข็มนาฬิกา มีจุดตัดกันของเส้นอยู่ทางด้านซ้ายล่าง และมีจุดปลายทางมุมขวาด้านบนชี้ขึ้นด้านบน จากนั้นนำค่าความเป็นสมาชิกของคุณลักษณะมาพิจารณาความเบี่ยงเบนและความหลากหลายของรูปแบบของลายมือเขียน ซึ่งจะแสดงรายละเอียดการสร้างชุดกฎทางพีชชีในบทต่อไป



ศูนย์วิทยทรัพยากร
จุฬาลงกรณ์มหาวิทยาลัย