

บทที่ 3

หลักการพื้นฐานพีชชีลอจิก

3.1 กล่าวนำ

ทฤษฎีเซตแบบเดิม (crisp set) สามารถบอกได้ว่าสิ่งๆหนึ่งจะเป็นสมาชิกหรือไม่เป็นสมาชิกในเซตที่กำหนดขึ้น การกำหนดเฉพาะลงไปเลยด้วยค่าสองค่านี้ (0 : 1, ใช่ : ไม่ใช่, ขาว : ดำ) จะแก้ปัญหาก็เกี่ยวข้องกันจำนวนได้ดี แต่เมื่อปัญหาซับซ้อนขึ้นอาจจะเกี่ยวข้องกับความเป็นจริง ธรรมชาติ หรือความรู้สึกนึกคิดของมนุษย์แล้ว คำว่าใช่หรือไม่ใช่ไม่สามารถใช้แก้ปัญหาค่าได้นัก เนื่องจากปัญหาจะเป็นลักษณะคลุมเคลือ ดังเช่นคำต่อไปนี้ มากกว่า น้อยกว่า ค่อนข้าง เป็นต้น

ทฤษฎีพีชชีเซตได้นำมาใช้เพื่อแก้ปัญหาดังกล่าว ซึ่งได้พัฒนาในปี 1965 โดย Lotfi Zadeh แห่ง University of California Berkley


3.2 ทฤษฎีพีชชีเซต

3.2.1 แนะนำ

พีชชีเซต

ให้ U ประกอบด้วยสมาชิกทั้งหมดที่แสดงได้ดังนี้ $\{ u \}$ จะเรียก U ว่า Universe of discourse ซึ่งมี u เป็นสมาชิกของ U

ให้ F เป็นพีชชีเซตใน U และมีคุณลักษณะตามฟังก์ชันที่กำหนดให้ (μ_F : membership function) ซึ่งมีค่าอยู่ในช่วง $[0,1]$ หรือเขียนได้เป็น $\mu_F : U \rightarrow [0,1]$ ดังแสดงในรูปที่ 3.1



รูปที่ 3.1 พีชชีเซต และ membership function

ฟังก์ชันเซต F ใน U สามารถแสดงเป็นคู่ลำดับของสมาชิก u และค่า (grade) ของ membership function ได้ดังนี้

$$F = \{ (u, \mu_F(u)) / u \in U \} \quad (3.1)$$

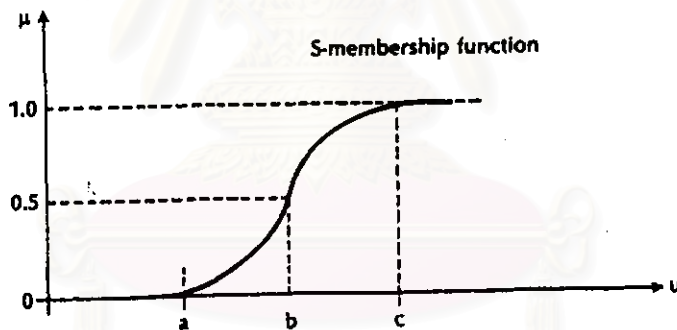
Membership Function

มี 2 วิธีในการกำหนด membership ของฟังก์ชันเซต คือ

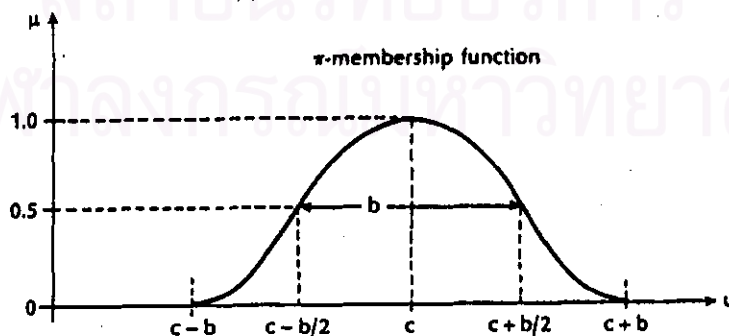
1. กำหนดโดยตัวเลข
2. กำหนดโดยฟังก์ชัน ซึ่งเป็นกรณีที่ใช้กันอยู่โดยทั่วไป
membership function ในทางปฏิบัติมีหลายแบบดังเช่น

1. ฟังก์ชัน S (S - function)
2. ฟังก์ชัน π (π - function)
3. รูปแบบสามเหลี่ยม (Triangular form)
4. รูปแบบ exponential (Exponential form)

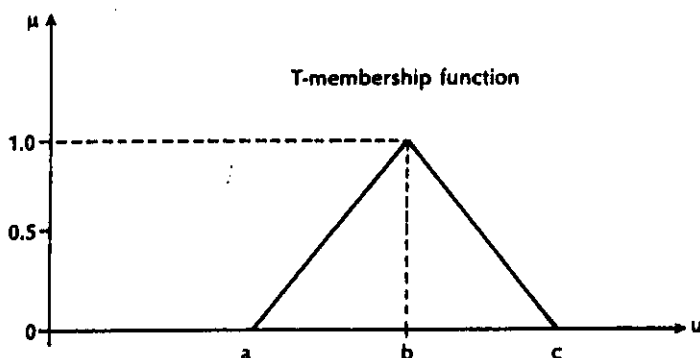
ตัวอย่างดังรูปที่ 3.2 - 3.4



รูปที่ 3.2 ฟังก์ชัน S



รูปที่ 3.3 ฟังก์ชัน π



รูปที่ 3.4 ฟังก์ชันสามเหลี่ยม

3.2.2 โอเปอเรชันของฟัซซีเซต

ให้ A และ B เป็นฟัซซีเซตใน U ซึ่งมี membership function μ_A และ μ_B ตามลำดับ

ความเท่ากัน (Equality)

ฟัซซีเซต A และ B จะเท่ากันเมื่อถูกกำหนดใน Universe เดียวกันและ membership function เหมือนกันแสดงได้ดังนี้

$$\mu_A(u) = \mu_B(u) \text{ สำหรับทุก } u \in U \quad (3.2)$$

ยูเนียน (Union)

การยูเนียนกันของฟัซซีเซต A และ B ซึ่งมี membership function $\mu_A(u)$ และ $\mu_B(u)$ จะได้ฟัซซีเซตที่มี membership function $\mu_{A \cup B}(u)$ แสดงในรูปสมการได้ดังนี้

$$\mu_{A \cup B}(u) = \max\{ \mu_A(u), \mu_B(u) \} \text{ สำหรับทุก } u \in U \quad (3.3)$$

อินเตอร์เซกชัน (Intersection)

การอินเตอร์เซกชันกันของฟัซซีเซต A และ B จะได้ฟัซซีเซตที่มี membership function $\mu_{A \cap B}(u)$ แสดงในรูปสมการได้ดังนี้

$$\mu_{A \cap B}(u) = \min\{ \mu_A(u), \mu_B(u) \} \text{ สำหรับทุก } u \in U \quad (3.4)$$

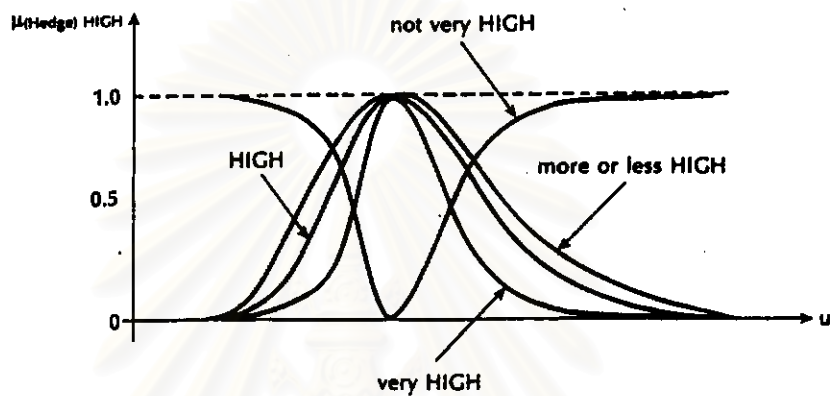
คอมพลีเมนต์ (complement)

คอมพลีเมนต์ของฟัซซีเซต A ที่มี membership function $\mu_A(u)$ จะได้ฟัซซีเซตที่อยู่ใน Universe เดียวกันโดยมี membership function ดังนี้

$$\mu_{\neg A}(u) = 1 - \mu_A(u) \text{ สำหรับทุก } u \in U \quad (3.5)$$

3.2.3 Linguistic hedge

ฟังก์ชันเซตสามารถแสดงเป็นค่า linguistic เช่น คำว่า " สูง " โดยมีตัวแปร linguistic คือ " ความสูง " สิ่งที่น่าสนใจของฟังก์ชันเซตคือความสามารถในการนำปริมาณของ linguistic (hedges) มาใช้ เช่น คำว่า มากกว่า น้อยกว่า มากๆ ไม่มาก ก่อนข้างน้อย เป็นต้น ดังแสดงในรูปที่ 3.5



รูปที่ 3.5 ฟังก์ชันเซตที่มีการปรับโดย hedges

3.3 ฟังก์ชันลอจิก

คำว่า " ฟังก์ชันลอจิก " ใช้กับจำนวนโดยมีหลายความหมายสำหรับการหาค่าความจริงของฟังก์ชัน เช่น " เกือบจริง " จะถูกกำหนดเป็นฟังก์ชันเซตโดยมีค่าตั้งแต่ศูนย์ถึงหนึ่ง [0,1]

ปกติข้อมูลที่เป็นความรู้จะเกี่ยวข้องกับความเป็นเหตุเป็นผลของฟังก์ชันดังแสดงในกฎซึ่งมีรูปแบบดังต่อไปนี้ " ถ้า x คือ A แล้ว y คือ B " โดยที่ x และ y เป็นตัวแปรฟังก์ชัน ส่วน A และ B คือค่าทางฟังก์ชัน ข้อความดังกล่าวอาจมีการใช้คำเชื่อมเช่น " และ " หรือ " หรือ "

การใช้ฟังก์ชันลอจิกจะง่ายต่อการพัฒนาระบบดังรายละเอียดต่อไปนี้

1. ความรู้และประสบการณ์สามารถนำมาเปลี่ยนเป็นความรู้ทางฟังก์ชันได้
2. ความรู้ทางฟังก์ชันที่ได้ไม่จำเป็นต้องแม่นยำมากนัก
3. ความจริงต่างๆ ที่นำมาใช้กับเงื่อนไขทางฟังก์ชันไม่จำเป็นต้องแม่นยำมากนัก
4. ข้อสรุปที่ได้จะหาจากความจริงต่างๆ ที่นำมาใช้และความรู้ทางฟังก์ชันที่สร้างขึ้น

เงื่อนไขทางฟังก์ชันแสดงเป็นตัวอย่างได้ดังนี้

ความรู้ : ถ้า น้ำร้อนมากๆ แล้ว เพิ่มน้ำเย็นมากๆ
 ความจริง : น้ำกำลังร้อนพอดีๆ
 สรุป : เติมน้ำร้อนน้อยๆ

จะเห็นว่าเงื่อนไขทางฟัซซีลอจิกคล้ายคลึงกับเหตุผลของมนุษย์ ความรู้ที่สามารถแสดงโดยใช้ค่าที่คลุมเคลือได้ เช่น " มากๆ " ส่วนความจริงสามารถใช้คำว่า " พอดีๆ " สรุปเองก็สามารถใช้คำว่า " น้อยๆ " ได้ ทำให้ฟัซซีลอจิกมีความยืดหยุ่นกว่าลอจิกแบบเดิมที่ใช้กันอยู่

3.4 กฎ Fuzzy Inference

กฎของฟัซซีปกติแสดงในรูปแบบ " ถ้า - แล้ว " การแสดงเหตุผลทางฟัซซีลอจิกแบ่งออกเป็น 2 ชนิด ตามการอ้างอิงเหตุผล (Fuzzy Inference) คือ

1. GMP (Generalized Modus Ponens)
2. GMT (Generalized Modus Tollens)

GMP คือ การแสดงเหตุผลทางตรง ส่วน GMT คือ การแสดงเหตุผลทางอ้อม

ให้ฟัซซีเซตกำหนดโดย A, A', B, B' และตัวแปร linguistic กำหนดโดย x, y วิธีของ GMP และ GMT สามารถแสดงได้ดังนี้

GMP :

ความรู้ : ถ้า x คือ A และ y คือ B (ความสัมพันธ์ : Relation, R)
ความจริง : x คือ A'
 สรุป : y คือ B' ($B' = A'oR$)

GMT :

ความรู้ : ถ้า x คือ A และ y คือ B (ความสัมพันธ์ : Relation, R)
ความจริง : y คือ B'
 สรุป : x คือ A' ($A' = RoB'$)

GMT จะใช้มากในงานวิจัยทางการแพทย์ ส่วน GMP จะใช้มากในระบบควบคุม

3.5 พื้นฐานความรู้ของฟัซซี

พื้นฐานความรู้ของฟัซซีประกอบจากกฎของฟัซซีหลายๆ กฎโดยไม่มีรูปแบบที่เป็นมาตรฐานซึ่งอยู่บนพื้นฐาน

1. สามารถนำเอาความรู้และประสบการณ์ที่นำไปใช้ในกฎได้ง่าย
 2. ทำให้นักออกแบบสร้างกฎได้ง่าย
 3. ลดค่าใช้จ่ายของงานที่ออกแบบ และ ทำให้ประสิทธิภาพของ fuzzy inference ดี
- มีค่าเชื่อมประโยคหลายค่าที่นำมาใช้ เช่น "และ" "หรือ" และ " ด้วยเหมือนกัน "

ตัวอย่าง กฎที่ k ของฟัซซีในพื้นฐานความรู้ฟัซซีแสดงได้ดังนี้

ถ้า x_1 คือ A_{k1} หรือ x_2 คือ A_{k2} และ x_3 คือ A_{k3}

แล้ว y_1 คือ B_{k1} y_2 คือ B_{k2} ด้วยเหมือนกัน

จะเห็นว่าพื้นฐานความรู้ฟัซซีสามารถมีได้หลายอินพุตและหลายเอาต์พุต (MIMO : Multiple Input Multiple Output) บางกรณีเราสามารถลดให้เหลือเอาต์พุตเดียวได้ (MISO : Multiple Input Single Output)

3.6 เหตุผลทางฟัซซี

3.6.1 Implication function

แต่ละกฎในพื้นฐานความรู้ของฟัซซีสอดคล้องกับความสัมพันธ์ทางฟัซซี พิจารณาระบบ MISO ที่มี N กฎ กฎที่ k แสดงโดย

ถ้า A_{k1} และ ... และ A_{kn} และ ... และ A_{km} แล้ว B_k

i มีค่า $1 - n$

A_{ki} คือ ฟัซซีสับเซตสำหรับตัวแปรอินพุต x ที่ i สำหรับกฎฟัซซีที่ k

B_k คือ ฟัซซีสับเซตสำหรับตัวแปรเอาต์พุต y ของกฎฟัซซีที่ k

โดยทั่วไปความสัมพันธ์ฟัซซี R_k ของกฎที่ k สามารถแสดงได้ดังนี้

$$R_k = A_k \rightarrow B_k \quad (3.6)$$

การอินเตอร์เซกชันของ A_{k1} จนถึง A_{kn} สามารถแสดงได้ 2 วิธี

1. การอินเตอร์เซกชันที่ใช้ค่าเป็นจุด (point-valued intersection)

2. การอินเตอร์เซกชันที่ใช้ค่าเป็นช่วง (interval-valued intersection)
ความสัมพันธ์ R_k ที่ได้จะมีความหมายแตกต่างกันไปขึ้นอยู่กับวิธีการที่ใช้

Point-Valued Intersection

Point-valued intersection ของสมการ (3.6) จะได้ฟuzzyเซตดังนี้

$$A_k = \bigcap_{i=1}^n A_{ki} \quad (3.7)$$

Interval-Valued Intersection

Interval-valued intersection ของสมการ (3.6) จะได้ฟuzzyเซตดังนี้

$$A_k = [L^k(n), U^k(n)] \quad (3.8)$$

L^k (Lower bound) = ขอบเขตล่าง

U^k (Upper bound) = ขอบเขตบน

ค่าจำกัดความของ $L^k(n)$ แสดงได้ดังนี้

$$L^k(1) = A_{k1}$$

$$L^k(2) = L^k(1) \wedge A_{k2}$$

....

$$L^k(n) = L^k(n-1) \wedge A_{kn}$$

3.6.2 สมการความสัมพันธ์ของฟuzzy

เพื่อหาความสัมพันธ์ทั้งหมดของฟuzzy (R) ภายใต้พื้นฐานความรู้ทางฟuzzy จะต้องใช้คอมโพสิชันโอเปอเรเตอร์ (Composition Operator) ของฟuzzy เพื่อรวมความสัมพันธ์ที่แสดงโดยแต่ละกฎ

พิจารณาระบบ MISO จะได้ฟuzzyเซต $A_k = A_{k1} \times \dots \times A_{kn} \times \dots \times A_{km}$ ในสเปซของการคูณ $U_1 \times \dots \times U_1 \times \dots \times U_n$ ผลลัพธ์ของกฎที่ k จะได้ B_k ดังนั้นความสัมพันธ์ทั้งหมด R บนพื้นฐานกฎทั้งหมด N กฎแสดงได้โดย

$$R = \bigcup_{k=1}^n R_k \quad (3.9)$$

นั่นคือ

$$R = \bigcup_{k=1}^n A_k \rightarrow B_k \quad (3.10)$$

โดย R ขึ้นกับวิธี implication ซึ่งได้แก่ point-valued fuzzy หรือ interval-valued fuzzy

3.6.3 กฎ Composition ของ Inference

เมื่อสัญญาณอินพุตที่ได้นำเข้าสู่พื้นฐานความรู้ทางฟัซซีดังนี้

$$x = (A'_1, \dots, A'_i, \dots, A'_n) \quad (3.11)$$

ให้ inferred fuzzy control จากกฎที่ i กำหนดโดย B'_i จะได้

$$y = B'_i \quad (i = 1, 2, \dots, n) \quad (3.12)$$

เมื่อใช้ GMP inference ฟัซซีคอนโทรล B' ใน Universe V สามารถแสดงได้

$$B' = (A'_1, \dots, A'_i, \dots, A'_n) \circ R \quad (3.13)$$

\circ แสดง compositional operator และ R คือสมการความสัมพันธ์ของพื้นฐานความรู้ทางฟัซซี

มีกฎที่เกี่ยวข้องกับ composition operation 2 แบบหลักใน inference คือ

1. กฎ Point-valued composition
2. กฎ Interval-valued composition

ในที่นี้จะขอกล่าวเพียงกรณีแรกซึ่งเป็นกรณีที่ใช้ในงานวิทยานิพนธ์นี้

กฎ Point-valued composition ของ Inference

กฎ point-valued composition ของ inference คือการใช้เหตุผลเพื่อที่จะได้ค่าของ B' โดยการรวมทุกกฎตามลำดับดังนี้

$$B' = \bigcup_{k=1}^n B'_k = \bigcup_{k=1}^n A'_k \circ R_k \quad (3.14)$$

$$A' = \bigcap_{k=1}^n A'_k$$

(3.15)

โดยที่

ส่วน composition operator หลักๆ ที่ใช้กันอยู่มี 4 แบบคือ

1. sub-min operator
2. sub-product operation
3. sub-bound-product operation
4. sub-drastic-product operation

เนื่องจาก sub-min และ sub-product composition operator มีขั้นตอนคำนวณง่ายจึงใช้กันอย่างแพร่หลายในการประยุกต์งานต่างๆ โดยเฉพาะงานที่ต้องการเวลาในการคำนวณน้อย

พิจารณากรณีที่ใช้ sub-min operator จะได้

$$\mu_{B'} = \bigcup_{k=1}^n [\sup(\wedge_{k=1}^n \mu_{A'_k}) \wedge (\wedge_{i=1}^n \mu_{A_{ki}} \rightarrow \mu_{B_{ki}})]$$

(3.16)

โดยทั่วไปกฎ point-valued composition ของ inference จะเกี่ยวข้องกับสิ่งต่อไปนี้

1. ตัวเชื่อม " และ " และ " หรือ " โดย " และ " แสดงการ intersection ส่วน " หรือ " แสดงการ union โดย intersection มี priority มากกว่า union
2. ทาผลลัพท์เบื้องต้น (เช่น ถ้าและ.....) ของแต่ละกฎซึ่งเรียกว่า fire strength a_k
3. เลือก compositional operator เพื่อทาผลลัพท์ต่อไป


ในนงานวิจัยนี้ใช้ sub-min compositional operator จึงขอยกตัวอย่างสำหรับวิธีดังกล่าว

กฎที่ 1 ถ้า x คือ A_1 และ y คือ B_1 แล้ว z คือ C_1

กฎที่ 1 ถ้า x คือ A_2 และ y คือ B_2 แล้ว z คือ C_2

กฎที่ 1 ถ้า x คือ A_3 และ y คือ B_3 แล้ว z คือ C_3

เมื่ออินพุต $x = A'$ และ $y = B'$ กระบวนการเหตุผลทางฟัซซีจะใช้ sub-min ดังแสดงในรูปที่ 3.6



รูปที่ 3.6 เหตุผลทางฟัซซีโดยใช้ sup-min operation


นั่นคือ

1. แต่ละกฎจะได้ค่า fire strength
2. ตัวเชื่อมมีผลต่อค่า fire strength
3. ผลลัพธ์ที่ได้จากแต่ละกฎถูกกำหนดโดยค่า fire strength
4. ผลลัพธ์ที่ได้จากการรวมกฎทั้งหมดของฟัซซีเท่ากับการสรุปผลที่ได้จากแต่ละกฎ

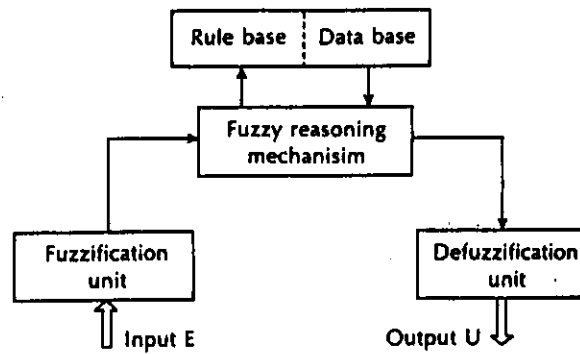
ค่าอินพุตโดยทั่วไปจะอยู่ในรูปของ "crisp" (ค่าที่ไม่คลุมเครือ crisp ตรงข้ามกับ fuzzy) เหตุผลทางฟัซซีจะอยู่บนพื้นฐาน sub-min operator ซึ่งเรียกว่า MAX - MIN fuzzy inference

3.7 โครงสร้างพื้นฐานของการควบคุมระบบโดยใช้ฟัซซี (FLC : Fuzzy Logic Control)

การควบคุมโดยใช้ฟัซซีลอจิกสามารถนำมาใช้ดังแสดงในรูปที่ 3.7 และ 3.8



รูปที่ 3.7 ระบบควบคุมฟัซซีลอจิก



รูปที่ 3.8 โครงสร้างพื้นฐานของ FLC

ส่วนประกอบสำคัญของ FLC คือ

1. fuzzification unit
2. fuzzy logic unit
3. defuzzification unit

รูปแบบของ FLC แตกต่างกันไปขึ้นกับวัตถุประสงค์ของการออกแบบ เช่น FLC อาจมีจำนวนกฎที่จำกัด (a static fuzzy knowledge base) หรืออาจจะมีสามารถในการเรียนรู้โดยการปรับส่วนพื้นฐานความรู้ (a dynamic fuzzy knowledge base) โครงสร้างพื้นฐานของ FLC แสดงในรูปที่ 3.8

fuzzy knowledge base ประกอบไปด้วยข้อมูลที่สำคัญ 2 ส่วน คือ

1. data base ซึ่งเป็นส่วนที่จะกำหนด membership function ของฟัซซีเซตสำหรับตัวแปรในระบบ
2. rule base จะจับคู่ (map) ค่าฟัซซีอินพุตไปเป็นฟัซซีเอาต์พุต

ตัวแปรของระบบแบ่งออกเป็น 2 กลุ่ม คือ ตัวแปรอินพุต (E) และตัวแปรเอาต์พุต (U) โดยใช้ FLC ในการควบคุมขั้นตอน fuzzification และ defuzzification เพื่อ map ค่าจริงไปเป็นค่าทางฟัซซี และค่าทางฟัซซีไปเป็นค่าจริงตามลำดับ

เอาต์พุตจะใช้กระบวนการ defuzzification ซึ่งเกี่ยวข้องกับ weight และการรวมกันของจำนวนฟัซซีเซตที่ได้จาก fuzzy inference เพื่อจะได้ค่า crisp ที่แน่นอนของเอาต์พุต

ส่วนของ rule base ใน knowledge base ประกอบด้วยจำนวนกฎฟัซซีมากซึ่งแสดงความสัมพันธ์ของการควบคุม กฎเหล่านี้ส่วนใหญ่จะใช้รูปแบบของ "ถ้า - แล้ว"

fuzzy knowledge base อาจจะเป็น static หรือ dynamic ในกรณีนี้ dynamic fuzzy knowledge base จะต้องมีการเรียนรู้ (learning หรือ self organizing) โดย FLC

fuzzy logic reasoning module จะใช้ fuzzy logic คล้ายคลึงกับการตัดสินใจของมนุษย์โดยจะทำการใช้ knowledge base สำหรับ fuzzified อินพุตในช่วง fuzzy inference operation ต่างๆ เป็นไปตามนี้คือ

1. กำหนดดีกรีของการจับคู่ระหว่างฟัซซีอินพุตกับฟัซซีเซต
2. หา fire strength สำหรับแต่ละกฎโดยใช้ดีกรีที่ได้จากข้อ 1. และตัวเชื่อม
สำหรับ point-valued fuzzy inference โอเปอร์เรเตอร์จะหา fire strength ให้กับแต่ละกฎ แต่ถ้าเป็น interval-valued fuzzy inference จะได้สองค่าคือ fire strength ขอบเขตบน และ fire strength ขอบเขตล่าง
3. หาเอาต์พุตโดยใช้ fire strength ที่ได้จากข้อ 2 แล้วกำหนดฟัซซีเซตสำหรับเอาต์พุต

3.7.1 ตัวแปรระบบและพารามิเตอร์ฟัซซี

ฟัซซีเซตสำหรับแต่ละระบบจะกำหนดตัวแปรในรูปของ linguistic เช่น เพิ่มขึ้นมากๆ เพิ่มขึ้นปานกลาง เพิ่มขึ้นน้อยๆ ไม่เพิ่ม ลดลงน้อยๆ ลดลงปานกลาง ลดลงมากๆ ฯลฯ โดย membership function จะเป็นตัวกำหนดค่า linguistic ของแต่ละฟัซซีเซต

รูปร่างของ membership function สำหรับตัวแปรขึ้นกับจุดประสงค์ของการออกแบบโดยมีแนวทางดังนี้

1. มีการกระจายอย่างสม่ำเสมอของฟัซซีเซตใน Universe
2. ฟัซซีเซตควรเป็นจำนวนคี่เพื่อที่จะได้มีฟัซซีเซตที่เป็นค่ากลาง เช่น 5 หรือ 7
3. ฟัซซีเซตที่อยู่ใกล้กันควรจะซ้อนกันเพื่อแสดงว่าไม่มีค่า crisp อยู่ และเพื่อจะได้มีหลายๆ กฎในการหาเอาต์พุต
4. การใช้ membership function แบบสามเหลี่ยม หรือ สี่เหลี่ยมคางหมูจะใช้เวลาในการคำนวณน้อยกว่ารูปแบบอื่นๆ

การซ้อนกันของฟัซซีเซตข้างเคียงควรจะให้มีความหนาแน่นประมาณ 15-20 % ของพื้นที่จะมีแนวโน้มที่ดี

3.7.2 ขั้นตอน Fuzzification

เป็นกระบวนการในการ map ค่าอินพุตที่ได้จากการสังเกตเข้าสู่ฟัซซีเซตเพื่อจะได้ค่าทางฟัซซี (ปกติแล้วค่าที่ได้จากการสังเกตจะเป็น crisp) แสดงได้ดังนี้

$$x = \text{fuzzification} (x_0) \quad (3.17)$$

x_0 เป็นเวกเตอร์ของค่า crisp ของอินพุต 1 ตัวแปร

x เป็นเวกเตอร์ของฟัซซีเซตที่กำหนดสำหรับตัวแปร

fuzzifier คือ fuzzification operator ซึ่งมีผลต่อการ map ข้อมูล crisp ไปเป็นข้อมูลทางฟัซซี มีหลายวิธีในการ fuzzification ดังเช่น

1. Fuzzy singleton : ในงานควบคุมที่เป็น Real time อินพุตจะถูกวัดโดยเซนเซอร์ซึ่งจะได้ค่า crisp ซึ่งง่ายต่อการเปลี่ยนเป็นค่าทางฟัซซี สมมติอินพุต x_0 เข้าไปในฟัซซีเซต A ซึ่งมี membership function $\mu_A(x_0) = 1$ เป็นวิธีที่สร้างขึ้นง่ายและสอดคล้องกับธรรมชาติ
2. Fuzzy member : (ค่าที่ไม่แน่นอน) เป็นการขยายความคิดในการคิดฟัซซีแบบช่วง
3. Hybrid fuzzy : เป็นการรวมกรณี 1 และ 2 เข้าด้วยกัน

ในทงานวิจัยนี้จะกล่าวเฉพาะกรณีที่ 1

3.7.3 การใช้เหตุผล

มี fuzzy inference หลายวิธีที่ใช้ แต่ที่ใช้กันมากคือ

1. วิธี point-valued MAX-MIN fuzzy inference
2. วิธี point-valued MAX-DOT fuzzy inference

ในงานวิจัยนี้ใช้วิธีที่ 1 เช่น

กฎที่ i : ถ้า x คือ A_1 และ y คือ B_1 แล้ว z คือ C_1 จะได้ fire strength ของกฎที่ i จากอินพุต x_0 และ y_0 ดังนี้

$$\alpha = \mu_{A_1}(x_0) \wedge \mu_{B_1}(y_0) \quad (3.18)$$

MAX-MIN fuzzy reasoning

$$\mu_C(w) = (\alpha_1 \wedge \mu_{C_1}(w)) \vee (\alpha_2 \wedge \mu_{C_2}(w)) \quad (3.19)$$

3.7.4 วิธี Defuzzification

Defuzzification เป็นกระบวนการ map จากค่าทางฟัซซีไปเป็นค่า crisp เพื่อได้ค่าที่เป็นตัวแทนที่ดีที่สุดของค่าฟัซซีที่ได้

$$y_0 = \text{defuzzifier}(y) \quad (3.20)$$

y_0 คือ fuzzy control action

y คือ crisp control action

defuzzifier คือ defuzzification operator

ในงาน real time วิธีการ defuzzification ที่ใช้โดยทั่วไปคือ

1. วิธี Mean of Maximum
2. วิธี Center of Area

วิธี Mean of Maximum : MOM

เรียกอีกอย่างว่า height defuzzification โดยวิธีนี้จะมีการสร้าง control action ซึ่งเป็นตัวแทนค่าเฉลี่ยของ control action ซึ่งมี membership function เข้าใกล้ค่ามากที่สุด

พิจารณาระบบฟัซซีแบบ MISO ซึ่งมีทั้งหมด n กฎ ให้ค่าความสูงมากที่สุดของ membership function ของฟัซซีเซตต่างๆ ทางด้านเอาต์พุตมีค่า H_i และค่า crisp control ของเอาต์พุตกำหนดโดย W_i

ให้ fire strength จากกฎที่ i เป็น α_i
จะได้ค่า crisp control W ดังนี้

$$W = \frac{\sum_{i=1}^n \alpha_i H_i W_i}{\sum_{i=1}^n \alpha_i H_i} \quad (3.21)$$

ส่วนใหญ่แล้ว $H_i = 1$ membership function ที่สมมาตรจะนำมาใช้กับฟัซซีเซตที่กำหนดขึ้นไม่เช่นนั้นอาจทำให้การ defuzzification ผิดพลาด

วิธี Center of Area : COP

จะสร้างจุดศูนย์กลางถ่วง (center of gravity) ของ control action พิจารณาระบบฟัซซี MISO ซึ่งมีจำนวน n กฎ ให้โมเมนต์ของ membership function ของ fuzzy set ของกฎที่ i กำหนดโดย M_i พื้นที่ดังกล่าวกำหนดโดย A_i fire strength ของกฎ i กำหนดโดย α_i ค่า crisp control W จะได้

$$W = \frac{\sum_{i=1}^n \alpha_i M_i}{\sum_{i=1}^n \alpha_i A_i}$$

(3.22)



สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย