

วิธีกำหนดกฎของ ANFIS โดยใช้ GRANULAR COMPUTING

RULE CONSTRUCTION FOR ANFIS USING GRANULAR COMPUTING

พรประสิทธิ์ บุญทอง
PORNPASIT BOONTONG

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต
สาขาวิชาวิศวกรรมคอมพิวเตอร์

บัณฑิตวิทยาลัย


สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ. 2550

สำนักหอสมุดกลาง พระจอมเกล้าลาดกระบัง

วิธีกำหนดกฎของ ANFIS โดยใช้ GRANULAR COMPUTING

RULE CONSTRUCTION FOR ANFIS USING GRANULAR COMPUTING



พรประสิทธิ์ บุญทอง

PORNPRASIT BOONTONG

เลขหมู่.....
เลขทะเบียน..... 74632
วัน,เดือน,ปี..... - 8 ต.ค. 2550

b..... 1182788๙
i.....

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชาวิศวกรรมคอมพิวเตอร์

บัณฑิตวิทยาลัย

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ.2550

RULE CONSTRUCTION FOR ANFIS USING GRANULAR COMPUTING

PORNPRASIT BOONTONG

**A THESIS SUBMITTED IN PARTIAL FULFILLMENT
OF THE REQUIREMENT FOR THE DEGREE OF
MASTER OF ENGINEERING IN COMPUTER ENGINEERING
SCHOOL OF GRADUATE STUDIES
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG**

2007

COPYRIGHT 2007

SCHOOL OF GRADUATE STUDIES

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

หัวข้อวิทยานิพนธ์	วิธีกำหนดกฎของ ANFIS โดยใช้ GRANULAR COMPUTING
นักศึกษา	นายพรประสิทธิ์ บุญทอง
รหัสนักศึกษา	45061211
ปริญญา	วิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชา	วิศวกรรมคอมพิวเตอร์
พ.ศ.	2550
อาจารย์ที่ปรึกษาวิทยานิพนธ์	รศ.ดร. เอื้อน ปิ่นเงิน

บทคัดย่อ

ปัจจุบันมีการใช้เทคโนโลยีระบบอัจฉริยะแบบผสมผสาน ในการแก้ปัญหาทางด้านการจำแนกประเภทข้อมูลกันอย่างแพร่หลาย ด้วยจุดเด่นของการผสมผสานการทำงานของระบบอัจฉริยะแต่ละตัว โดยเฉพาะการผสมผสานการทำงานของนิวรอลเน็ตเวิร์ค (Neural Network) และฟัซซี่ลอจิก (Fuzzy Logic) ภายใต้อะแดปทีฟนิวโรฟัซซี่อินเฟอร์เรนซ์ซิสเต็ม (Adaptive Neuro-Fuzzy Inference System :ANFIS) แต่เนื่องจากโหนดในชั้น Rule Layer มีจำนวนมากตามจำนวน ฟังก์ชันความเป็นสมาชิกของฟัซซี่และจำนวนอินพุต ทำให้ ANFIS ต้องใช้เวลาในการฝึกสอนมาก บทความนี้นำเสนอการกำหนดกฎของ ANFIS โดยนำหลักการแกรนูลาร์คอมพิวติง (Granular Computing) มาใช้สร้างโหนดของ Rule Layer ที่เหมาะสมให้กับ ANFIS ผลการทดลองได้จำนวนโหนดของ Rule layer ลดลง ทำให้เวลาในการฝึกสอนและทดสอบลดลง

Thesis Title	RULE CONSTRUCTION FOR ANFIS USING GRANULAR COMPUTING
Student	Mr. Pornprasit Boontong
Student ID.	45061211
Degree	Master of Engineering
Program	Computer Engineering
Year	2007
Thesis Advisor	Assoc. Prof. Dr. Ouen Pinngern

ABSTRACT

Recently hybrid intelligent system is the popular kind of method for solving problem especially classification problems. Neural Network and Fuzzy Logic combined into hybrid system call Adaptive Neuro-Fuzzy Inference system (ANFIS). Due to large number of nodes in rule layer, conventional ANFIS spends much more time for training and testing .This research propose a method to modify ANFIS based on Granular Computing to reducing number of rule nodes, with intention of making ANFIS more efficient regarding to training time. Simulation results promised that Granular Computing can be used to reduce number of nodes in rule layer and training time of ANFIS.

กิตติกรรมประกาศ

วิทยานิพนธ์นี้สำเร็จลุล่วงด้วยดีเนื่องด้วยการอำนวยการอันวพรที่ยิ่งใหญ่ และกำลังใจจาก คุณแม่ พี่ชายและน้อง ๆ ทุกคน ข้าพเจ้าขอสำนึกในพระคุณนี้อย่างเป็นที่สุด

วิทยานิพนธ์นี้จะไม่สำเร็จลุล่วงหากปราศจากแรงผลักดัน และคำแนะนำที่มีประโยชน์ของ รศ.ดร. เอื้อน ปิ่นเงิน ผู้ควบคุมวิทยานิพนธ์ ข้าพเจ้าขอกราบขอบพระคุณเป็นอย่างสูง

ข้าพเจ้าขอกราบเท้า คุณครูและอาจารย์ทุกท่านตั้งแต่เล็กจนเติบโตใหญ่ ที่ได้มอบวิชาความรู้ ให้แก่ข้าพเจ้า รวมทั้งคำสั่งสอนและอบรมให้ข้าพเจ้าเป็นคนดี ข้าพเจ้าขอกราบขอบพระคุณเป็นอย่างสูง

ข้าพเจ้าขอขอบคุณสำนักวิจัยการสื่อสารและเทคโนโลยีสารสนเทศ (ReCCIT) ที่ได้ สนับสนุนเครื่องมือ ตลอดจนข้อมูล และหนังสือต่างๆ ที่ใช้ในการทำวิจัย

ข้าพเจ้าขอขอบคุณ ผศ.ดร.วิศิษฎ์ หิรัญกิตติ และเพื่อนๆ สมาชิกห้องวิจัยการสื่อสารและ คมนาคมชาญฉลาด ที่ให้การสนับสนุนสถานที่ทำวิจัย

ข้าพเจ้าขอขอบคุณสำหรับกำลังใจ คำแนะนำ และประสบการณ์ที่ดีจากพี่ ๆ น้อง ๆ และ เพื่อน ๆ นักศึกษา ป.โททุกท่าน และขอขอบคุณ นายไพฑูรย์ ศรีนิล นายเกรียงศักดิ์ เตมีย์ นายธรรมกร ครองไตรภพ นายสมบัติ ฝอยทอง นายศรชัย อุดมธนาพงศ์ และ Mr. Thach Ngugen Huy ที่ช่วยแนะนำข้อมูลการทำวิจัย และแก้ไขภาษาในการพิมพ์บทความตีพิมพ์ และวิทยานิพนธ์ ฉบับนี้ ข้าพเจ้า ขอขอบคุณ

สุดท้ายนี้ต้องขอขอบคุณ นางสาวบุรี ศรีสวัสดิ์ ที่เป็นเสมือนเพื่อนคู่คิดและเป็นกำลังใจที่ คีตตลอดมา

สำหรับคุณค่าและประโยชน์อันพึงมีจากวิทยานิพนธ์ฉบับนี้ ข้าพเจ้าขอมอบให้กับผู้มี พระคุณทุกท่าน หากวิทยานิพนธ์ฉบับนี้มีข้อผิดพลาดประการใดข้าพเจ้าขอน้อมรับไว้เพียงผู้เดียว

พรประสิทธิ์ บุญทอง

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	I
บทคัดย่อภาษาอังกฤษ.....	II
กิตติกรรมประกาศ.....	III
สารบัญ.....	IV
สารบัญตาราง.....	VII
สารบัญภาพ.....	VIII
บทที่ 1 บทนำ.....	1
1.1 ความเป็นมาและความสำคัญของปัญหา.....	1
1.2 ความมุ่งหมายและวัตถุประสงค์ของการศึกษา.....	2
1.3 แนวคิดที่ใช้ในงานวิจัย	2
1.4 การเปรียบเทียบระหว่างวิธีการที่นำเสนอกับวิธีการแบบพื้นฐาน	3
1.5 ขอบเขตการวิจัย.....	3
1.6 ขั้นตอนของการศึกษา	3
บทที่ 2 เอกสารและงานวิจัยที่เกี่ยวข้อง	4
2.1 ANFIS: Adaptive-Network-Based Fuzzy Inference System.....	4
2.2 Perspective of Granular Computing	4
2.3 Modified ANFIS: Architecture-Improving Efficiency of ANFIS Technique	5
บทที่ 3 นิเวศวิทยา.....	6
3.1 ทฤษฎีฟuzzy เซต	6
3.2 การแทนข้อมูลในฟuzzy เซต	7
3.3 ฟังก์ชันความเป็นสมาชิก	8
3.3 การเรียนรู้.....	13
3.3.1 อาร์ทฟิเชียล นิวรอนเน็ตเวิร์ค	13
3.3.2 รูปแบบการใช้งานนิวรอนแบบต่างๆ	15
3.4 ฟuzzy อินเฟอร์เรนซ์ซิสเต็ม (Fuzzy Inference System)	17
3.5 อะแดปทีฟนิวโรฟuzzy อินเฟอร์เรนซ์ซิสเต็ม.....	18
3.5.1 โครงสร้างของ ANFIS.....	19

สารบัญ(ต่อ)

	หน้า
3.5.2 การเรียนรู้ของ ANFIS	20
3.6 สรุป.....	21
บทที่ 4 แกรนนูลาร์คอมพิวติง.....	22
4.1 บทนำ.....	22
4.2 หลักการพื้นฐานของการคำนวณแกรนนูลาร์	22
4.3 การสร้างกฎด้วยหลักการคำนวณแกรนนูลาร์	24
4.4 ตัวอย่างการสร้างกฎด้วยหลักการคำนวณแกรนนูลาร์	24
4.5 สรุป.....	29
บทที่ 5 การปรับปรุง ANFIS	30
5.1 กระบวนการเตรียมข้อมูล.....	31
5.1.1 ข้อมูล Iris Plants	31
5.1.2 ข้อมูล KDD Cup 1999	31
5.1.3 ข้อมูล Abalone.....	32
5.2 การสร้างกฎด้วยหลักการคำนวณแกรนนูลาร์	35
5.3 กระบวนการปรับปรุง ANFIS.....	38
5.4 การแก้ปัญหาการจำแนกประเภทข้อมูลด้วย ANFIS	41
5.4.1 การฝึกสอนระบบ	41
5.4.2 การทดสอบระบบ	47
5.5 สรุป.....	48
บทที่ 6 ผลการทดลอง	49
6.1 การทดลองที่ 1 การทดลองการจำแนกประเภทข้อมูลโดยใช้โมเดล ANFIS แบบเดิม .49	
6.1.1 จุดประสงค์การทดลอง	49
6.1.2 ขั้นตอนการทดลอง	49
6.2 การทดลองที่ 2 ทดลองการจำแนกประเภทข้อมูลโดยใช้โมเดล ANFIS ปรับปรุงใหม่ 51	
6.2.1 จุดประสงค์ของการทดลอง.....	51
6.2.2 ขั้นตอนการทดลอง	52

สารบัญ(ต่อ)

	หน้า
6.3 สรุปและวิเคราะห์ผลการทดลอง.....	53
บทที่ 7 สรุปผลการวิจัยและข้อเสนอแนะ	57
7.1 สรุปผลการวิจัย	57
7.2 ปัญหาและข้อเสนอแนะ	57
บรรณานุกรม.....	59
ภาคผนวก.....	60
ประวัติผู้เขียน	68

สารบัญตาราง

ตารางที่	หน้า
4.1 ตัวอย่างตารางสารสนเทศ.....	25
4.2 แกรนดุลพื้นฐานของการประมวลผลในลำดับชั้นแรก	26
4.3 แสดงการหาค่า T_i ของแต่ละคุณลักษณะ.....	27
4.4 แสดงการหาค่า global certainty ของคุณลักษณะแต่ละตัว.....	27
4.5 แสดงการหาค่า minimum local certainty ของคุณลักษณะ outlook	27
4.6 แสดงค่า certainty support ของแกรนดุลพื้นฐานในชั้นแรก	28
5.1 แสดงกลุ่มข้อมูลที่ใช้ทดลอง.....	31
5.2 ตารางสารสนเทศข้อมูล Iris Plants	33
5.3 ตารางสารสนเทศข้อมูล KDD Cup 1999	33
5.3 ตารางสารสนเทศข้อมูล KDD Cup 1999 (ต่อ).....	34
5.4 ตารางสารสนเทศข้อมูล Abalone.....	34
5.4 ตารางสารสนเทศข้อมูล Abalone (ต่อ)	35
5.5 กฎ fuzzy if-then ของสารสนเทศของฐานข้อมูล Iris Plant	36
5.6 กฎ fuzzy if-then ของสารสนเทศของฐานข้อมูล KDD Cup 1999	36
5.7 กฎ fuzzy if-then ของสารสนเทศของฐานข้อมูล Abalone	37
5.7 กฎ fuzzy if-then ของสารสนเทศของฐานข้อมูล Abalone(ต่อ).....	38
5.8 แสดงจำนวนกฎและ Total Fitting Parameter ของ ANFIS แบบเดิม	38
5.9 แสดงจำนวนกฎและ Total Fitting Parameter ของ ANFIS แบบใหม่.....	39
5.10 แสดงกฎ Fuzzy If-Then สำหรับการจำแนกประเภทข้อมูล Iris Plant.....	41
5.11 แสดงตัวอย่างข้อมูล Iris Plant.....	42
5.12 แสดงพารามิเตอร์ของฟังก์ชันความเป็นสมาชิกของอินพุท	42
5.13 แสดงค่าที่ได้จากการคำนวณ Firing Strength ของกฎ Fuzzy If-Then.....	43
5.14 แสดงค่า Normalize Firing Strength ของกฎ.....	43
5.15 แสดงเอาต์พุทของ Rule Consequent parameter	44
5.16 แสดง Parameter ของฟังก์ชันความเป็นสมาชิกของอินพุทก่อนการฝึกสอน.....	47
5.17 แสดง Parameter ของฟังก์ชันความเป็นสมาชิกของอินพุทหลังการฝึกสอน	47
5.18 แสดงตัวอย่างของข้อมูลที่นำมาทำการทดสอบ.....	47
5.19 แสดงตัวอย่างการคำนวณเอาต์พุทของ ANFIS	48

สารบัญตาราง(ต่อ)

ตารางที่	หน้า
5.20 แสดงเอาที่พู่ทของการทดสอบจำแนกประเภทข้อมูล	48
6.1 สภาพแวดล้อมของการทดลองด้วยโมเดล ANFIS แบบเดิม	49
6.2 แสดงจำนวนข้อมูลสำหรับฝึกระบบและข้อมูลทดสอบ.....	50
6.3 แสดงผลการทดลองด้วยฐานข้อมูล Iris Plant	50
6.4 แสดงผลการทดลองด้วยฐานข้อมูล KDD Cup 1999.....	50
6.5 แสดงผลการทดลองด้วยข้อมูล Abalone	51
6.6 สภาพแวดล้อมของการทดลองด้วยโมเดล ANFIS ที่ปรับปรุงใหม่.....	52
6.7 แสดงผลการทดลองด้วยฐานข้อมูล Iris Plant	52
6.8 แสดงผลการทดลองด้วยฐานข้อมูล KDD Cup 1999.....	52
6.9 แสดงผลการทดลองด้วยฐานข้อมูล Abalone	53
6.10 อัตราส่วนของเวลาที่ลดลงในการฝึกสอนระบบของ ANFIS แบบเดิมและแบบใหม่	56
6.11 แสดงจำนวนข้อมูลฝึกสอนที่มีผลต่ออัตราการจำแนกประเภทข้อมูลที่ถูกต้อง.....	56

สารบัญรูป

รูปที่	หน้า
3.1 กราฟแสดงค่าความเป็นสมาชิกของ x ที่มีต่อเซต A กรณีที่เป็นคริสป์เซต (crisp set).....	7
3.2 กราฟแสดงค่าความเป็นสมาชิกของเซต A “ความสูง” กรณีที่เป็นฟัซซี่เซต.....	8
3.3 กราฟฟังก์ชันความเป็นสมาชิกของตัวแปร “ความสูง” ที่ประกอบไปด้วย 3 เทอมเซต.....	9
3.4 กราฟแสดงฟังก์ชันความเป็นสมาชิกแบบรูปสามเหลี่ยม.....	10
3.5 กราฟแสดงฟังก์ชันความเป็นสมาชิกแบบรูปสี่เหลี่ยมคางหมู.....	10
3.6 กราฟแสดงฟังก์ชันความเป็นสมาชิกแบบรูปตัว S	11
3.7 กราฟแสดงฟังก์ชันความเป็นสมาชิกแบบรูประฆังคว่ำ.....	12
3.8 กราฟแสดงฟังก์ชันความเป็นสมาชิกแบบรูป Gaussian.....	12
3.9 รูปทางชีวิตวิทยาของสมอง.....	13
3.10 ไดอะแกรมของนิวรอนเน็ตเวิร์ก.....	14
3.11 แสดงเอ็กซิเวชัน ฟังก์ชันชนิดต่าง.....	15
3.12 แสดงการทำงานหลายเลเยอร์.....	16
3.13 แสดงการทำงานของแต่ละพหุพหุเกชัน นิวรอลเน็ตเวิร์ก.....	17
3.15 แสดงส่วนประกอบของฟัซซี่อินเฟอร์เรนซ์ซิสเต็ม.....	18
3.16 โครงสร้าง ANFIS แบบ 2 อินพุตและกฎฟัซซี่ 2 กฎ.....	19
5.1 แสดงขั้นตอนการทำงานของระบบ.....	30
5.2 แสดง Fuzzy space ของแต่ละคุณลักษณะ.....	32
5.3 แสดงโครงสร้างเดิมของ ANFIS.....	39
5.4 แสดงโครงสร้างใหม่ของ ANFIS ตามสารสนเทศ Iris Plant.....	40
5.5 แสดงโครงสร้างใหม่ของ ANFIS ตามสารสนเทศ KDD Cup 1999.....	40
5.6 แสดงโครงสร้างใหม่ของ ANFIS ตามสารสนเทศ Abalone.....	40
5.7 แสดงฟังก์ชันความเป็นสมาชิกก่อนการฝึกสอน.....	44
5.8 แสดงฟังก์ชันความเป็นสมาชิกหลังการฝึกสอน.....	45
6.1 กราฟเปรียบเทียบอัตราการจำแนกประเภทของ ANFIS แบบเดิมและแบบใหม่.....	53
6.2 กราฟเปรียบเทียบเวลาฝึกสอนของ ANFIS แบบเดิมและแบบใหม่ของการจำแนกประเภท ข้อมูลของ Iris Plant Dataset.....	53
6.3 กราฟเปรียบเทียบเวลาฝึกสอนของ ANFIS แบบเดิมและแบบใหม่ของการจำแนกประเภท ข้อมูลของ KDD Cup 1999.....	54

สารบัญรูป(ต่อ)

รูปที่	หน้า
6.4 กราฟเปรียบเทียบเวลาฝึกสอนของ ANFIS แบบเดิมและแบบใหม่ของการจำแนกประเภท ข้อมูลของ Abalone Dataset	54

บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

ปัจจุบันมีการใช้เทคโนโลยีระบบอัจฉริยะแบบผสมผสาน (Hybrid Intelligent System) ในการแก้ปัญหาทางด้านการจำแนกประเภทข้อมูลกันอย่างแพร่หลาย ด้วยจุดเด่นของการผสมผสานการทำงานของระบบอัจฉริยะ โดยเฉพาะ การผสมผสานการทำงานของอาร์ทิฟิเชียลนิวรัลเน็ตเวิร์ค (Artificial Neural Network :ANN) และฟัซซีลอจิก (Fuzzy Logic :FL) เป็นเทคนิคสำหรับสร้างระบบอัจฉริยะ ซึ่งเมื่อออกแบบให้ทำงานร่วมกัน จะทำให้เครื่องมือทั้งสองทำงานในลักษณะส่งเสริมซึ่งกันและกัน โดย ANN มีคุณสมบัติเด่นทางด้านการเรียนรู้จากข้อมูลที่เป็นข้อมูลดิบ ในขณะที่ FL มีข้อดีทางด้านการให้เหตุผล โดยการใช้ลึงควิสติกอิพอร์เมชัน (linguistic information) ที่ได้จากผู้เชี่ยวชาญ อย่างไรก็ตาม FL ก็มีจุดอ่อนทางด้านการเรียนรู้และการปรับระบบ ให้เข้ากับสภาพแวดล้อมของปัญหาต่างๆ ถึงแม้ว่า ANN มีจุดเด่นในด้านการเรียนรู้และการปรับตัวเองแต่ก็มีจุดอ่อนเนื่องจากการทำงานในลักษณะการคำนวณที่ซับซ้อน ทำให้ผู้ใช้ไม่สามารถเข้าถึงกระบวนการคำนวณภายใน ทำให้ขบวนการนำเสนอความรู้แก่ผู้ใช้ทำได้ไม่ดี การผสมผสานการทำงานของ ANN และ FL ภายใต้ชื่อ อะแดปทีฟนิวโรฟัซซีอินเฟอร์เรนซ์ซิสเต็ม (Adaptive Neuro-Fuzzy Inference System: ANFIS) ทำให้ระบบเกิดการผสมผสานการทำงาน ในการนำเสนอองค์ความรู้ แล้วนำความรู้ที่นั้นมาวินิจฉัยประกอบการตัดสินใจ อีกทั้งทำให้ระบบสามารถเรียนรู้ และปรับตัวในสภาพแวดล้อมขององค์ความรู้เหล่านั้น ได้อย่างที่มนุษย์สามารถทำได้

ในกระบวนการทำงานของ ANFIS ระบบถูกฝึกให้มีการเรียนรู้และปรับค่าพารามิเตอร์ของกฎ if-then และกำหนดฟังก์ชันความเป็นสมาชิกของอินพุตและเอาต์พุตของระบบ ซึ่งโครงสร้างของ ANFIS ประกอบด้วย ชั้นอินพุต ชั้นซ่อนและชั้นเอาต์พุต ซึ่งแทนฟังก์ชันความเป็นสมาชิกและกฎ fuzzy if-then ตามลำดับ โดยส่วนจำนวนโหนดของกฎ fuzzy if-then มีจำนวน p โดยที่ p แทนจำนวนการแบ่ง ค่าความเป็นสมาชิก ของอินพุตและ n แทนจำนวนอินพุต ดังนั้นหากค่า n มีค่ามาก จะทำให้จำนวนโหนดของกฎ fuzzy if-then มีจำนวนมาก ซึ่งจะส่งผลทำให้ ANFIS สิ้นเปลืองเวลาในการฝึกสอนเพื่อปรับค่าพารามิเตอร์

ในวิทยานิพนธ์นี้นำเสนอแนวทางในการปรับปรุง ANFIS ในส่วนของการกำหนดค่าเริ่มต้นของกฎ fuzzy if-then โดยนำหลักการของการคำนวณแกรนูลาร์ (Granular Computing) มาใช้สร้างโหนดของกฎ fuzzy if-then ที่เหมาะสมในชั้นซ่อนของ ANFIS ด้วยวิธีการที่นำเสนอในวิทยานิพนธ์นี้ทำให้จำนวนกฎ fuzzy if-then ลดลงและส่งผลให้เวลาในการฝึกสอน ANFIS ลดลง

1.2 ความมุ่งหมายและวัตถุประสงค์ของการศึกษา

1. เพื่อศึกษาการจำแนกประเภทข้อมูลและการประยุกต์ใช้ ANFIS ในการการจำแนกข้อมูล
2. เพื่อศึกษาหลักการคำนวณแกรนูลาร์และอัลกอริทึมสำหรับการกำหนดกฎให้กับ ANFIS
3. เพื่อศึกษาแนวทางในการพัฒนา ANFIS และนำเสนอโมเดลใหม่ที่ผู้วิจัยได้พัฒนาขึ้น
4. เพื่อเปรียบเทียบประสิทธิภาพของ ANFIS แบบเดิมและ โมเดลใหม่ที่ผู้วิจัยนำเสนอ

1.3 แนวคิดที่ใช้ในงานวิจัย

จุดอ่อน ANFIS ในการแก้ปัญหาทางด้านการจำแนกข้อมูล คือการสร้างกฎ fuzzy if-then ในชั้นของรูลแอนทีซิเดนต์ (Rule antecedent layer) ซึ่งโดยพื้นฐานกฎ fuzzy if-then จะถูกกำหนดโดยผู้เชี่ยวชาญ แต่ในกรณีที่ไม่มีการกำหนดกฎ fuzzy if-then จากผู้เชี่ยวชาญ ANFIS จะทำการสร้างกฎขึ้นมาโดยอัตโนมัติ ซึ่งจำนวนกฎที่สร้างขึ้นจะสอดคล้องกับจำนวนการแบ่งฟังก์ชันความเป็นสมาชิกและจำนวนอินพุทของข้อมูล ซึ่งในกรณีที่ปัญหานั้นๆมีอินพุทข้อมูลจำนวนมากๆ ทำให้จำนวนโหนดของรูลแอนทีซิเดนต์เพิ่มขึ้นในลักษณะทวีคูณ ทำให้ ANFIS ใช้เวลาในการคำนวณเพื่อฝึกสอนมากตามไปด้วย

ในงานวิจัยนี้จึงนำเสนอการกำหนดกฎของ ANFIS ด้วยการสร้างโหนดในส่วนของกฎ fuzzy if-then โดยการสร้างกฎนำหลักการของคำนวณแกรนูลาร์ ซึ่งเป็นหลักการที่สามารถสร้างกฎขึ้นมาโดยการประมวลผลในลักษณะลำดับขั้น ทำให้ในส่วนเงื่อนไขของกฎไม่จำเป็นต้องพิจารณาถึงคุณลักษณะทุกๆคุณลักษณะ อีกทั้งการควบคุมการสร้างกฎอาศัยหลักการหาค่ามินิมัมโลคัลเซอร์เทนตี (Minimum local certainty) ซึ่งเป็นค่าเทรชโฮล (Threshold) ของค่าความถูกต้องของกฎ ซึ่งค่าเทรชโฮลสามารถปรับเปลี่ยนให้เข้ากับข้อมูลแต่ละตัวอย่างเหมาะสม จากกฎ fuzzy if-then ที่ได้จะถูกนำมาเป็นกฎเริ่มต้นให้กับ ANFIS ทำให้ยังคงประสิทธิภาพในการจำแนกประเภทข้อมูลไว้ได้ในขณะที่เวลาในการฝึกสอนลดลง

1.4 การเปรียบเทียบระหว่างวิธีการที่นำเสนอกับวิธีการแบบพื้นฐาน

ทำการเปรียบเทียบประสิทธิภาพของโมเดล ANFIS แบบเดิมซึ่งกฎ fuzzy if-then ถูกสร้างขึ้นอัตโนมัติและโมเดลของ ANFIS ที่ปรับปรุงขึ้นใหม่ ซึ่งกฎ fuzzy if-then ถูกสร้างขึ้นด้วยหลักการคำนวณแกรนูลาร์ ซึ่งเปรียบเทียบอัตราการจำแนกประเภทข้อมูลและการเปรียบเทียบเวลาที่ใช้ในการฝึกสอน ANFIS

1.5 ขอบเขตการวิจัย

1. ศึกษาเปรียบเทียบเวลาที่ใช้ในการฝึกสอนและเปรียบเทียบประสิทธิภาพการจำแนกประเภทข้อมูลของ ANFIS แบบเดิมกับ ANFIS ที่ปรับปรุงใหม่
2. ข้อมูลที่ใช้ในการฝึกสอนและทดสอบเป็นข้อมูลที่ได้จาก UCI Machine Learning Repository ซึ่งประกอบด้วยข้อมูล Iris Plant ข้อมูล KDD Cup 1999 ซึ่งเป็นการจำลองพฤติกรรมกรนูกอบระบบเครือข่าย โดยเลือกเฉพาะพฤติกรรมกรนูกอบประเภท Denial of Service และข้อมูล Abalone ซึ่งเป็นข้อมูลการพยากรณ์อายุของหอยชนิดหนึ่ง

1.6 ขั้นตอนของการศึกษา

วิทยานิพนธ์ฉบับนี้ได้แบ่งเนื้อหาออกเป็น 7 บทด้วยกันคือ

บทที่ 1 กล่าวถึงความเป็นมาของงานวิจัย ความมุ่งหมายและวัตถุประสงค์ ขอบเขตของการวิจัย และขั้นตอนการศึกษา

บทที่ 2 กล่าวถึงเอกสารและงานวิจัยที่เกี่ยวข้อง

บทที่ 3 กล่าวถึงระบบอัจฉริยะแบบผสมผสาน นิวโรฟัซซี่ โดยเน้นที่โมเดลของ โรเจอร์ จาง ที่มีชื่อว่า Adaptive Neuro-Fuzzy Inference System (ANFIS) ซึ่งเป็นโมเดลที่งานวิจัยนี้ นำมาใช้ในการแก้ปัญหาด้านการจำแนกประเภทข้อมูล

บทที่ 4 กล่าวถึงหลักการพื้นฐานของการคำนวณแกรนูลาร์

บทที่ 5 กล่าวถึงหลักการและวิธีการดำเนินงานวิจัย โดยจะเน้นถึงการเตรียมระบบเพื่อทำการทดสอบ

บทที่ 6 เป็นการทดลอง ผลการทดลอง

บทที่ 7 เป็นบทสรุปผลการวิจัยและข้อเสนอแนะ

บทที่ 2

เอกสารและงานวิจัยที่เกี่ยวข้อง

2.1 ANFIS: Adaptive-Network-Based Fuzzy Inference System

เอกสารงานวิจัยชื่อ ANFIS: Adaptive-Network-Based Fuzzy Inference System นำเสนอ โดย R. Jang ในปี ค.ศ. 1993 ซึ่งเสนอแบบการคำนวณในการนำเสนอองค์ความรู้ของมนุษย์ โดยเฉพาะแนวความคิดที่ให้ระบบสามารถแยกแยะสิ่งต่างๆ ที่มีความคลุมเครือได้ ซึ่งนำเสนอในรูปแบบของพีชคณิตอินเฟอร์เรนซ์ซิสเต็มที่สามารถปรับตัวเองได้โดยใช้อัลกอริทึมการเรียนรู้แบบผสม (hybrid learning) ซึ่งจุดเด่นของงานวิจัยนี้คือการผสมผสานการทำงานของเทคโนโลยีระบบอัจฉริยะสองระบบคือ อาทิจีเสียนิวรอลเน็ตเวิร์ค (Artificial Neural Network) และพีชคณิตลอจิก (Fuzzy Logic) อีกทั้งยังการใช้อัลกอริทึมการเรียนรู้แบบผสมผสาน (hybrid learning) ระหว่างอัลกอริทึม เกรเดียนเดสเซนท (gradient descent) และอัลกอริทึมลีสแควเอสทิเมท (Least Square Estimate) ทำให้กระบวนการเรียนรู้สามารถหลีกเลี่ยงปัญหาโลคัลมินิมา (local minima trap)

อย่างไรก็ตาม ANFIS ให้ผลลัพธ์ของอัตราการจำแนกประเภทข้อมูลสูง แต่ ANFIS ยังคงมีข้อจำกัดในเรื่องของเวลาที่ใช้ในการคำนวณในขั้นตอนของการฝึกสอน ซึ่งจากโครงสร้างของ ANFIS จำนวนของพารามิเตอร์ขึ้นอยู่กับปัญหาแต่ละชนิด ในกรณีที่ปัญหานั้นๆ มีข้อมูลอินพุตจำนวนมากๆ จำนวนพารามิเตอร์ก็มากตาม ทำให้ต้องใช้เวลาที่ใช้ในการฝึกสอน ANFIS มาก ซึ่งจำนวนพารามิเตอร์ทั้งหมดเป็น $(n \cdot p \cdot m) + p$ โดยที่ n แทนจำนวนอินพุต p แทนจำนวนกฎ fuzzy if-then และ m แทนการแบ่งฟังก์ชันความเป็นสมาชิก และ m แทนจำนวนพารามิเตอร์ของฟังก์ชันความเป็นสมาชิกชนิด ระฆังคว่ำ (Bell membership function) จากโครงสร้างดังกล่าวหากมีการปรับเปลี่ยนจำนวนการแบ่งฟังก์ชันความเป็นสมาชิกแล้วจะต้องพิจารณาให้รอบคอบ เนื่องจากจะทำให้จำนวนพารามิเตอร์ของ ANFIS เปลี่ยนไปอย่างมาก ซึ่งจะมีผลกับเวลาที่ใช้ในการฝึกสอน ANFIS

2.2 Perspective of Granular Computing

เอกสารงานวิจัยชื่อ Perspective of Granular Computing ซึ่งนำเสนอโดย Yiyu Yao ในปี ค.ศ. 2005 งานวิจัยนี้นำเสนอแนวคิดในภาพรวมในมุมมองต่าง ๆ ของการคำนวณแกรนูลาร์ (Granular Computing) ซึ่งในมุมมองต่าง ๆ นั้นเป็นการพยายามตอบคำถามในหลายๆคำถามเกี่ยวกับการคำนวณแกรนูลาร์ เช่น การคำนวณแกรนูลาร์คืออะไร ทำไมต้องศึกษาการคำนวณแกรนูลาร์ มีอะไรใหม่ ๆ ที่แตกต่างจากแนวคิดแบบอื่นๆ และผลลัพธ์ที่ได้จากการศึกษาหลักการ

คำนวณแกรนูลาร์ ประกอบด้วยหลักการพื้นฐานของการคำนวณแกรนูลาร์ หลักการประมวลผล และการนำเสนอจุดเด่นของการนำหลักการคำนวณแกรนูลาร์ มาแก้ปัญหาในด้านต่างๆ

2.2.1 เอกสารงานวิจัยชื่อ A Rule Generation Algorithm based on Granular Computing นำเสนอโดย J. J. An, G. Y. Wang และ Y. Wu, Q. Gan ในงานวิจัยนี้นำเสนอการแทนตารางสารสนเทศให้อยู่ในรูปของ แกรนูล (Granule) แล้วทำการประมวลผลในลักษณะลำดับชั้นเพื่อสร้างกฎที่ใช้ในการตัดสินใจ

2.2.2 เอกสารงานวิจัยชื่อ A SELF-LEARNING ALGORITHM FOR DECISION TREE PRE-PRUNING นำเสนอโดย DE-SHENG YIN, GUO-YIN WANG และ YU WU ในงานวิจัยนี้นำเสนอการสร้างกฎโดยใช้หลักการคำนวณแกรนูลาร์ ซึ่งในกระบวนการสร้างกฎทำการหาค่า minimum local certainty ซึ่งใช้เป็นค่าเทอร์สโฮลด์ (Threshold) ของค่าความถูกต้องของกฎ ทำให้ระบบสามารถปรับค่าเทอร์สโฮลด์ให้เข้ากับตารางสารสนเทศต่าง ๆ ได้

2.3 Modified ANFIS: Architecture–Improving Efficiency of ANFIS Technique

ที่มา: 7th Seminar on Neural Network Applications in Electrical Engineering, Sep 2004

จุดอ่อนของอะแดปทีฟนิวโรฟิวซซีอินเฟอร์เรนซ์ซิสเต็ม (Adaptive Neuro-Fuzzy Inference System: ANFIS) ในการแก้ปัญหการสร้างกฎ fuzzy if-then ในชั้นของรูลแอนทีซีเดนต์ (Rule antecedent layer) ซึ่งในแต่ละปัญหา กฎ fuzzy if-then จะถูกกำหนดขึ้นโดยอัตโนมัติจำนวนพารามิเตอร์ทั้งหมดเป็น $(n \cdot p \cdot m) + p$ โดยที่ n แทนจำนวนอินพุต p แทนจำนวนกฎ Fuzzy if-then และ m แทนการแบ่งฟังก์ชันความเป็นสมาชิก และ m แทนจำนวนพารามิเตอร์ของฟังก์ชันความเป็นสมาชิก

งานวิจัยนี้นำเสนอรายละเอียดของปรับปรุง ANFIS ด้วยการประมาณค่าจำนวนของกฎ Fuzzy if-then ให้เท่ากับจำนวนของ Input Fuzzy Set

บทที่ 3

นิวโรฟัซซี่

ซอฟต์แวร์คอมพิวเตอร์ (Soft computing) เป็นแบบการคำนวณที่เกิดขึ้นใหม่ที่ได้รับความสนใจในงานทางด้านการสร้างระบบอัจฉริยะเพื่อแก้ปัญหาที่มีความซับซ้อนมากๆ ซึ่งในปัญหาที่สภาพแวดล้อมที่ไม่แน่นอน มีการเปลี่ยนแปลงของข้อมูลและตัวแปรต่างๆตลอดเวลา เป็นระบบที่สามารถปรับตัวให้เรียนรู้ปัญหาในสภาพแวดล้อมต่างๆ ซึ่งการประมวลผลกับปัญหาต่างๆที่มีองค์ประกอบของซอฟต์แวร์คอมพิวเตอร์เป็นการผสมผสานการทำงานจากระบบอัจฉริยะหลายชนิดประกอบด้วย อาร์ทิฟิเชียลนิวรอลเน็ตเวิร์ค (Artificial Neural Network :ANN) ฟัซซี่อินเฟอร์เรนซ์ซิสเต็ม (Fuzzy Inference System :FIS) แอปพร็อกซิเมทีสไนง (approximate reasoning) และ เอฟโพลูชันนารีคอมพิวเตอร์ (Evolutionary Computation) ซึ่งระบบอัจฉริยะแต่ละชนิดมีจุดเด่นเฉพาะตัว โดยการนำจุดเด่นของระบบอัจฉริยะมารวมกันในลักษณะที่เรียกว่าระบบอัจฉริยะแบบผสมผสานเช่น นิวโรฟัซซี่ (Neuro-Fuzzy) เป็นการงานร่วมกันของนิวรอลเน็ตเวิร์ค (Neural Network) ซึ่งมีความสามารถในการเรียนรู้แพทเทิร์น (Pattern) และปรับตัวเองตามสภาพแวดล้อมต่างๆ และความสามารถของฟัซซี่อินเฟอร์เรนซ์ซิสเต็ม ในการทำงานในลักษณะการนำเสนอองค์ความรู้ (Knowledge Representation) แล้วนำความรู้ที่นำมาวินิจฉัยประกอบการตัดสินใจ

3.1 ทฤษฎีฟัซซี่เซต

ทฤษฎีฟัซซี่เซตได้ถูกพัฒนาขึ้นโดย Zadeh ในปี ค.ศ. 1965 ซึ่งมีความพยายามที่จะเลียนแบบหลักการคิดของมนุษย์ที่สามารถพิจารณาแก้ไขปัญหาต่างๆ ได้โดยใช้ความรู้ เหตุผลและปัจจัยแวดล้อมต่างๆ มาประกอบกัน เพื่อหาทางออกของปัญหาที่เหมาะสมที่สุดและถูกนำมาใช้ในการอธิบายระบบที่มีความคลุมเครือ ฟัซซี่เซตมีพื้นฐานมาจากทฤษฎีเซต โดยค่าความเป็นสมาชิกของข้อมูลจะอยู่ในช่วง 0 ถึง 1 ซึ่งมีความแตกต่างจากค่าความเป็นสมาชิกของเซตธรรมดาที่มีค่า 0 และ 1 เท่านั้น ทฤษฎีของฟัซซี่เซตได้ถูกพัฒนาไปใช้ในงานหลายๆ ด้าน เช่น งานทางด้านระบบควบคุมในทางวิศวกรรมศาสตร์ ทางด้านประมวลผลภาพหรือการจัดกลุ่มของข้อมูล เป็นต้น ในระบบที่เป็นคริปส์ (crisp set) การระบุถึงการเป็นสมาชิกของเซตจะมีเพียง “เป็นสมาชิก” และ “ไม่เป็นสมาชิก” โดยแทนด้วยค่าความเป็นสมาชิก 0 หรือ 1 แต่ในฟัซซี่เซต การระบุถึงการเป็นสมาชิกจะอ้างจากค่าความเป็นสมาชิกที่มีค่าอยู่ในช่วง 0 ถึง 1 ถ้ากำหนดให้ U เป็นเซตเอกภพสัมพัทธ์ และฟัซซี่เซต $A \subseteq U$ ดังนั้นฟัซซี่เซต A สามารถเขียนให้อยู่ในรูปความสัมพันธ์ของ $x \in U$ กับ $\mu_A(x)$ ดังสมการที่ 3.1

$$A = \{(x, \mu_A(x)) | x \in U\} \quad (3.1)$$

โดยที่ $\mu_A(x)$ คือฟังก์ชันความเป็นสมาชิกของ x ในฟัซซี่เซต A


ตัวแปรฟัซซี่ (Fuzzy variable) หรือบางครั้งอาจจะเรียกว่า Linguistic variable คือฟัซซี่เซตของระบบที่เราสนใจ ตัวอย่างเช่น ถ้าเรากำหนดให้ “ความสูง” เป็นตัวแปรฟัซซี่ และกำหนดเซตค่าของตัวแปรเป็น {เตี้ย, ปานกลาง, สูง} เราอาจจะเรียกเซตของค่าตัวแปรเหล่านี้ว่าค่าตัวแปรฟัซซี่ หรือ เทอมเซต (Term set) นอกจากนี้ตัวแปรฟัซซี่แต่ละตัวอาจจะมีส่วนขยาย (Hedges) เพื่อปรับค่าตัวแปรฟัซซี่ให้มีความยืดหยุ่นมากยิ่งขึ้น เช่น จากค่าของตัวแปรความสูง “เตี้ย-เตี้ยมาก” หรือ “สูง-ค่อนข้างสูง” เป็นต้น คำว่า “มาก” หรือ “ค่อนข้าง” ในที่นี้เป็นส่วนขยายของตัวแปรฟัซซี่

3.2 การแทนข้อมูลในฟัซซี่เซต

การแทนข้อมูลในฟัซซี่เซต เพื่อให้เข้าใจมากยิ่งขึ้นจะเปรียบเทียบกับระบบเซตธรรมดา ตัวอย่างเช่น “ความสูง” (ในระบบฟัซซี่เซต ก็คือตัวแปรฟัซซี่เซต) ที่เราสนใจอยู่ในช่วง 140-180 เซนติเมตร (เป็นโดเมนของเอกภพสัมพัทธ์) แต่ถ้าเราสนใจเฉพาะคนที่สูง และกำหนดให้เซต A เป็นเซตของคนที่สูง (“สูง” ในฟัซซี่เซตจะเป็นเทอมเซต หรือค่าตัวแปรฟัซซี่) ดังนั้นเซต A ในกรณีของระบบเซตธรรมดาจะต้องมีการกำหนดค่าเริ่มเปลี่ยน หรือค่าเทรชโฮลด์ (Threshold) เพื่อเป็นตัวชี้ว่าข้อมูลจะเป็นสมาชิกของเซตใด ถ้าลองสมมติกำหนดค่าเทรชโฮลด์มีค่าเท่ากับ 170 เซนติเมตร นั่นคือ ถ้าคนใดมีความสูงมากกว่าหรือเท่ากับ 170 เซนติเมตร จะถือว่าคนนั้นสูง (เป็นสมาชิกของเซต A) ซึ่งสามารถเขียนเป็นฟังก์ชันความเป็นสมาชิกได้ดังสมการที่ 3.2

$$\mu_A(x) = \begin{cases} 1 & x \geq 170 \\ 0 & \text{otherwise} \end{cases} \quad (3.2)$$


โดยที่ x คือความสูงของคน ดังนั้นจากสมการที่ 3.2 เราสามารถนำมาเขียนเป็นกราฟแสดงความเป็นสมาชิกของเซตได้รูปที่ 3.1



รูปที่ 3.1 กราฟแสดงค่าความเป็นสมาชิกของ x ที่มีต่อเซต A กรณี่ที่เป็นคริสปเซต (crisp set)

จากรูปที่ 3.1 จะเห็นได้ว่าคนที่มีความสูงตั้งแต่ 170 เซนติเมตร ขึ้นไปเท่านั้นจึงถือว่าเป็นคนสูง (มีค่าความเป็นสมาชิกเท่ากับ 1) นอกนั้นถือว่าเป็นคนเตี้ยทั้งหมด แต่ในความเป็นจริงจะไม่ถูกต้องมากนัก เพราะคนที่มีความสูง 169.9 เซนติเมตร ก็มีความสูงใกล้เคียงกับคนที่สูง 170 เซนติเมตรมาก แต่ถือว่าเป็นคนเตี้ย จากปัญหานี้ สามารถอธิบายโดยฟัซซี่เซตที่มีฟังก์ชันความเป็นสมาชิกที่มีความสอดคล้องกับความเป็นจริงมากกว่าการอธิบายโดยใช้คริสป์เซต ดังแสดงในสมการที่ 3.3

$$\mu_A(x) = \begin{cases} \frac{1}{10}(x - 160) & 160 \leq x \leq 170 \\ 1 & x > 170 \\ 0 & \text{otherwise} \end{cases} \quad (3.3)$$



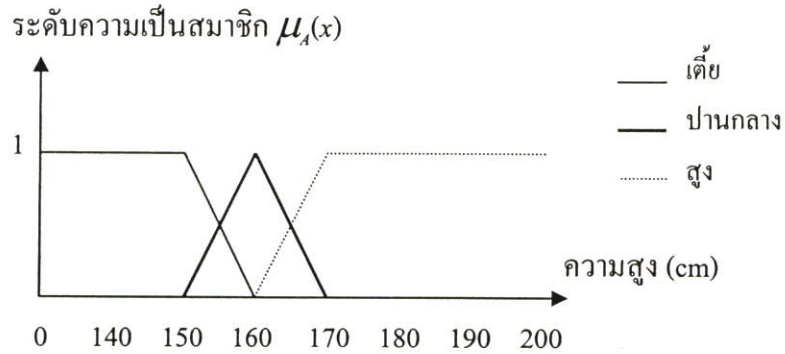
รูปที่ 3.2 กราฟแสดงค่าความเป็นสมาชิกของเซต A “ความสูง” กรณี่ที่เป็นฟัซซี่เซต

จากรูปที่ 3.1 และรูปที่ 3.2 จะเห็นได้ว่ากราฟแสดงความเป็นสมาชิกของฟัซซี่เซตจะมีความต่อเนื่องในช่วง $[0,1]$ เช่น คนที่มีความสูง 165 เซนติเมตร ก็จะถือว่าเป็นคนสูงเช่นกัน แต่เขาจะมีระดับความเป็นสมาชิกของเซตคนสูงเท่ากับ 0.5 แต่ถ้าเปรียบเทียบกับคริสป์เซตจะพบว่าคนที่มีความสูง 165 เซนติเมตรจะมีค่าความเป็นสมาชิกของเซตคนสูง (เซต A) เท่ากับค่าศูนย์ใดๆ ที่ความสูงน้อยกว่า 170 เซนติเมตรเพียงเล็กน้อยเท่านั้น

3.3 ฟังก์ชันความเป็นสมาชิก

พิจารณาคูณสมบัติของฟัซซี่เซต จากกราฟรูปที่ 3.2 แกนนอนของกราฟจะแทนโดเมนของฟัซซี่เซต ส่วนแกนตั้งจะแทนค่าระดับความเป็นสมาชิก แต่ในกราฟรูปที่ 3.2 มีเทอมเซตเพียงเทอมเดียว คือเทอมของคนสูงเท่านั้นเพื่อให้ครอบคลุมกลุ่มประชากรที่เราสนใจจึงเพิ่มเทอมเซตอีกสองเทอมคือ เทอมเซตของคน “เตี้ย” และเทอมเซตของคนที่มีความสูง “ปานกลาง” ดังรูปที่ 3.3 ซึ่ง

ในกรณีที่มีโดเมนของตัวแปรฟัซซีเซตที่ครอบคลุมประชากรทั้งหมดที่ทำการศึกษา เราจะเรียกโดเมนของตัวแปรนี้ว่า เซตเอกภพสัมพัทธ์ และในแต่ละเทอมเซตก็จะมีโดเมนของตัวอย่างเช่น เทอมเซตของคนเตี้ยจะมีโดเมนอยู่ในช่วง $[0, 160]$ เซนติเมตร เทอมเซตของคนที่มีความสูงปานกลางจะมีโดเมนอยู่ในช่วง $[150, 170]$ เซนติเมตร และเทอมเซตของคนที่สูงจะมีค่าตั้งแต่ 160 เซนติเมตรขึ้นไป




รูปที่ 3.3 กราฟฟังก์ชันความเป็นสมาชิกของตัวแปร “ความสูง” ที่ประกอบไปด้วย 3 เทอมเซต

กราฟฟังก์ชันความเป็นสมาชิกมีหลายแบบที่จะใช้ในการประมาณค่าระดับความเป็นสมาชิกของแต่ละเทอมเซต โดยมีทั้งแบบที่ประมาณค่าเป็นเชิงเส้น เช่น รูปสามเหลี่ยม รูปสี่เหลี่ยมคางหมู และแบบที่ประมาณค่าโดยฟังก์ชันต่อเนื่อง เช่น แบบเส้นโค้งรูปตัว S รูปประฆังคว่ำ และเกาส์เซียน เป็นต้น ซึ่งมีรายละเอียดดังนี้

ฟังก์ชันความเป็นสมาชิกแบบสมการเชิงเส้นเป็นฟังก์ชันที่ใช้ในการแปลงค่าความสัมพันธ์ของโดเมนไปยังเรนจ์สำหรับข้อมูลที่มีความสัมพันธ์เป็นเชิงเส้น ดังสมการที่ 3.3


ฟังก์ชันความเป็นสมาชิกแบบรูปสามเหลี่ยม (Triangular membership function) เป็นฟังก์ชันความเป็นสมาชิกที่นิยมใช้กันมากในระบบควบคุมที่ใช้ฟัซซีเซต เทอมเซตที่กำหนดโดยฟังก์ชันนี้จะต้องมีค่าที่เหมาะสมที่สุดอยู่เพียงค่าเดียวที่ทำให้ค่าความเป็นสมาชิกเท่ากับหนึ่ง ส่วนค่าอื่นๆ จะมีค่าความเป็นสมาชิกลดลงเรื่อยๆ เมื่อยิ่งห่างจากค่านี้มากขึ้น ในตัวอย่างของตัวแปรความสูง เทอมเซต “ปานกลาง” มีฟังก์ชันความเป็นสมาชิกเป็นรูปสามเหลี่ยม ถ้ากำหนดให้ $a \leq b \leq c$ เมื่อ $a, b,$ และ c เป็นเลขจำนวนจริงใดๆ ดังนั้นสมการของฟังก์ชันความเป็นสมาชิกแบบรูปสามเหลี่ยมสามารถกำหนดได้ดังสมการที่ 3.4



รูปที่ 3.4 กราฟแสดงฟังก์ชันความเป็นสมาชิกแบบรูปสามเหลี่ยม

$$\text{triangle}(x; a, b, c) = \begin{cases} 0 & x \leq a \\ \frac{x-a}{b-a} & a \leq x \leq b \\ \frac{c-x}{c-b} & b \leq x \leq c \\ 0 & c \leq x \end{cases} \quad (3.4)$$


ฟังก์ชันความเป็นสมาชิกแบบรูปสี่เหลี่ยมคางหมู (Trapezoidal membership function) เป็นฟังก์ชันความเป็นสมาชิกที่กำหนดด้วยสมการรูปสี่เหลี่ยมคางหมู นิยมใช้ในระบบควบคุมที่ใช้พีซีซีเชื่อมกัน แต่จะพบน้อยกว่าฟังก์ชันความเป็นสมาชิกที่กำหนดด้วยสมการรูปสามเหลี่ยม ฟังก์ชันความเป็นสมาชิกที่กำหนดด้วยสมการรูปสี่เหลี่ยมคางหมูจะต้องมีช่วงของค่าที่เหมาะสมมากที่สุดอยู่ในกลุ่มหนึ่งที่ทำให้ค่าความเป็นสมาชิกของเทอมเซตนั้นๆ นอกจากนั้นจะมีค่าความเป็นสมาชิกน้อยลงเรื่อยๆ เมื่อยิ่งห่างจากข้อมูลกลุ่มนี้ ถ้ากำหนดให้ $a \leq b \leq c \leq d$ เมื่อ $a, b, c,$ และ d เมื่อ $a, b, c,$ และ d เป็นเลขจำนวนจริงใดๆ ดังนั้นสมการของฟังก์ชันความเป็นสมาชิกแบบรูปสี่เหลี่ยมคางหมูสามารถกำหนดได้ดังสมการที่ 3.5



รูปที่ 3.5 กราฟแสดงฟังก์ชันความเป็นสมาชิกแบบรูปสี่เหลี่ยมคางหมู

$$\text{trapezoid}(x;a,b,c,d)=\begin{cases} 0 & x \leq a \\ \frac{x-a}{b-a} & a \leq x \leq b \\ 1 & b \leq x \leq c \\ \frac{d-x}{d-c} & c \leq x \leq d \\ 0 & d \leq x \end{cases} \quad (3.5)$$


ฟังก์ชันความเป็นสมาชิกแบบเส้นโค้งรูปตัว S (Sigmoidal membership function) เป็นฟังก์ชันความเป็นสมาชิกที่กำหนดความสัมพันธ์ระหว่างโดเมนไปยังเรนจ์แบบไม่เป็นเชิงเส้น ตัวแปรที่เหมาะสมที่จะใช้ฟังก์ชันนี้คือพวกอายุการใช้งานของอุปกรณ์ต่างๆ ตัวแปรส่วนใหญ่ที่ใช้ในทางการประมวลผลทางภาพเป็นต้น ซึ่งตัวแปรพวกนี้มักจะมีความสัมพันธ์แบบไม่เป็นเชิงเส้นที่เป็นรูปตัว S หรือ S^{-1} ถ้ากำหนดให้ $a \leq b \leq c$ เมื่อ $a, b,$ และ c เป็นเลขจำนวนจริงใดๆ ดังนั้นสมการของฟังก์ชันความเป็นสมาชิกของเส้นโค้งรูปตัว S สามารถกำหนดได้ดังสมการที่ 3.6 และ $S^{-1}=1-\mu_A(x)$ โดยที่ $\mu_A(x)$ ได้จากสมการที่ 3.6



รูปที่ 3.6 กราฟแสดงฟังก์ชันความเป็นสมาชิกแบบรูปตัว S

$$\text{sigmoid}(x;a,b,c)=\begin{cases} 0 & x \leq a \\ 2((x-a)/(c-a))^2 & a \leq x \leq b \\ 1-2((x-a)/(c-a))^2 & b \leq x \leq c \\ 1 & x \geq c \end{cases} \quad (3.6)$$

ฟังก์ชันความเป็นสมาชิกแบบรูประฆังคว่ำ (Bell membership function) เป็นฟังก์ชันความเป็นสมาชิกที่มีคุณสมบัติของข้อมูลคล้ายกับฟังก์ชันความเป็นสมาชิกแบบรูปสามเหลี่ยม แต่ข้อมูลของโดเมนที่แปลงไปยังเรนจ์จะมีความสัมพันธ์ในลักษณะไม่เป็นเชิงเส้น ฟังก์ชันความเป็นสมาชิกแบบรูประฆังคว่ำสามารถกำหนดได้ดังสมการที่ 3.7




รูปที่ 3.7 กราฟแสดงฟังก์ชันความเป็นสมาชิกแบบรูปประฆังคว่ำ

$$bell(x; a, b, c) = \frac{1}{1 + \left[\left(\frac{x-c}{a} \right)^2 \right]^b} \quad (3.7)$$

ฟังก์ชันความเป็นสมาชิกแบบเกาส์เซียน (Gaussian membership function) สามารถกำหนดได้โดยสมการที่ 3.9

$$gaussian(x; c, \sigma) = e^{-\frac{(x-c)^2}{2\sigma^2}} \quad (3.8)$$

โดยที่ c เป็นค่ากลางและ σ เป็นความกว้างของฟังก์ชันความเป็นสมาชิกแบบเกาส์เซียน ตามลำดับ




รูปที่ 3.8 กราฟแสดงฟังก์ชันความเป็นสมาชิกแบบรูป Gaussian

3.3 การเรียนรู้

อุปกรณ์ต่างๆ ที่นำคอมพิวเตอร์เข้าไปใช้งานเพื่อการเรียนรู้นั้น จะเรียนรู้ได้โดยอาศัย ประสบการณ์, ตัวอย่าง, และ การอ้างอิงจากการเปรียบเทียบ (analog) ซึ่งการเรียนรู้ทำให้อุปกรณ์ เพิ่มระดับความสามารถให้มากขึ้น โดยวิธีการที่เป็นที่นิยมวิธีการหนึ่งในการนำมาใช้ในการเรียนรู้ คือ อาร์ทิฟิเชียล นิวรอนเน็ตเวิร์ค (Artificial Neuron Network)

3.3.1 อาร์ทิฟิเชียล นิวรอนเน็ตเวิร์ค


อาร์ทิฟิเชียล นิวรอนเน็ตเวิร์ค เป็นการจำลองการทำงานของสมองมนุษย์มาเป็นรูปแบบการประมวลผลข้อมูล ปกติแล้วในสมองของมนุษย์จะประกอบด้วยเซลล์ประสาทจำนวนมาก ซึ่งทำงานอย่างอิสระ แต่ละเซลล์จะมีการเชื่อมต่อกันเรียกว่า ซินแนป (Synapse) มี ส่วนที่เป็นอินพุตของเซลล์ เรียกว่าเดนไดรด์ (Dendrite) และส่วนที่เป็นเอาพุตเรียกว่าแอกซอน (Axon) ซึ่ง การติดต่อทำได้โดยการสร้างความต่างศักย์ (Voltage) ซึ่งถือว่าเซลล์ประสาทเหล่านี้เป็นหน่วยย่อย ที่สุดในการทำงานของสมอง ซึ่งการทำงานจะเป็นไปในลักษณะที่สัญญาณประสาทถูกส่งต่อกัน ไปเป็นทอดๆ จากเซลล์หนึ่งไปยังอีกเซลล์หนึ่ง โดยแต่ละเซลล์จะทำหน้าที่ในการคำนวณในส่วนย่อย และมีการเชื่อมต่อถึงกันที่ซัพซ็อนเพื่อให้ได้ผลการคำนวณที่ต้องการ



รูปที่ 3.9 รูปทางชีววิทยาของสมอง

ข้อดี ของการทำงานแบบนี้ คือ เราไม่จำเป็นต้องทราบถึงรูปแบบการคำนวณที่แน่นอน แต่ ปล่อยให้ทำหน้าที่ของกระบวนการเรียนรู้ ที่จะทำหน้าที่สร้างรูปแบบการคำนวณที่ใกล้เคียงกับ การคำนวณค่าที่ถูกต้องขึ้นมา โดยอาศัยการปรับค่าที่อยู่ภายในหน่วยย่อย หรือ ค่าที่บริเวณ จุดเชื่อมต่อระหว่างหน่วยย่อยเหล่านี้ว่าจะให้ค่าอินพุตใดมีความสำคัญเท่าไร เมื่อนำมาใช้ในทาง คอมพิวเตอร์ เราจึงสร้างหน่วยประมวลผลซึ่งมีลักษณะคล้ายเซลล์ประสาท โดยให้แต่ละหน่วย ประกอบด้วยส่วนอินพุตที่มีค่าน้ำหนัก (Weight) อยู่เพื่อระบุค่าความสำคัญของอินพุตนั้นๆ ภายใน

จะมีการประมวลผลโดยส่วนแรกจะนำค่าอินพุตทั้งหมดมารวมกัน จากนั้นจึงนำไปแทนค่าในแอ็คติเวชัน ฟังก์ชัน (Activation Function) แล้วได้ออกมาเป็นเอาต์พุต



รูปที่ 3.10 โค้ดแกรมของนิวรอนเน็ตเวิร์ก

จากรูปที่ 3.10 แสดงโค้ดแกรมของนิวรอนเน็ตเวิร์ก ซึ่งสามารถเขียนเป็นสมการได้ดังนี้

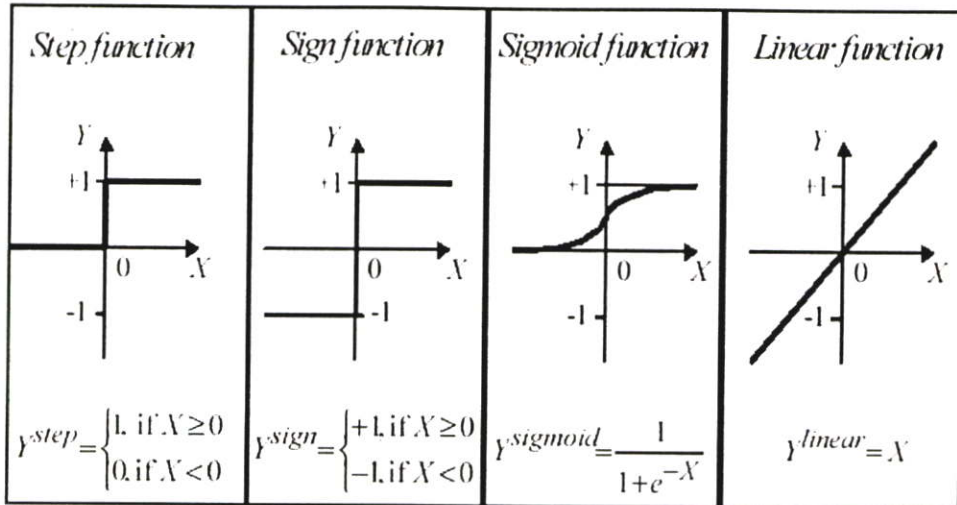
$$\begin{aligned} net &= \sum_i x_i \cdot w_i + \theta \\ &= x_1 w_1 + x_2 w_2 + \dots x_n w_n + \theta \end{aligned} \quad (3.9)$$

โดยที่ x_1, x_2, \dots, x_n เป็นชุดข้อมูลอินพุต
 w_1, w_2, \dots, w_n เป็นค่าตัวเลขน้ำหนัก
 θ เป็นค่าเทรสโฮลของนิวรอน

จากรูปที่ 3.10 นิวรอน 1 โหนดจะมีค่าอินพุตหลายค่า แต่จะมีค่าเอาต์พุตเพียงค่าเดียว โดยเอาต์พุตในแต่ละนิวรอน เกิดจากการรวมของผลคูณระหว่างอินพุตและตัวเลขน้ำหนักของอินพุตนั้น จากนั้นเมื่อคำนวณแล้วนำมาแทนค่าในแอ็คติเวชันฟังก์ชัน

แอ็คติเวชันฟังก์ชันที่นำมาใช้ในการแยกประเภทการจดจำของงานนั้น โดยมีรูปแบบดังนี้

1. สะเทีป และ ซายฟังก์ชัน ถูกเรียกว่า ฮาร์ดลิมิตฟังก์ชัน คือ มักจะถูกใช้ในการตัดสินใจของนิวรอนเน็ตเวิร์ก ในการแยกประเภท และการจดจำรูปแบบ
2. ซิกมอย ฟังก์ชัน ใช้กับอินพุตที่มีค่าระหว่างค่าบวก ถึงอินฟินิตี้ และมีค่าเอาต์พุตอยู่ระหว่าง 0-1 ฟังก์ชันนี้จะถูกใช้ในแบ็คพรีอพพากะชันนิวรอนเน็ตเวิร์ก(Back Propagation Network)
3. ลีเนียร์แอ็คติเวชัน (linear activation function) ใช้กลับค่าที่มีเอาต์พุตเท่ากับค่าน้ำหนักของนิวรอนในส่วนอินพุต มักจะใช้ในจัดการค่าประมาณ




รูปที่ 3.11 แสดงเอ็คนิเวชัน ฟังก์ชันชนิดต่าง

3.3.2 รูปแบบการใช้งานนิรอนแบบต่างๆ

มัลติเลเยอร์ เพอร์เซ็ปตรอนเน็ตเวิร์ค (Multi-layered perceptron Network) เน็ตเวิร์คแบบนี้จะมีลักษณะแบ่งออกเป็นชั้นหรือเลเยอร์ (Layer) ซึ่งประกอบไปด้วยอินพุตยูนิต (Input units), เอาท์พุตยูนิต (Output units) และฮิดเดนยูนิต (Hidden units) ซึ่งจำนวนชั้นของชั้นซ่อน จะแตกต่างกันไปตามความซับซ้อนของการคำนวณที่ใช้กล่าวคือ ยิ่งการคำนวณซับซ้อนมาก ก็ต้องมีชั้นของฮิดเดน ยูนิต มากขึ้น ข้อมูลที่รับเข้ามาทาง อินพุต ยูนิต นั้นจะถูกผ่าน ไปให้แต่ละหน่วยประมวลผลที่อยู่ในชั้นเดียวกันเพื่อทำการประมวลผล และสัญญาณเหล่านี้จะถูกส่งผ่านไปเรื่อยๆ สู่ออกไป ซึ่งจะมีการให้ค่าความสำคัญ (Weight) ของอินพุตที่รับเข้ามาจากหน่วยต่างๆ แตกต่างกันไป และสัญญาณจะถูกส่งต่อระหว่างชั้นไปเรื่อยๆ จนกระทั่ง ไปถึงเอาพุตยูนิตซึ่งจะส่งผลลัพธ์ที่ได้ออกมา โดยค่าน้ำหนักของอินพุตต่างๆ นั้น จะถูกปรับโดยวิธีการเรียนรู้ (Learning) โดยวิธีการเรียนรู้ ก็คือการนำข้อมูลที่ทราบผลลัพธ์ แล้ว มาใช้เป็นอินพุต และเปรียบเทียบค่าเอาพุตที่ได้กับผลลัพธ์หาค่าความผิดพลาด


จากนั้นจึงนำค่าความผิดพลาดที่ได้มาทำการปรับน้ำหนัก (Weight) ภายใน Neural Network ซึ่งวิธีการปรับค่าน้ำหนักนั้นขึ้นอยู่กับวิธีการเรียนรู้ที่เลือกใช้ ซึ่งวิธีการเรียนรู้นั้นมีหลายรูปแบบ ขึ้นกับการออกแบบ โครงสร้างภายในของ นิรอน เน็ตเวิร์คและประเภทของงานที่นำไปใช้



รูปที่ 3.12 แสดงการทำงานหลายเลเยอร์

3.3.2 แแบ็คพร็อพกาเกชัน นิวรอลเน็ตเวิร์ค (Back-propagation neural network)

แบ็คพร็อพกาเกชัน นิวรอลเน็ตเวิร์ค เป็นวิธีการเรียนรู้รูปแบบหนึ่ง ซึ่งเป็นที่นิยมใช้ โดยอาศัยประสบการณ์ที่ได้จากความรู้ของการแปลงสัญญาณระหว่างอินพุตและเอาต์พุตภายในเน็ตเวิร์คแบบหลายเลเยอร์ด้วยรูปแบบของการเรียนรู้แบบมีครูสอน ขั้นตอนการดำเนินการของแบ็คพร็อพกาเกชันประกอบด้วยสองส่วนหลัก คือส่วนของการป้อนไปข้างหน้าและส่วนการป้อนกลับ ซึ่งในส่วนป้อนไปข้างหน้าอินพุตแพทเทิร์นจะถูกคำนวณผ่านเน็ตเวิร์คและสร้างเอาต์พุตที่แน่นอน ในส่วนการป้อนกลับนั้นค่าความแตกต่างระหว่างเอาต์พุตจริงที่ต้องการ กับค่าที่ได้จากการคำนวณ ในเลเยอร์สุดท้ายจะสร้างสัญญาณค่าผิดพลาดของสำหรับแพทเทิร์น และจะถูกแพร่ขยาย (Propagate) แบบย้อนกลับผ่านเน็ตเวิร์คเดิมเพื่อปรับค่าตัวเลขน้ำหนักของระบบ ซึ่งการทำงานจะกระทำซ้ำในลักษณะเดิมอีกครั้ง จนกระทั่งค่าผิดพลาดของระบบโดยรวม น้อยกว่าค่าผิดพลาดของระบบที่ยอมรับได้ การเรียนรู้ของระบบจึงถือว่าสมบูรณ์



รูปที่ 3.13 แสดงการทำงานของแบ็คพรีอพพากชัน นิวรอลเน็ตเวิร์ค

3.4 ฟัชซีอินเฟอร์เรนซ์ซิสเต็ม (Fuzzy Inference System)


ฟัชซีอินเฟอร์เรนซ์ซิสเต็ม (Fuzzy Inference System:FIS) หรือรู้จักกันในชื่อ ฟัชซีรูเบสซิสเต็ม (Fuzzy Rule-based System) โดยทั่วไปแล้ว ฟัชซีอินเฟอร์เรนซ์ซิสเต็ม ประกอบด้วยส่วนต่างๆ แสดงดังรูปที่ 3.9

1. รูเบส (Rule base) เป็นส่วนของกฎ fuzzy if-then
2. คาตาเบส (Database) เป็นส่วนการกำหนดฟังก์ชันความเป็นสมาชิกซึ่งนำมาใช้กับกฎ fuzzy if-then
3. ดีซิชั่นเมคกิงยูนิต (Decision making unit) เป็นส่วนของการวินิจฉัยเพื่อตัดสินใจ
4. ฟัชซีฟิเคชัน อินเตอร์เฟส (Fuzzification interface) เป็นส่วนของการแปลงค่าของอินพุทไปเป็นค่าตัวแปรฟัชซี
5. ดีฟัชซีฟิเคชัน อินเตอร์เฟส (Defuzzification interface) เป็นส่วนของการแปลงผลการวินิจฉัยซึ่งอยู่ในรูปฟัชซีไปเป็นค่าตัวเลข

ซึ่งโดยทั่วไป รูเบสและคาตาเบสรวมกันเรียกว่า ฐานความรู้ (Knowledge base) ซึ่งขั้นตอนการทำงานของฟัชซีอินเฟอร์เรนซ์ มีดังนี้

1. ฟัชซีฟิเคชัน (Fuzzification) เป็นส่วนของการเปรียบเทียบค่าของอินพุทกับฟังก์ชันความเป็นสมาชิก เพื่อกำหนดเป็นค่าตัวแปรฟัชซี

2. รูลอีวาสุเอชัน (Rule evaluation) เป็นการคำนวณค่าจากกฎเพื่อรวมค่าความเป็นสมาชิกของส่วนเงื่อนไขของกฎแต่ละตัว ซึ่งค่าที่ได้เรียกว่าไฟร์ริง เสตร์ง (firing strength) ของกฎ
3. อะกรีเกชัน (Aggregation) เป็นการรวมเอาที่พุดของกฎหลายๆกฎ ซึ่งเป็นการนำฟังก์ชันความเป็นสมาชิกของเอาที่พุดของแต่ละกฎมารวมกัน
4. คีฟิซซิฟิเคชัน (Defuzzification) ขั้นตอนสุดท้ายของฟัซซีอินเฟอร์เรนซ์ คือการแปลงค่าผลรวมของเอาที่พุดซึ่งอยู่ในรูปของฟัซซีเซตไปเป็นค่าตัวเลข ซึ่งมี 2 วิธีคือ แมมดานิ สไตล์ (Mamdani-style) ซึ่งเป็นการหาค่าเซ็นเตอร์ออฟกราวิตี (Center of Gravity) และสุจิโนสไตล์ (Sugeno-style) ซึ่งเป็นการหาค่าน้ำหนักเฉลี่ย



รูปที่ 3.15 แสดงส่วนประกอบของฟัซซีอินเฟอร์เรนซ์ซิสเต็ม

3.5 อะแดพทิฟนิวโรฟัซซีอินเฟอร์เรนซ์ซิสเต็ม

Fuzzy Logic (FL) และ Artificial Neural Network (ANN) เป็นเทคนิคสำหรับสร้างระบบอัจฉริยะ ซึ่งเมื่อออกแบบให้ทำงานร่วมกันจะทำให้เครื่องมือทั้งสองทำงานในลักษณะส่งเสริมซึ่งกันและกัน โดย ANN มีคุณสมบัติเด่นทางด้านการเรียนรู้จากข้อมูลที่เป็นข้อมูลดิบ ในขณะที่ FL มีข้อดีทางการให้เหตุผล โดยการใช้ลิ่งกวิสติกอินฟอร์เมชันที่ได้จากผู้เชี่ยวชาญ อย่างไรก็ตาม FL ก็มีจุดอ่อนทางด้านการเรียนรู้และการปรับระบบให้เข้ากับสภาพแวดล้อมของปัญหาต่างๆ ถึงแม้ว่า ANN มีจุดเด่นในด้านการเรียนรู้และการปรับตัวเองแต่ก็มีจุดอ่อนเนื่องจากการทำงานในลักษณะการคำนวณที่ซับซ้อน ทำให้ผู้ใช้ไม่สามารถเข้าถึงกระบวนการคำนวณภายในทำให้กระบวนการนำเสนอความรู้แก่ผู้ใช้ทำได้ไม่ดี การรวมการทำงานของ ANN และ FL ภายใต้ชื่อนิวโรฟัซซี (neuro-fuzzy) ทำให้ระบบเกิดการผสมผสานการทำงานในการนำเสนอองค์ความรู้แล้วนำความรู้

นั้นมาวินิจฉัยประกอบการตัดสินใจ อีกทั้งทำให้ระบบยังสามารถเรียนรู้และปรับตัวในสภาพแวดล้อมขององค์ความรู้เหล่านั้นได้อย่างที่มนุษย์สามารถทำได้


Adaptive Neuro-Fuzzy Inference System (ANFIS) เป็นนิวรอลเน็ตเวิร์คแบบหลายชั้น ที่ทำงานเสมือนระบบพีซีอินเฟอร์เรนซ์ ซึ่งทำให้ระบบสามารถเรียนรู้และปรับค่าพารามิเตอร์ของกฎ if-then โครงสร้างของ ANFIS ประกอบด้วยชั้นอินพุต ชั้นซ่อนและชั้นเอาต์พุต ซึ่งแทน membership function และกฎ fuzzy if-then ตามลำดับ โดยจำนวน โหนดของกฎ fuzzy if-then จะมีจำนวนเท่ากับ p^n เมื่อ p แทนจำนวนการแบ่ง membership function ของอินพุตและ n แทนจำนวนอินพุต

3.5.1 โครงสร้างของ ANFIS

ปีค.ศ. 1993 R. Jang ได้เสนองานวิจัยทางด้าน Neural Network ซึ่งทำงานเทียบเท่ากับ Fuzzy Inference ตามแบบของ Sugeno Fuzzy Inference โดยใช้ชื่อว่า Adaptive Neuro-Fuzzy Inference System หรือ ANFIS โครงสร้าง ANFIS ซึ่งมี 2 อินพุตและกฎพีซี 2 กฎแสดงดังรูปที่ 3.10 การทำงานของ ANFIS ใน layer ต่างๆ ดังนี้ :

Rule1: If x is A_1 and y is B_1 then $f_1 = p_1x + q_1y + r_1$

Rule2: If x is A_2 and y is B_2 then $f_2 = p_2x + q_2y + r_2$



รูปที่ 3.16 โครงสร้าง ANFIS แบบ 2 อินพุตและกฎพีซี 2 กฎ

Layer1 Fuzzification layer: แต่ละ node ในชั้นนี้แสดงอยู่ในรูปของ membership function ดังสมการที่ 3.10

$$\begin{aligned}
 O_i^1 &= \mu_{A_i}(x), i = 1,2 \\
 O_i^1 &= \mu_{B_i}(y), i = 3,4
 \end{aligned}
 \tag{3.10}$$

โดยที่ x (หรือ y) แทนอินพุทของ node i , และ A_i (หรือ B_i) แทนค่าปริมาณ Linguistic Variable ซึ่งในขั้นนี้ใช้การกำหนด Membership Function แบบ Bell ด้วยสมการที่ 3.11

$$\mu_{A_i}(x) = \frac{1}{1 + \left(\frac{x - c_i}{a_i}\right)^{2b_i}} \quad (3.11)$$

โดยที่ a_i , b_i และ c_i เป็นพารามิเตอร์แทนจุดศูนย์กลาง (center) ความกว้าง (width) และ slope ของ Bell Function ตามลำดับ

Layer2 Rule Antecedent Layer: node ในขั้นนี้ทำงานตามหลักของ Fuzzy Rule ตามแบบของ Sugeno เอาท์พุทของขั้นนี้แทน firing strength ของ fuzzy rule ดังสมการที่ 3.12

$$O_i^2 = w_i = \mu_{A_i}(x) \times \mu_{B_i}(y), i = 1, 2 \quad (3.12)$$

Layer3 Rule consequent layer: ในขั้นนี้รับอินพุทจาก Rule Antecedent Layer แล้วคำนวณหาค่า Normalized Firing Strength. ตามสมการที่ 3.13

$$O_i^3 = \bar{w}_i = \frac{w_i}{\sum_i w_i}, i = 1, 2 \quad (3.13)$$

Layer4 Combination and Defuzzification Layer: แต่ละ node ในขั้นนี้เป็น square node กำหนดตามสมการที่ 3.14

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x_1 + q_i x_2 + r_i), i = 1, 2 \quad (3.14)$$

โดยที่ \bar{w}_i เป็นเอาท์พุทของ layer 3, และ $\{p_i; q_i; r_i\}$ เป็นเซตของ Consequent Parameter ซึ่งใช้ Least Means Square Algorithm เพื่อหาค่า consequent parameters

Layer5 Rule Inference layer: เป็นนิรอรผลรวม ซึ่งคำนวณค่าผลรวมของ เอาท์พุท ของ Defuzzification Neuron ทุกตัว และให้ค่าเอาท์พุทของ ANFIS ดังสมการที่ 3.15

$$Overall\ output = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (3.15)$$

3.5.2 การเรียนรู้ของ ANFIS

ANFIS เรียนรู้โดยการใช้อัลกอริทึมการเรียนรู้แบบผสม (hybrid learning algorithm) ซึ่งเป็นการทำงานร่วมกันของอัลกอริทึม least-square estimator และอัลกอริทึม gradient descent method โดยการทำงานลำดับแรกกำหนดค่าเริ่มต้นของแอกติเวชันฟังก์ชัน (activation function)

ให้กับเมมเบอร์ชิพนิวรอน (membership neuron) แต่ละตัว จากนั้นฟังก์ชันจะจัดศูนย์กลางของนิวรอนที่เชื่อมต่อกับอินพุต x จะกำหนดความกว้างและสโลป (slope) เพื่อให้เกิดการทับซ้อนกัน

อัลกอริทึมสำหรับฝึกสอนของ ANFIS ในแต่ละรอบการทำงาน (epoch) จะประกอบด้วยฟอร์เวิร์ดพาส (forward pass) และแบ็กเวิร์ดพาส (backward pass) โดยในส่วนฟอร์เวิร์ดพาส (forward pass) มีการนำเข้าข้อมูลสำหรับฝึกสอนของอินพุตแล้วทำการคำนวณเอาต์พุต ในแต่ละชั้นและเอาต์พุตของรูคคอนซีควนซ์ (rule consequent) จะถูกกำหนดโดยอัลกอริทึม least-square estimator จากการที่ ANFIS ใช้ลักษณะการอินเฟอร์เรนซ์ตามแบบของซูกิโน (Sugeno-style fuzzy inference) เอาต์พุต y ที่ได้จึงเป็นลิเนียร์ฟังก์ชัน (linear function) ในส่วนแบ็กเวิร์ดพาส (backward pass) จะใช้อัลกอริทึมแบ็กพรอปเพเกชัน (back-propagation algorithm) ซึ่งมีการส่งค่า error กลับมา แล้วทำการปรับค่าพารามิเตอร์ของแอนทีซีเดนซ์ (antecedent parameter)

3.6 สรุป

การสร้างระบบอัจฉริยะแบบผสม โดยเฉพาะการผสมผสานการทำงานของ อาร์ทิฟิเชียล นิวรอลเน็ตเวิร์ค (Artificial Neural Network) และ ฟัซซีลอจิก (Fuzzy Logic) ทำให้ระบบนำเสนอองค์ความรู้ แล้วนำความรู้นั้นมาวินิจฉัยประกอบการตัดสินใจ อีกทั้งทำให้ระบบยังสามารถเรียนรู้และปรับตัวเองในสภาพแวดล้อมขององค์ความรู้เหล่านั้นได้อย่างที่มนุษย์สามารถทำได้

บทที่ 4

แกรนูลาร์คอมพิวติง

ในบทนี้จะกล่าวถึงหลักการพื้นฐานของแกรนูลาร์คอมพิวติง หรือเรียกอีกชื่อหนึ่งคือการคำนวณแกรนูลาร์ (Granular Computing: GrC) ซึ่งในงานวิจัยนี้นำมาใช้เป็นหลักการในการสร้างกฎ โดยอันดับแรกจะทำการสร้างโครงสร้างของแกรนูล (Granular) ด้วยการแบ่งสารสนเทศออกเป็นแกรนูลย่อย จากนั้นทำการประมวลผลแกรนูลในแต่ละลำดับชั้น หากแกรนูลในชั้นนั้นๆ ยังไม่ครอบคลุมการแก้ปัญหาที่นั้นๆ จะทำการประกอบ หรือแยกส่วนประกอบของแกรนูล จนกว่าจะครอบคลุมการแก้ปัญหาที่นั้นๆ ได้ทั้งหมด

4.1 บทนำ

Information Granulation เป็นปัจจัยสำคัญของการแก้ปัญหาของมนุษย์ โดยเฉพาะการออกแบบและสร้างระบบอัจฉริยะ Professor L.A. Zadeh ได้นำเสนอแนวคิดพื้นฐานของการแก้ปัญหาด้านการรู้จำของมนุษย์ในหลายๆ รูปแบบ เช่น Granulation, Organization และ Causation โดย Granulation เป็นแนวคิดที่เกี่ยวกับการแยกส่วนประกอบออกเป็นส่วนย่อยๆ Organization เป็นหลักการรวมส่วนย่อยเข้าด้วยกัน และ Causation เป็นแนวคิดที่เกี่ยวกับการรวมหลักของเหตุและผล โดยแนวคิดของการคำนวณแกรนูลาร์ ในการแก้ปัญหา ทำการแบ่งปัญหาออกเป็นส่วนย่อยเรียกว่าแกรนูล โดยโครงสร้างของแกรนูลกำหนดให้อยู่ในรูปของ ความสัมพันธ์คล้ายกัน ความน่าจะเป็น และ ความสัมพันธ์ในรูปของกฎ Fuzzy if-then

4.2 หลักการพื้นฐานของการคำนวณแกรนูลาร์

การแก้ปัญหาโดยใช้หลักการของการคำนวณแกรนูลาร์ ชั้นแรกแบ่งปัญหาออกเป็นแกรนูลย่อย จากนั้นในการคำนวณในแต่ละลำดับชั้นแกรนูลจะประกอบกันหรือแยกส่วนได้เป็นแกรนูลใหม่แล้วทำการประมวลผลไปจนกระทั่งแกรนูลใหม่แก้ปัญหาที่นั้นๆ ได้อย่างถูกต้อง ซึ่งหลักการเบื้องต้นของการคำนวณแกรนูลาร์มีดังนี้

นิยามที่ 1 [5] กำหนดให้ปัญหาอยู่ในรูปของตารางสารสนเทศมีส่วนประกอบดังนี้ $S = \langle U, R, V, f \rangle$ โดยที่ U แทนเซตของวัตถุ $R = C \cup D$ แทนเซตของคุณลักษณะ ซึ่งประกอบด้วยเซตของส่วนเงื่อนไข I และเซตของส่วนตัดสินใจ (D) สำหรับทุกๆ คุณลักษณะ $r \in R$ เซตของค่า V_r กำหนดโดย $V = \bigcup_{r \in R} V_r$ สำหรับแต่ละคุณลักษณะ x กำหนดฟังก์ชัน $f_x : U \times R \rightarrow V$

นิยามที่ 2 กำหนดให้สารสนเทศ $S = \langle U, R, V, f \rangle$ สมการลอจิกที่ใช้ในการตัดสินใจในสารสนเทศ S เขียนอยู่ในรูปแบบ (r, v) โดยที่ $r \in R$ และ $v \in V$, ถ้ากำหนดให้ ϕ และ φ แทนฟอร์มูลา (formula) แล้วการกระทำของฟอร์มูลาในรูปแบบต่างๆ ดังนี้ $\sim\phi$, $\phi \wedge \varphi$, $\phi \vee \varphi$, และ $\phi \rightarrow \varphi$ ก็ยังคงเป็นฟอร์มูลาด้วย ถ้ากำหนดให้วัตถุ x สนับสนุนฟอร์มูลา ϕ เขียนอยู่ในรูปของ $x \models \phi$ แล้ว $m(\phi) = \{x \in U \mid x \models \phi\}$ แทนเซตของวัตถุ x ทั้งหมดที่มีคุณสมบัติตรงตามสมการ ϕ ในการกำหนด แกรนมูลพื้นฐานจากของตารางสารสนเทศอยู่ในรูปของ $(\phi, m(\phi))$

นิยามที่ 3 [5] กำหนดให้ฟอร์มูลาสองฟอร์มูลา ϕ และ φ ซึ่งค่า confidence support ของสมการ φ ที่ถูกกำหนดโดยฟอร์มูลา ϕ

$$AS(\phi \Rightarrow \varphi) = |m(\phi) \cap m(\varphi)| / |m(\phi)| \quad (4.1)$$

โดย ค่า Absolute Support (AS) แสดงในรูปของค่า support เชิงปริมาณ

นิยามที่ 4 [8] กำหนดให้ สารสนเทศ $S = \langle U, R, V, f \rangle$ โดยที่ U แทนเซตของวัตถุ $R = C \cup D$ ซึ่ง $U/IND(C)$ และ $U/IND(D)$ เป็นตัวแบ่งกัน U โดย C และ D ซึ่งกลุ่มของส่วนเงื่อนไข E_i กำหนดโดย $E_i \in U/IND(C)$ โดยที่ $i=1, \dots, m$, $m = |U/IND(C)|$ กลุ่มของส่วนตัดสินใจ X_j กำหนดโดย $X_j \in U/IND(D)$ โดยที่ $j=1, \dots, n$, $n = |U/IND(D)|$

นิยามที่ 5 [8] กำหนดให้สารสนเทศ $S = \langle U, R, V, f \rangle$ ค่า certainty ของกลุ่มเงื่อนไข $E_i \in U/IND(C)$, $i=1, \dots, m$ กำหนดโดย

$$k(E_i) = \max \left\{ \frac{|E_i \cap X_j|}{|E_i|} \mid X_j \in U/IND(D) \right\} \quad (4.2)$$

นิยามที่ 6 [8] ให้ $C_k \in C$ $k(E_{k_1}), \dots, k(E_{k_l})$ แทนค่า certainty ของเงื่อนไข Minimum local certainty กำหนดโดย

$$a_c(C_k) = \min \{ k(E_{k_1}), \dots, k(E_{k_l}), \dots, k(E_{k_m}) \} \quad (4.3)$$

นิยามที่ 7 [8] กำหนดให้ สารสนเทศ $S = \langle U, R, V, f \rangle$ global certainty กำหนดโดย

$$\mu_c(C_k) = \frac{\sum_{i=1}^m |T_{ki}|}{|U|} \quad (4.4)$$

โดยที่ $T_{ki} = \max_j \{|E_{ki} \cap X_j|\}$ โดยที่ $X_j \in U/IND(D)$

4.3 การสร้างกฎด้วยหลักการคำนวณแกรนูลาร์

อัลกอริทึมที่ใช้ในการสร้างกฎ if-then ภายใต้หลักการของการคำนวณแกรนูลาร์จะทำการแทนตารางสารสนเทศ $S = \langle U, R, V, f \rangle$ โดยที่ U แทนเซตของวัตถุ $R = C \cup D$ แทนเซตของคุณลักษณะซึ่งประกอบด้วยเซตของส่วนเงื่อนไข และเซตของส่วนตัดสินใจ ให้ ϕ และ φ แทนฟอร์มูลาที่ใช้ตัดสินใจซึ่งอยู่ในรูปแบบของ $\phi = (c_1, v_{c1}) \wedge \dots \wedge (c_p, v_{cp})$ โดยกำหนดให้ $m(\phi) = \{x \in U \mid x = \phi\}$ แทนเซตของวัตถุ x ทั้งหมดที่มีคุณสมบัติตรงตามฟอร์มูลา ϕ ซึ่งการกำหนดแกรนูลพื้นฐานจากของตารางสารสนเทศ อยู่ในรูปแบบ $(\phi, m(\phi))$

จากการแทนตารางสารสนเทศให้อยู่ในรูปแบบแกรนูลพื้นฐานแล้วทำการหา Global certainty (μ_c) ของคุณลักษณะแต่ละตัว แล้วเลือกคุณลักษณะที่มีค่า μ_c สูงที่สุด มาทำการหาค่า Local Certainty (a_c) ของฟอร์มูลา ϕ แล้วเลือกค่าต่ำสุด นำมาเป็นค่าเทรชโฮลด์ (Threshold) ของการสร้างกฎ ซึ่งอัลกอริทึมที่ใช้ในการสร้างกฎ if-then สรุปเป็นลำดับขั้นตอนดังนี้

ขั้นที่ 1. กำหนดค่าเริ่มต้นของเซตของ Rule Set $RS = \{\Phi\}$, $Gr_{RS} = \{\Phi\}$, $DFS = \{\Phi\}$, $h=1$

- Gr_{RS} แทนเซตของวัตถุที่ถูกรวมถึง
- DFS เป็นเซตของฟอร์มูลาของส่วนตัดสินใจ
- h แทนความยาวของการขยายแกรนูล

ขั้นที่ 2. คำนวณหาค่า minimum local certainty (a_c) ของตารางสารสนเทศ

ขั้นที่ 3. คำนวณการประมวลผลแกรนูลในแต่ละลำดับขั้น

สำหรับแต่ละ $\varphi_j \in DFS$ หาค่า $AS(\phi_i^h \Rightarrow \varphi_j)$

ถ้า $AS(\phi_i^h \Rightarrow \varphi_j) \geq a_c$ และ $m(\phi_i^h) - Gr_{RS} \neq \Phi$ แล้ว

$RS = RS \cup \{\phi_i^h \Rightarrow \varphi_j \mid AS(\phi_i^h \Rightarrow \varphi_j) \geq a_c\}$,

$Gr_{RS} = Gr_{RS} \cup \{m(\phi_i^h \Rightarrow \varphi_j)\}$

ขั้นที่ 4. ถ้า $U - Gr_{RS} \neq \{\Phi\}$ แล้ว $h = h + 1$ กลับไปขั้นตอนที่ 3 ถ้าไม่หยุดการทำงาน

4.4 ตัวอย่างการสร้างกฎด้วยหลักการคำนวณแกรนูลาร์

จากตัวอย่างตารางสารสนเทศดังตารางที่ 4.1 ประกอบด้วยคุณลักษณะส่วนเงื่อนไข 4 คุณลักษณะคือ outlook, temp(Temperature), hum(humidity), windy และคุณลักษณะส่วนตัดสินใจ ซึ่งมีกลุ่มของข้อมูล 2 กลุ่ม เมื่อแทนตารางสารสนเทศให้อยู่ในรูปแกรนูลพื้นฐานเพื่อประมวลผลในลำดับขั้นแรก ซึ่งแทนในรูปแบบ $\phi = (c_1, v_{c1}) \wedge \dots \wedge (c_p, v_{cp})$ ได้ตารางแสดงแกรนูลพื้นฐานดังตารางที่ 4.2

ตารางที่ 4.1 ตัวอย่างตารางสารสนเทศ

	Outlook	Temp	Hum	Windy	D
E1	Overcast	Hot	High	Not	Y
E2	Overcast	Hot	High	Very	N
E3	Overcast	Hot	High	Medium	N
E4	Sunny	Hot	High	Not	Y
E5	Sunny	Hot	High	Medium	Y
E6	Rain	Mild	High	Not	N
E7	Rain	Mild	High	Medium	N
E8	Rain	Hot	Normal	Not	Y
E9	Rain	Cool	Normal	Medium	N
E10	Rain	Hot	Normal	Very	N
E11	Sunny	Cool	Normal	Very	Y
E12	Sunny	Cool	Normal	Medium	Y
E13	Overcast	Mild	High	Not	N
E14	Overcast	Mild	High	Medium	N
E15	Overcast	Cool	Normal	Not	Y
E16	Overcast	Cool	Normal	Medium	Y
E17	Rain	Mild	Normal	Not	N
E18	Rain	Mild	Normal	Medium	N
E19	Overcast	Mild	Normal	Medium	Y
E20	Overcast	Mild	Normal	Very	Y
E21	Sunny	Mild	High	Very	Y
E22	Sunny	Mild	High	Medium	Y
E23	Sunny	Hot	Normal	Not	Y
E24	Rain	Mild	High	Very	N
E25	Overcast	Hot	High	Not	N

ตารางที่ 4.2 แกรนนูลพื้นฐานของการประมวลผลในลำดับชั้นแรก

ϕ	$m(\phi)$	φ	$m(\varphi)$
(outlook, overcast)	{E1, E2, E3, E13, E14, E15, E16, E19, E20, E25}	(D,Y)	{E1, E4, E5, E8, E11, E12, E15, E16, E19, E20, E21, E22, E23}
(outlook, rain)	{E6, E7, E8, E9, E10, E17, E18, E24}		
(outlook, sunny)	{E4, E5, E11, E12, E21, E22, E23}		
(temp, cool)	{E9, E11, E12, E15, E16}	(D,N)	{E2, E3, E6, E7, E9, E10, E13, E14, E17, E18, E24, E25}
(temp, hot)	{E1, E2, E3, E4, E5, E8, E10, E23, E25}		
(temp, mild)	{E6, E7, E13, E14, E17, E18, E19, E20, E21, E22, E24}		
(hum, high)	{E1, E2, E3, E4, E5, E6, E7, E13, E14, E21, E22, E24, E25}		
(hum, normal)	{E8, E9, E10, E11, E12, E15, E16, E17, E18, E19, E20, E23}		
(windy, not)	{E1, E4, E6, E8, E13, E15, E17, E23, E25}		
(windy, medium)	{E3, E5, E7, E9, E12, E14, E16, E18, E19, E22}		
(windy, very)	{E2, E10, E11, E20, E21, E24}		

จากแกรนนูลพื้นฐานของการประมวลผลในลำดับชั้นแรก ซึ่งเมื่อคำนวณหาค่า T_{ki} ของคุณลักษณะแต่ละคุณลักษณะได้ดังตารางที่ 4.3

ตารางที่ 4.3 แสดงการหาค่า T_{ki} ของแต่ละคุณลักษณะ

ϕ	$ E_{ki} \cap X_{(Y)} $	$ E_{ki} \cap X_{(N)} $
(outlook, overcast)	5	5
(outlook, rain)	1	7
(outlook, sunny)	7	0
(temp, cool)	1	4
(temp, hot)	5	4
(temp, mild)	4	7
(hum, high)	5	8
(hum, normal)	8	4
(windy, not)	5	4
(windy, medium)	5	5
(windy, very)	3	3

จากค่า T_{ki} ของแต่ละคุณลักษณะนำค่าที่ได้มาหาค่า global certainty ของคุณลักษณะได้ดังตารางที่ 4.5 ซึ่งค่า global certainty ของคุณลักษณะ outlook มีค่าสูงสุด ฉะนั้นจะใช้คุณลักษณะของ outlook เพื่อหาค่า minimum local certainty (a_c) ตามสมการที่ 4.3 ซึ่งผลลัพธ์ของการหาค่า a_c ของคุณลักษณะ outlook แสดงดังตารางที่ 4.5

ตารางที่ 4.4 แสดงการหาค่า global certainty ของคุณลักษณะแต่ละตัว

คุณลักษณะ	Global Certainty (μ_c)
outlook	$(5+7+7) / 25 = 0.76$
temp	$(4+5+7) / 25 = 0.64$
hum	$(8+8) / 25 = 0.64$
windy	$(5+5+3) / 25 = 0.52$

ตารางที่ 4.5 แสดงการหาค่า minimum local certainty ของคุณลักษณะ outlook

ϕ	$k(E_{ki})$
(outlook, overcast)	$5 / (5+5) = 0.5$
(outlook, rain)	$7 / (7+1) = 0.875$
(outlook, sunny)	$7 / (7+0) = 1$

จากตัวอย่างตารางสารสนเทศได้ค่า minimum local certainty เท่ากับ 0.5 ซึ่งค่าที่ได้จะนำเป็นค่าเทรสโฮลด์ (Threshold) ของการสร้างกฎด้วยอัลกอริทึมสำหรับการสร้างกฎ ด้วยหลักการคำนวณแกรนูลาร์ ซึ่งจากตารางแกรนูลพื้นฐานของการประมวลผลในลำดับขั้นแรก เมื่อคำนวณหาค่า certainty support ของกลุ่มเงื่อนไขของคุณลักษณะแต่ละตัวได้ผลลัพธ์แสดงดังตารางที่ 4.6

ตารางที่ 4.6 แสดงค่า certainty support ของแกรนูลพื้นฐานในขั้นแรก

ϕ	$AS(\phi \Rightarrow \varphi_{(Y)})$	$AS(\phi \Rightarrow \varphi_{(N)})$
(outlook, overcast)	0.5	0.5
(outlook, rain)	0.125	0.85
(outlook, sunny)	1	0
(temp, cool)	0.8	0.2
(temp, hot)	0.55	0.44
(temp, mild)	0.36	0.63
(hum, high)	0.38	0.61
(hum, normal)	0.66	0.33
(windy, not)	0.55	0.44
(windy, medium)	0.5	0.5
(windy, very)	0.5	0.5

จากการพิจารณาค่า certainty support ของ $AS(\phi \Rightarrow \varphi_{(Y)})$ และ $AS(\phi \Rightarrow \varphi_{(N)})$ สำหรับแต่ละ $\varphi_j \in DFS$ หาค่า ถ้า $AS(\phi_i^h \Rightarrow \varphi_j) \geq a_c$ และ $m(\phi_i^h) - Gr_{RS} \neq \Phi$ แล้ว $RS = RS \cup \{\phi_i^h \Rightarrow \varphi_j \mid AS(\phi_i^h \Rightarrow \varphi_j) \geq a_c\}$

จะได้

$$R_1: (\text{outlook, overcast}) \Rightarrow (D, Y) \mid 0.5, R_2: (\text{outlook, rain}) \Rightarrow (D, N) \mid 0.85$$

$$R_3: (\text{outlook, sunny}) \Rightarrow (D, N) \mid 1, R_4: (\text{temp, cool}) \Rightarrow (D, Y) \mid 0.8$$

$$R_5: (\text{temp, hot}) \Rightarrow (D, Y) \mid 0.55, R_6: (\text{temp, mild}) \Rightarrow (D, N) \mid 0.63$$

$$R_7: (\text{hum, high}) \Rightarrow (D, N) \mid 0.61, R_8: (\text{hum, normal}) \Rightarrow (D, Y) \mid 0.66$$

$$R_9: (\text{windy, not}) \Rightarrow (D, Y) \mid 0.55, R_{10}: (\text{windy, medium}) \Rightarrow (D, Y) \mid 0.5$$

$$R_{11}: (\text{windy, very}) \Rightarrow (D, Y) \mid 0.5$$

พิจารณา $Gr_{RS} = Gr_{RS} \cup \{m(\phi_i \Rightarrow \phi_j)\}$

จะได้ $Gr_{RS} = \{E1 \cup E2 \cup E3 \dots \cup \dots E25\}$, $U - Gr_{RS} = \{\Phi\}$, หยุดการทำงาน

4.5 สรุป

ในบทนี้ได้นำเสนอหลักการพื้นฐานของการสร้างกฎ fuzzy if-then ด้วยหลักการคำนวณแแกรนูลาร์ ซึ่งในงานวิจัยนี้ นำกฎ fuzzy if-then ที่ได้ไปปรับปรุงโครงสร้างของ ANFIS ในชั้น รูลแอนทีซีเดนต์ (rule antecedent layer) ของ ANFIS ต่อไป

บทที่ 5

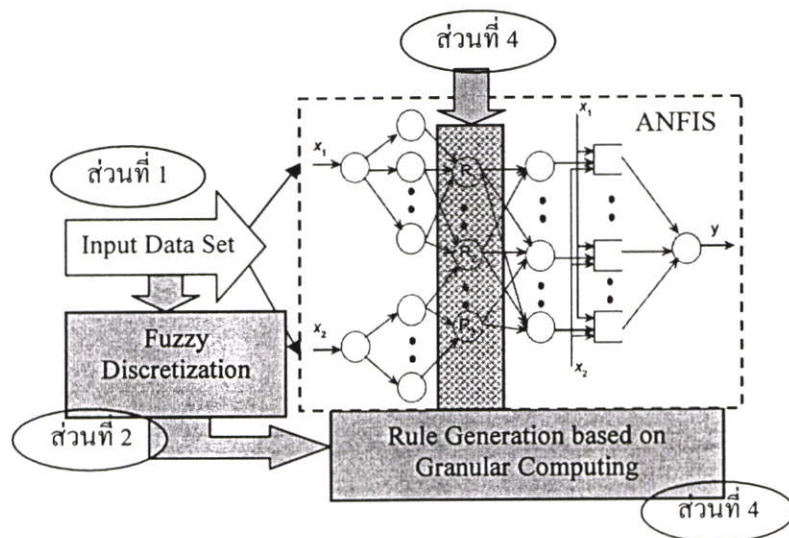
การปรับปรุง ANFIS

ในบทนี้จะกล่าวถึงหลักการและวิธีการดำเนินงานวิจัย ของงานวิจัยที่ผู้วิจัยนำเสนอ ซึ่งในส่วนนี้จะนำเสนอถึงวิธีการในการดำเนินงานวิจัย การเตรียมข้อมูลที่ใช้ในการทดลอง แสดงโมเดล การทดลอง และการวัดประสิทธิภาพของระบบ เป็นต้น

โครงสร้างเดิมของ ANFIS ที่มีจำนวนอินพุต n และจำนวนของการแบ่งฟังก์ชันความเป็นสมาชิกออกเป็น p ดังนั้นจำนวนกฎที่ได้เป็น p^n ให้ m แทนจำนวน fitting parameter ของฟังก์ชันความเป็นสมาชิกแต่ละตัว จำนวน premise fitting parameter ของแต่ละอินพุตเป็น $p \cdot m$ ดังนั้นจำนวน premise fitting parameter ทั้งหมดเป็น $p \cdot m \cdot n$ ซึ่งในงานวิจัยนี้ทำการลดจำนวน premise fitting parameter ด้วยการสร้าง กฎ if-then โดยใช้หลักการคำนวณแกรนูลาร์

กระบวนการทำงานของระบบเพื่อปรับปรุง ANFIS แสดงดังรูปที่ 5.1 จากรูป จากภาพส่วนที่ 1 คือข้อมูลที่ใช้ในการสร้างกฎและใช้ฝึกสอน ANFIS ซึ่งเป็นข้อมูลที่มีลักษณะต่อเนื่อง ส่วนที่ 2 เป็นส่วนที่ทำหน้าที่แปลงข้อมูลที่มีลักษณะต่อเนื่องเป็นช่วง ส่วนที่ 3 เป็นส่วนที่ทำหน้าสร้างกฎ โดยใช้หลักการคำนวณแกรนูลาร์ และส่วนที่ 4 เป็นส่วนของการลดจำนวน โหนดในชั้นกฎของ ANFIS โดยมีลำดับขั้นตอน การทำงานของระบบดังนี้

1. กระบวนการเตรียมข้อมูล
2. กระบวนการสร้างกฎด้วยหลักการคำนวณแกรนูลาร์
3. กระบวนการปรับปรุง ANFIS



รูปที่ 5.1 แสดงขั้นตอนการทำงานของระบบ

5.1 กระบวนการเตรียมข้อมูล

ข้อมูลที่ใช้สำหรับสร้างกฎฝึกสอนและทดสอบ ANFIS งานวิจัยนี้ นำมาจาก UCI Machine Learning Repository โดยข้อมูลที่เลือกมาทำการทดสอบมีดังนี้

5.1.1 ข้อมูล Iris Plants

ข้อมูล Iris Plant ซึ่งสร้างโดย R.A. Fisher ซึ่งรายละเอียดของข้อมูลประกอบด้วย

1. จำนวนคุณลักษณะ 4 คุณลักษณะ
 - sepal length in cm
 - sepal width in cm
 - petal length in cm
 - petal width in cm
2. จำนวนแถวของข้อมูล 150 แถว
3. กลุ่มของข้อมูล มี 3 กลุ่ม
 - Iris Setosa
 - Iris Versicolour
 - Iris Virginica

5.1.2 ข้อมูล KDD Cup 1999

ข้อมูล KDD Cup 1999 [17] เป็นข้อมูลที่จำลองพฤติกรรมกรรมการบุกรุกที่นิยมใช้ในงานวิจัยที่เกี่ยวกับการตรวจจับผู้บุกรุก เป็นข้อมูลที่ประยุกต์มาจากข้อมูลพฤติกรรมกรรมการบุกรุกของ DARPA 98 [17] ซึ่งมีข้อมูลประกอบไปด้วยทั้งพฤติกรรมกรรมการบุกรุกและพฤติกรรมปกติ โดยข้อมูลนี้ได้จากการวิเคราะห์ระบบเครือข่ายของมหาวิทยาลัยโคลัมเบีย (Columbia University) [17]

1. จำนวนคุณลักษณะทั้งหมด 41 คุณลักษณะ สำหรับในงานวิจัยนี้ เลือกทดสอบกับการบุกรุกชนิด Denial of Service ซึ่งใช้คุณลักษณะของข้อมูล 7 คุณลักษณะ
2. จำนวนกลุ่มข้อมูลและ แถวของข้อมูล แสดงดังตาราง

ตารางที่ 5.1 แสดงกลุ่มข้อมูลที่ใช้ทดลอง

Attack Type	จำนวนข้อมูล (เรคคอร์ด)
normal	9,727
neptune	10,720
smurf	28,080
Back	220

5.1.3 ข้อมูล Abalone

ข้อมูล Abalone เป็นข้อมูลการพยากรณ์อายุของหอยชนิดหนึ่ง พัฒนาโดย Sam Waugh Department of Computer Science, University of Tasmania ซึ่งรายละเอียดข้อมูลประกอบด้วย


1. จำนวนคุณลักษณะ 8 คุณลักษณะ
2. จำนวนแถวของข้อมูล 4177 แถว
3. กลุ่มของข้อมูล 29 กลุ่ม

จากข้อมูลที่ใช้ทดสอบทั้งสามชนิด ซึ่งเป็นข้อมูลที่อยู่ในรูปแบบของข้อมูล Continuous ขั้นตอนของการสร้างกฎจะดำเนินการแปลงข้อมูล Continuous เป็น Discrete เพื่อใช้ในการสร้างกฎ ซึ่งการแปลงข้อมูลใช้หลักของ Fuzzy Discretization [7] โดยขั้นแรกจะทำการแปลงค่าของแต่ละคุณลักษณะให้มีค่าอยู่ระหว่าง 0 ถึง 1 โดยใช้สมการต่อไปนี้:

$$x = \frac{x - MIN}{MAX - MIN} \quad (5.1)$$

โดยที่ x คือค่าของคุณลักษณะ
 MIN คือค่าต่ำที่สุดของคุณลักษณะ
 MAX คือค่าสูงที่สุดของคุณลักษณะ

จากนั้นแปลงค่าที่คำนวณได้เป็นค่าฟัซซี่โดยใช้ 3 ฟัซซี่เซต ประกอบด้วย Low(L), Medium(M) และ High(H) ตามลำดับดังรูปที่ 5.2



รูปที่ 5.2 แสดง Fuzzy space ของแต่ละคุณลักษณะ

ผลที่ได้จากการแปลงข้อมูล Continuous เป็น Discrete ของข้อมูลทั้งสาม จะนำไปใช้เป็นตารางสารสนเทศในขั้นตอนของการสร้างกฎ ตัวอย่างผลลัพธ์การแปลงข้อมูลแสดงดังตารางที่ 5.2 5.3 และ 5.4 ตามลำดับ

ตารางที่ 5.2 ตารางสารสนเทศข้อมูล Iris Plants

	sepal length	sepal width	petal length	petal width	Class
E1	c1H	c2M	c3H	c4H	Iris-virginica
E2	c1H	c2M	c3H	c4M	Iris-virginica
E3	c1L	c2L	c3M	c4M	Iris-versicolor
E4	c1L	c2M	c3L	c4L	Iris-setosa
E5	c1M	c2H	c3L	c4L	Iris-setosa
E6	c1M	c2L	c3M	c4H	Iris-virginica
E7	c1M	c2L	c3M	c4M	Iris-versicolor
E8	c1M	c2M	c3H	c4H	Iris-virginica
E9	c1M	c2M	c3H	c4M	Iris-virginica
E10	c1M	c2M	c3L	c4L	Iris-setosa
E11	c1M	c2M	c3M	c4H	Iris-virginica
E12	c1M	c2M	c3M	c4M	Iris-versicolor

ตารางที่ 5.3 ตารางสารสนเทศข้อมูล KDD Cup 1999

A	B	C	D	E	F	G	H	Class
c1H	c2L	c3L	c4L	c5H	c6H	c7L	c8L	Back
c1H	c2L	c3L	c4L	c5L	c6L	c7L	c8L	Back
c1H	c2L	c3L	c4L	c5L	c6L	c7M	c8L	Back
c1H	c2L	c3L	c4L	c5M	c6M	c7L	c8L	Back
c1L	c2L	c3H	c4H	c5H	c6H	c7H	c8L	Smurf
c1L	c2L	c3H	c4H	c5H	c6L	c7M	c8L	Smurf
c1L	c2L	c3H	c4H	c5H	c6M	c7M	c8L	Smurf
c1L	c2L	c3H	c4H	c5M	c6L	c7L	c8L	Smurf
c1L	c2L	c3L	c4L	c5H	c6H	c7H	c8L	Smurf
c1L	c2L	c3L	c4L	c5H	c6H	c7L	c8L	Normal
c1L	c2L	c3L	c4L	c5H	c6L	c7L	c8L	Neptune
c1L	c2L	c3L	c4L	c5L	c6H	c7H	c8L	Normal
c1L	c2L	c3L	c4L	c5L	c6H	c7L	c8L	Normal
c1L	c2L	c3L	c4L	c5L	c6H	c7M	c8L	Normal

ตารางที่ 5.3 ตารางสารสนเทศข้อมูล KDD Cup 1999 (ต่อ)

A	B	C	D	E	F	G	H	Class
c1L	c2L	c3L	c4L	c5L	c6L	c7L	c8L	Normal
c1L	c2L	c3L	c4L	c5L	c6L	c7L	c8L	Neptune
c1L	c2L	c3L	c4L	c5L	c6M	c7L	c8L	Normal
c1L	c2L	c3L	c4L	c5M	c6H	c7L	c8L	Normal
c1L	c2L	c3L	c4L	c5M	c6L	c7L	c8L	Normal
c1L	c2L	c3L	c4L	c5M	c6L	c7L	c8L	Neptune
c1L	c2L	c3L	c4L	c5M	c6M	c7L	c8L	Normal
c1L	c2L	c3M	c4L	c5H	c6L	c7L	c8L	Neptune
c1L	c2L	c3M	c4L	c5M	c6L	c7L	c8L	Neptune
c1L	c2L	c3M	c4M	c5H	c6H	c7H	c8L	Smurf
c1L	c2M	c3L	c4L	c5L	c6H	c7L	c8L	Normal
c1L	c2M	c3L	c4L	c5M	c6H	c7L	c8L	Normal
c1M	c2L	c3L	c4L	c5M	c6M	c7L	c8L	Back

ตารางที่ 5.4 ตารางสารสนเทศข้อมูล Abalone

A	B	C	D	E	F	G	H	Class
c1M	c2H	c3M	c4L	c5M	c6M	c7M	c8M	8
c1M	c2H	c3M	c4L	c5M	c6M	c7M	c8M	9
c1M	c2H	c3M	c4L	c5M	c6M	c7M	c8M	10
c1M	c2H	c3M	c4L	c5M	c6M	c7M	c8M	11
c1M	c2H	c3M	c4L	c5M	c6M	c7M	c8M	12
c1M	c2H	c3M	c4L	c5M	c6M	c7M	c8M	14
c1M	c2H	c3M	c4L	c5M	c6M	c7M	c8M	15
c1M	c2H	c3M	c4L	c5M	c6M	c7M	c8M	16
c1M	c2H	c3M	c4L	c5M	c6M	c7M	c8M	17
c1M	c2L	c3L	c4L	c5L	c6L	c7L	c8L	3
c1M	c2L	c3L	c4L	c5L	c6L	c7L	c8L	4
c1M	c2L	c3L	c4L	c5L	c6L	c7L	c8L	5
c1M	c2L	c3L	c4L	c5L	c6L	c7L	c8L	7
c1M	c2M	c3H	c4L	c5M	c6M	c7M	c8M	8

ตารางที่ 5.4 ตารางสารสนเทศข้อมูล Abalone (ต่อ)

A	B	C	D	E	F	G	H	Class
c1M	c2M	c3H	c4L	c5M	c6M	c7M	c8M	10
c1M	c2M	c3H	c4L	c5M	c6M	c7M	c8M	12
c1M	c2M	c3H	c4L	c5M	c6M	c7M	c8M	13
c1M	c2M	c3L	c4L	c5L	c6L	c7L	c8L	5
c1M	c2M	c3L	c4L	c5L	c6L	c7L	c8L	6
c1M	c2M	c3L	c4L	c5L	c6L	c7L	c8L	7
c1M	c2M	c3M	c4L	c5L	c6L	c7L	c8L	5
c1M	c2M	c3M	c4L	c5L	c6L	c7L	c8L	6
c1M	c2M	c3M	c4L	c5L	c6L	c7L	c8L	8
c1M	c2M	c3M	c4L	c5L	c6L	c7L	c8L	9

5.2 การสร้างกฎด้วยหลักการคำนวณแกรนูลาร์

จากการแทนตารางสารสนเทศให้อยู่ในรูปแบบแกรนูลพื้นฐานแล้วทำการหา Global certainty (μ_c) ของคุณลักษณะแต่ละตัว แล้วเลือกคุณลักษณะที่มีค่า μ_c สูงที่สุด มาทำการหาค่า Local Certainty (a_c) ของฟอร์มูลา ϕ แล้วเลือกค่าต่ำสุดมาเป็นค่าเทรชโฮล (Threshold) ของการสร้างกฎ ซึ่งอัลกอริธึมที่ใช้ในการสร้างกฎ if-then แสดงดังอัลกอริธึมที่ 1 โดยสรุปเป็นลำดับขั้นตอนดังนี้

อัลกอริธึมที่ 1 อัลกอริธึมที่ใช้ในการสร้างกฎ if-then

ขั้นที่ 1. กำหนดค่าเริ่มต้นของเซตของ Rule Set $RS = \{\Phi\}$, $Gr_{RS} = \{\Phi\}$, $DFS = \{\Phi\}$, $h = 1$ โดยที่ Gr_{RS} แทนเซตของวัตถุที่กฎครอบคลุมถึง และ RS, DFS เป็นเซตของ สมการลอจิก h แทนความยาวของการขยายแกรนูล

ขั้นที่ 2. คำนวณหาค่า minimum local certainty (a_c) ของตารางสารสนเทศ

ขั้นที่ 3. คำนวณการประมวลผลแกรนูลในแต่ละลำดับขั้น

สำหรับแต่ละ $\varphi_j \in DFS$ หาค่า $AS(\phi_i^h \Rightarrow \varphi_j)$

ถ้า $AS(\phi_i^h \Rightarrow \varphi_j) \geq a_c$ และ $m(\phi_i^h) - Gr_{RS} \neq \Phi$ แล้ว

$$RS = RS \cup \{\phi_i^h \Rightarrow \varphi_j | AS(\phi_i^h \Rightarrow \varphi_j)\},$$

$$Gr_{RS} = Gr_{RS} \cup \{m(\phi_i^h \Rightarrow \varphi_j)\}$$

ขั้นที่ 4. ขั้นที่ 4. ถ้า $U - Gr_{RS} \neq \{\Phi\}$ ให้ $h = h + 1$ และกลับไปขั้นตอนที่ 3

แต่ถ้าเป็นอย่างอื่นให้จบการทำงาน

จากอัลกอริทึมที่ 1 ใช้ในการสร้างกฎ if-then ภายใต้หลักการคำนวณแกรนูลาร์ จะได้เซตของกฎ fuzzy if-then ของตารางสารสนเทศทั้งสาม แสดงดังตารางที่ 5.5 5.6 และ 5.7 ตามลำดับ

ตารางที่ 5.5 กฎ fuzzy if-then ของสารสนเทศของฐานข้อมูล Iris Plant

เงื่อนไข	กลุ่ม	cf
IF C1 =c1H THEN	3	1.00
IF C2 =c2M THEN	3	0.63
IF C3 =c3H THEN	3	1.00
IF C4 =c4H THEN	3	1.00
IF C2 =c2L THEN	2	0.67
IF C3 =c3M THEN	2	0.60
IF C4 =c4M THEN	2	0.60
IF C2 =c2H THEN	1	1.00
IF C3 =c3L THEN	1	1.00
IF C4 =c4L THEN	1	1.00

ตารางที่ 5.6 กฎ fuzzy if-then ของสารสนเทศของฐานข้อมูล KDD Cup 1999

เงื่อนไข	กลุ่ม	cf
IF C1 =c1H THEN	1	1.00
IF C1 =c1M THEN	1	1.00
IF C3 =c3H THEN	3	1.00
IF C4 =c4H THEN	3	1.00
IF C4 =c4M THEN	3	1.00
IF C7 =c7H THEN	3	0.75
IF C2 =c2M THEN	0	1.00
IF C3 =c3L THEN	0	0.46
IF C5 =c5L THEN	0	0.67
IF C6 =c6H THEN	0	0.64
IF C3 =c3M THEN	2	0.67
IF C6=c6M AND C7=c7M THEN	4	0.67

ตารางที่ 5.7 กฎ fuzzy if-then ของสารสนเทศของฐานข้อมูล Abalone

เงื่อนไข	กลุ่ม	cf
IF C1 =c1H THEN	10	0.12
IF C1 =c1M THEN	10	0.11
IF C3 =c3H THEN	10	0.10
IF C4 =c4H THEN	10	1.00
IF C4 =c4M THEN	10	0.12
IF C7 =c7H THEN	10	0.11
IF C7 =c7M THEN	10	0.11
IF C8 =c8L THEN	10	0.11
IF C1 =c1H THEN	11	0.11
IF C3 =c3H THEN	11	0.11
IF C5 =c5H THEN	11	0.15
IF C6 =c6H THEN	11	0.23
IF C7 =c7H THEN	11	0.20
IF C8 =c8H THEN	17	0.22
IF C8 =c8H THEN	18	0.22
IF C6 =c6H THEN	9	0.15
IF C5 =c5H THEN	13	0.12
IF C6 =c6H THEN	13	0.15
IF C7 =c7H THEN	13	0.20
IF C8 =c8H THEN	16	0.11
IF C2 =c2L THEN	3	0.15
IF C2 =c2L THEN	4	0.23
IF C3 =c3L THEN	4	0.15
IF C2 =c2L THEN	5	0.15
IF C3 =c3L THEN	5	0.25
IF C2 =c2L THEN	6	0.15
IF C3 =c3L THEN	6	0.15
IF C3 =c3L THEN	7	0.15
IF C4 =c4H THEN	8	1.00

ตารางที่ 5.7 กฎ fuzzy if-then ของสารสนเทศของฐานข้อมูล Abalone(ต่อ)

เงื่อนไข	กลุ่ม	cf
IF C8 =c8L THEN	8	0.11
IF C3 =c3H THEN	12	0.11
IF C5 =c5H THEN	12	0.15
IF C6 =c6H THEN	12	0.15
IF C7 =c7H THEN	12	0.40
IF C5 =c5H THEN	14	0.15
IF C6 =c6H THEN	14	0.15
IF C8 =c8H THEN	14	0.22
IF C8 =c8H THEN	20	0.11
IF C7 =c7H THEN	23	0.20
IF C8 =c8H THEN	27	0.11

5.3 กระบวนการปรับปรุง ANFIS

โครงสร้างเดิมของ ANFIS หากไม่มีการกำหนดกฎโดยผู้เชี่ยวชาญแล้ว ANFIS จะสร้างกฎขึ้นโดยอัตโนมัติ ซึ่งตารางที่ 5.8 แสดงจำนวนกฎและ Total Fitting Parameter ของ ANFIS แบบเดิม ตัวอย่างโครงสร้างของ ANFIS แสดงดังรูปที่ 5.3

ตารางที่ 5.8 แสดงจำนวนกฎและ Total Fitting Parameter ของ ANFIS แบบเดิม

ฐานข้อมูล	จำนวนอินพุต (n)	จำนวนกฎ (p^n)	Total Fitting Parameter
Iris Plant	4	81	117
KDD Cup 1999	7	2187	2250
Abalone	8	6561	6633

$$\text{Total Fitting Parameter} = (n \times p \times m) + p^n \quad (5.2)$$

โดยที่ n แทนจำนวนอินพุต

p แทนจำนวนการแบ่งฟังก์ชันความเป็นสมาชิก


ในขั้นตอนนี้จะนำกฎที่สร้างขึ้น โดยคำนวณแกรนูลาร์ซึ่งมีจำนวนกฎ Fuzzy if-then และ Total Fitting Parameter แสดงดังตารางที่ 5.9 จากนั้นนำกฎ fuzzy if-then มาสร้างเป็นกฎเริ่มต้นของ ANFIS ด้วยการปรับ Rule layer ซึ่งเมื่อแทนกฎที่ได้จากคำนวณแกรนูลาร์จึงได้โครงสร้างใหม่ของ ANFIS แสดงดังรูปที่ 5.4 รูปที่ 5.5 และรูปที่ 5.6 ตามลำดับ

ตารางที่ 5.9 แสดงจำนวนกฎและ Total Fitting Parameter ของ ANFIS แบบใหม่


ฐานข้อมูล	จำนวนอินพุต (n)	จำนวนกฎ	Total Fitting Parameter
Iris Plant	4	10	40
KDD Cup 1999	7	12	51
Abalone	8	40	85

$$\text{Total Fitting Parameter} = m \sum_{i=1}^n (p_i) + |\text{RuleSet}| \quad (5.3)$$


โดยที่ p แทนจำนวนการแบ่งฟังก์ชันความเป็นสมาชิก
 m แทนจำนวนพารามิเตอร์ต่อฟังก์ชันความเป็นสมาชิก
 n แทนจำนวนอินพุต




รูปที่ 5.3 แสดงโครงสร้างเดิมของ ANFIS



รูปที่ 5.4 แสดงโครงสร้างใหม่ของ ANFIS ตามสารสนเทศ Iris Plant



รูปที่ 5.5 แสดงโครงสร้างใหม่ของ ANFIS ตามสารสนเทศ KDD Cup 1999



รูปที่ 5.6 แสดงโครงสร้างใหม่ของ ANFIS ตามสารสนเทศ Abalone

5.4 การแก้ปัญหาการจำแนกประเภทข้อมูลด้วย ANFIS โครงสร้างใหม่

การทำงานของ ANFIS ซึ่งประกอบด้วยการทำงานของฝึกลูกข่ายและทดสอบระบบ ซึ่งในการฝึกลูกข่ายนั้นประกอบด้วยส่วนประกอบ 2 ส่วนคือส่วนฟอร์เวิร์ดพาสและแบ็คเวิร์ดพาส โดยส่วนฟอร์เวิร์ดพาสทำการนำเข้าข้อมูลอินพุตแล้วคำนวณเอาท์พุทของ ANFIS แต่ละชั้นแล้วทำการคำนวณเอาท์พุทรวมของระบบซึ่งคำนวณตามแบบการอินเฟอร์เรนซ์ของ Sugeno และในส่วนของ Rule Consequent นั้นฟังก์ชันความเป็นสมาชิกของเอาท์พุท (Output MF) เป็น Zero-Order ซึ่งให้ค่าเอาท์พุทเป็นค่าตัวเลข

5.4.1 การฝึกลูกข่าย

รูปที่ 5.4 แสดงโครงสร้างของ ANFIS ของการจำแนกข้อมูลของ Iris Plant ซึ่งมี 4 อินพุต และมีจำนวนกฎที่กำหนดขึ้นจากหลักของแกรนนูลาร์คอมพิวติงทั้งหมด 10 กฎ โดยจากกฎการจำแนกประเภทข้อมูลซึ่งมีกลุ่มข้อมูลทั้งหมด 3 กลุ่ม จากนั้นทำการกำหนดค่าเริ่มต้นของ Rule Consequent Parameter โดยทำการกำหนดค่าความต่างระหว่าง Parameter แต่ละตัวโดยสมการที่ 5.4 ซึ่งกฎการจำแนกประเภทข้อมูลแสดงดังตารางที่ 5.10

$$(high - low) / (c - 1) \quad (5.4)$$

โดยที่ *high* แทนค่าสูงสุดของ Consequent parameter

low แทนค่าต่ำสุดของ Consequent parameter และ *c* แทนจำนวนกฎ

ตารางที่ 5.10 แสดงกฎ Fuzzy If-Then สำหรับการจำแนกประเภทข้อมูล Iris Plant

ลำดับที่	Rule Antecedent	Rule Consequent
1	If (input2 is High)	Output is MF1(1)
2	If (input3 is Low)	Output is MF2(1.22)
3	If (input4 is Low)	Output is MF3(1.44)
4	If (input2 is Low)	Output is MF4(1.66)
5	If (input3 is Medium)	Output is MF5(1.88)
6	If (input4 is Medium)	Output is MF6(2.11)
7	If (input1 is High)	Output is MF7(2.33)
8	If (input2 is Medium)	Output is MF8(2.55)
9	If (input3 is High)	Output is MF9(2.77)
10	If (input4 is High)	Output is MF10(3)

ตารางที่ 5.11 แสดงตัวอย่างข้อมูล Iris Plant

ลำดับที่	Sepal Length	Sepal Width	Petal Length	Petal Width	Class
1	6.70	3.10	4.40	1.40	2
2	5.40	3.90	1.70	0.40	1
3	6.50	3.20	5.10	2.00	3

ขั้นตอนการฝึกสอนของ ANFIS ส่วนของการฝึกสอนระบบประกอบด้วยขั้นตอนต่างๆ ดังนี้

1. การคำนวณในส่วนฟอร์เวิร์ดพาส

การคำนวณในส่วนฟอร์เวิร์ดพาสเมื่อนำเข้าข้อมูลอินพุตแสดงดังตารางที่ 5.11 ซึ่งประกอบด้วยจำนวน 4 อินพุตคือ ความยาวใบเลี้ยง (Sepal Length) ความกว้างใบเลี้ยง (Sepal Width) ความยาวกลีบดอก (Petal Length) และความกว้างกลีบดอก (Petal Width) จากนั้นคำนวณเอาที่พู่ของ Rule Consequent โดยใช้ Least Square Estimator มีขั้นตอนการทำงานดังนี้

ขั้นที่ 1 คำนวณค่า Firing Strength ของกฎ (w_n) โดยจากกฎ Fuzzy If-Then ในตารางที่ 5.10 ทำการคำนวณหา Firing Strength ของกฎแต่ละกฎ ซึ่ง Attribute ของส่วนเงื่อนไขใช้เพียง Attribute เดียว โดยนำเข้าข้อมูลจากตารางที่ 5.11 จากนั้นคำนวณค่า Firing Strength ของกฎได้จากสมการที่ 5.5

$$w_n = \frac{1}{1 + \left(\frac{x - c_n}{a_n}\right)^{2b_n}} \quad (5.5)$$

โดยที่ n แทนลำดับที่ของกฎ

x แทนข้อมูลอินพุต

a, b และ c แทนพารามิเตอร์ของฟังก์ชันความเป็นสมาชิกของอินพุตของแต่ละกฎ ซึ่งเป็นฟังก์ชันความเป็นสมาชิกชนิด Bell ซึ่งค่าพารามิเตอร์แสดงดังตารางที่ 5.12

ตารางที่ 5.12 แสดงพารามิเตอร์ของฟังก์ชันความเป็นสมาชิกของอินพุต

	Low	Medium	High
Input1	-	-	[0.9 2.5 6.1]
Input2	[0.55 2 2.2]	[0.55 2 3.3]	[0.55 2 4.4]
Input3	[1.475 2 1]	[1.475 2 3.95]	[1.475 2 6.9]
Input4	[0.6 2 0.1]	[0.6 2 1.3]	[0.6 2 2.5]

เมื่อแทนค่าข้อมูลแถวที่ 1 ของกฎที่ 1 ลงในสมการที่ 5.5 ผลลัพธ์ที่ได้แสดงดังนี้

$$w_1 = \frac{1}{1 + \left(\frac{3.10 - 4.4}{0.55}\right)^4} = 0.031$$

จากนั้นแทนค่าข้อมูลอินพุตแถวที่ 1 ตามกฎที่ 2 ถึง 10 และเมื่อแทนค่าข้อมูลแถวที่ 2 - 3 ได้ผลลัพธ์ดังตารางที่ 5.13

ตารางที่ 5.13 แสดงค่าที่ได้จากการคำนวณ Firing Strength ของกฎ Fuzzy If-Then

w_1	w_2	w_3	w_4	w_5	w_6	w_7	w_8	w_9	w_{10}
0.0310	0.0342	0.0435	0.1214	0.9913	0.9990	0.8828	0.9828	0.1078	0.0833
0.0086	0.0039	0.0055	0.7814	0.0588	0.1147	0.0533	0.2759	1	0.9878
0.061	0.195	0.197	0.024	0.022	0.160	0.142	0.194	0.001	0.0009

ขั้นที่ 2 เมื่อได้ Firing Strength ของกฎแล้วจากนั้นคำนวณหาค่า Normalize Firing Strength \bar{w}_n ตามสมการที่ 5.6 ผลลัพธ์ที่ได้แสดงดังตารางที่ 5.14

$$\bar{w}_n = \frac{w_n}{\sum_{i=1}^n w_n} \quad (5.6)$$

ตารางที่ 5.14 แสดงค่า Normalize Firing Strength ของกฎ

\bar{w}_1	\bar{w}_2	\bar{w}_3	\bar{w}_4	\bar{w}_5	\bar{w}_6	\bar{w}_7	\bar{w}_8	\bar{w}_9	\bar{w}_{10}
0.0072	0.0079	0.0101	0.0286	0.2317	0.2335	0.2065	0.2297	0.0252	0.019
0.0026	0.0011	0.0016	0.2375	0.0178	0.0348	0.0162	0.0838	0.3039	0.3002
0.061	0.195	0.197	0.024	0.022	0.160	0.142	0.194	0.001	0.0009

จากเอาต์พุตที่ต้องการของ ANFIS (y_d) แสดงดังสมการที่ 5.5 ให้ k แทน Consequent Parameter และ A แทนเมตริกแสดงดังสมการ 5.7

$$y_d = Ak \quad (5.7)$$

$$A = [w_n x_m] \quad (5.8)$$

โดยที่จากโครงสร้างของ ANFIS

$n = 10$ แทนจำนวนกฎ

$m = 4$ แทนจำนวนอินพุต

$$x_m \quad \text{แทนอินพุตเวกเตอร์}$$

$$y_d = \begin{bmatrix} 2 \\ 1 \\ 3 \end{bmatrix} \quad \text{แทนเอาต์พุตที่ต้องการของ ANFIS}$$

จากนั้นแทนค่าเมตริก A ตามสมการที่ 5.8 ซึ่งอยู่ในรูปของเมตริกขนาด 3 แถว x (10 x 4) หลักซึ่งแสดงในรูปเมตริก

$$\begin{bmatrix} \overline{w_1 x_1(p1)} & \dots & \overline{w_1 x_m(p1)} & \dots & \overline{w_n x_1(p1)} & \dots & \overline{w_n x_m(p1)} \\ \overline{w_1 x_1(p2)} & \dots & \overline{w_1 x_m(p2)} & \dots & \overline{w_n x_1(p2)} & \dots & \overline{w_n x_m(p2)} \\ \overline{w_1 x_1(p3)} & \dots & \overline{w_1 x_m(p3)} & \dots & \overline{w_n x_1(p3)} & \dots & \overline{w_n x_m(p3)} \end{bmatrix}$$

โดยที่ $p1, p2$ และ $p3$ แทนแถวของข้อมูลอินพุต

ขั้นที่ 3 กำหนด Consequent Parameter (k) โดย Least Square Estimator ดังสมการที่ 5.9

$$k = (A^T A)^{-1} A^T y_d \quad (5.9)$$

โดยที่ A^T เป็น transpose ของ A และ $(A^T A)^{-1} A^T$ เป็น Pseudo-inverse ของ A

เมื่อแทนค่าของข้อมูลของเมตริก A และ y_d จากนั้นคำนวณเอาต์พุตของ Rule Consequent parameter (k) ได้ผลลัพธ์ดังตารางที่ 5.15

ตารางที่ 5.15 แสดงเอาต์พุตของ Rule Consequent parameter

Rule Antecedent	Output MF	Consequent Parameter
If (input2 is High)	Output is MF1	-0.02088
If (input3 is Low)	Output is MF2	-0.3611
If (input4 is Low)	Output is MF3	-0.4396
If (input2 is Low)	Output is MF4	0.1863
If (input3 is Medium)	Output is MF5	1.873
If (input4 is Medium)	Output is MF6	-1.126
If (input1 is High)	Output is MF7	3.921
If (input2 is Medium)	Output is MF8	3.825
If (input3 is High)	Output is MF9	1.937
If (input4 is High)	Output is MF10	4.821

2. การทำงานในส่วนแบ็คเวิร์ดพาส

การทำงานในส่วนแบ็คเวิร์ดพาสใช้อัลกอริทึมแบบแพร่ย้อนกลับ (Back-Propagation) ซึ่งค่าผิดพลาดจากการฝึกสอนจะแพร่ย้อนกลับ และ Antecedent Parameter จะถูกปรับปรุง ดังสมการที่ 5.10

$$\Delta a = \alpha(y_d - y)k_i \bar{w}_i(1 - \bar{w}_i) \times \frac{1}{\mu_{A_i}} \times \frac{\partial \mu_{A_i}}{\partial a} \quad (5.10)$$

โดยที่ a แทนพารามิเตอร์ของ Bell Membership Function

α แทนอัตราการเรียนรู้

k_i แทนเอาต์พุตของ Rule Consequent

$y_d = \begin{bmatrix} 2 \\ 1 \\ 3 \end{bmatrix}$ แทนเอาต์พุตที่ต้องการของ ANFIS

y แทนเอาต์พุตที่ได้จากการคำนวณ

$\frac{\partial \mu_{A_i}}{\partial a}$ กำหนดได้ดังสมการ 5.11


$$\frac{\partial \mu_{A_i}}{\partial a} = \mu_{A_i}^2 \times \frac{2b}{c} \times \left(\frac{x1 - a}{c} \right)^{2b-1} \quad (5.11)$$

โดยที่ μ_{A_i} แทน Membership Function ของอินพุต

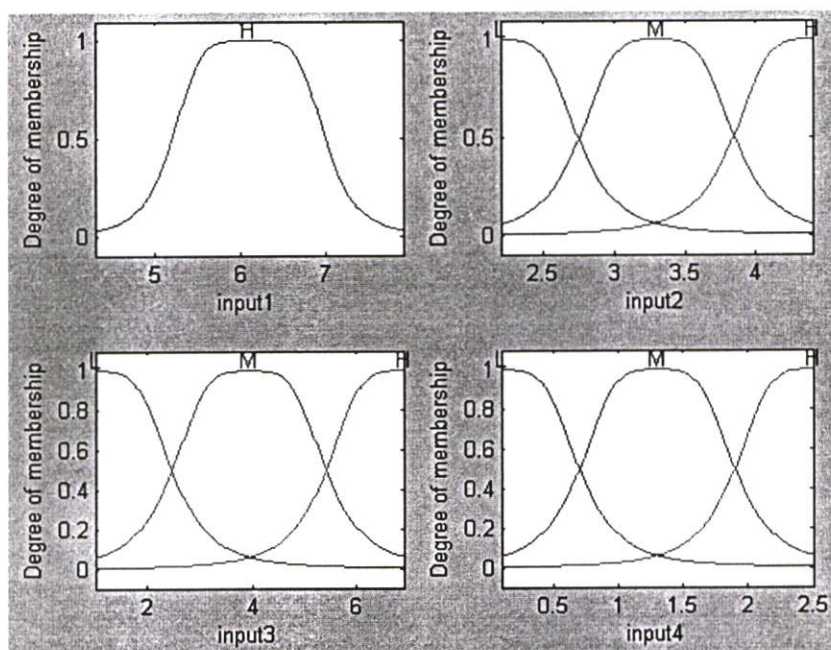
b แทน Slope ของ Bell Membership Function

c แทน Center ของ Bell Membership Function

เอาต์พุตที่ได้ของการปรับ Antecedent Parameter ซึ่งทำการปรับฟังก์ชันความเป็นสมาชิกของอินพุตซึ่งผลการปรับ Parameter แสดงดังตารางที่ 5.17 รูปที่ 5.7 และรูปที่ 5.8 แสดงฟังก์ชันความเป็นสมาชิกของอินพุตก่อนและหลังการฝึกสอนตามลำดับ



รูปที่ 5.7 แสดงฟังก์ชันความเป็นสมาชิกก่อนการฟัฟกสอน



รูปที่ 5.8 แสดงฟังก์ชันความเป็นสมาชิกหลังการฟัฟกสอน

จากรูปที่ 5.7 และ รูปที่ 5.8 แสดงฟังก์ชันความเป็นสมาชิกก่อนและหลังการฟัฟกสอน ซึ่งหลังจากฟัฟกสอนแล้วค่า Parameter ของฟังก์ชันความเป็นสมาชิกของอินพุตแต่ละตัวมีการปรับค่าเพียงเล็กน้อย จึงทำให้รูปแสดงฟังก์ชันความเป็นสมาชิกของอินพุตก่อนและหลังฟัฟกสอนมีความแตกต่างกันไม่มาก ตารางที่ 5.16 และตารางที่ 5.17 แสดง Parameter ของฟังก์ชันความเป็นสมาชิกของอินพุตก่อนและหลังฟัฟกสอน

ตารางที่ 5.16 แสดง Parameter ของฟังก์ชันความเป็นสมาชิกของอินพุตก่อนการฝึกสอน

	Low	Medium	High
Input1	[0.9 2.5 6.1]		
Input2	[0.55 2 2.2]	[0.55 2 3.3]	[0.55 2 4.4]
Input3	[1.475 2 1]	[1.475 2 3.95]	[1.475 2 6.9]
Input4	[0.6 2 0.1]	[0.6 2 1.3]	[0.6 2 2.5]

ตารางที่ 5.17 แสดง Parameter ของฟังก์ชันความเป็นสมาชิกของอินพุตหลังการฝึกสอน

	Low	Medium	High
Input1	[0.8993 2.5 6.1]		
Input2	[0.549 2 2.2]	[0.5496 2 3.3]	[0.5494 2 4.4]
Input3	[1.475 2 1]	[1.474 2 3.949]	[1.474 2 6.901]
Input4	[0.6001 2 0.1001]	[0.5933 2 1.294]	[0.6023 2 2.497]

5.4.2 การทดสอบระบบ

เมื่อทำการฝึกสอนระบบซึ่งระบบมีการปรับ Rule Consequent และทำการปรับ Antecedent Parameter แล้วระบบพร้อมที่จะทดสอบกับข้อมูล ตารางที่ 5.18 แสดงตัวอย่างของข้อมูลที่นำมาทำการทดสอบ จากนั้นทำการคำนวณเอาท์พุทของ ANFIS ตามสมการที่ 5.12

$$Overall\ output = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (5.12)$$

ตารางที่ 5.18 แสดงตัวอย่างของข้อมูลที่นำมาทำการทดสอบ

ลำดับที่	Sepal Length	Sepal Width	Petal Length	Petal Width
1	4.60	3.10	1.50	0.20
2	7.70	2.60	6.90	2.30
3	6.70	3.10	4.40	1.40

จากตัวอย่างข้อมูลอินพุตตามตารางที่ 5.18 ทำการคำนวณเอาท์พุทของ ANFIS ตามสมการที่ 5.12 เมื่อป้อนข้อมูลอินพุตแถวที่ 1 ได้ผลการทดสอบแสดงดังตารางที่ 5.19

ตารางที่ 5.19 แสดงตัวอย่างการคำนวณเอาต์พุตของ ANFIS

Rule Antecedent	Consequent Parameter (f_i)	Rule Firing Strength (w_i)	$w_i f_i$
If (input2 is High)	-0.02088	0.0327	-0.0006
If (input3 is Low)	-0.3611	0.9871	-0.356
If (input4 is Low)	-0.4396	0.9992	-0.4392
If (input2 is Low)	0.1863	0.1198	0.0223
If (input3 is Medium)	1.873	0.1161	0.2174
If (input4 is Medium)	-1.126	0.0813	-0.0915
If (input1 is High)	3.921	0.0697	0.2732
If (input2 is Medium)	3.825	0.9871	3.7756
If (input3 is High)	1.937	0.0055	0.0106
If (input4 is High)	4.821	0.0047	0.0226
ผลรวม		3.4032	3.4341
<i>Overall Output = 1.089</i>			

เมื่อทดสอบกับข้อมูลจากตารางที่ 5.18 ได้ผลการทดสอบแสดงดังตารางที่ 5.20 และได้
อัตราการทำนายประเภทข้อมูลที่ถูกต้องเฉลี่ย 99.7 %

ตารางที่ 5.20 แสดงเอาต์พุตของการทดสอบจำแนกประเภทข้อมูล

Sepal Length	Sepal Width	Petal Length	Petal Width	Output	Class
4.60	3.10	1.50	0.20	1.089	1
7.70	2.60	6.90	2.30	3.0001	3
6.70	3.10	4.40	1.40	2.4671	2

5.5 สรุป

ในบทนี้ผู้วิจัยได้นำเสนอการปรับปรุงโครงสร้างของ ANFIS ด้วยการสร้างกฎ fuzzy if-then ให้กับ Rule Antecedent Layer ซึ่งในปัญหาการจำแนกประเภทข้อมูล ในแต่ละปัญหาสามารถสร้างโมเดลของ ANFIS ให้ลดจำนวนกฎ และจำนวนพารามิเตอร์ลดลงเมื่อเทียบกับโมเดลของ ANFIS ตามโครงสร้างการสร้างกฎ fuzzy if-then แบบเดิม ซึ่งในบทถัดไปจะทำการทดสอบประสิทธิภาพของ ANFIS ทั้งสองโมเดล โดยทำการเปรียบเทียบอัตราความถูกต้องของการจำแนกประเภทข้อมูลและเปรียบเทียบเวลาที่ใช้ในการฝึกสอน

บทที่ 6

ผลการทดลอง

ในบทนี้จะกล่าวถึงการนำโมเดลจากบทที่ 5 มาทดลองเพื่อทดสอบประสิทธิภาพของโมเดล ANFIS แบบเดิม เปรียบเทียบกับโมเดล ANFIS ที่พัฒนาขึ้นใหม่ ด้วยหลักการคำนวณเกรนนูลาร์ ในปัญหาการจำแนกประเภทข้อมูล โดยการทดลองประกอบไปด้วย 2 การทดลอง การทดลองที่ 1 เป็นการทดสอบในปัญหาการจำแนกประเภทข้อมูล โดยใช้โมเดล ANFIS แบบเดิม การทดลองที่ 2 เป็นการทดสอบกับการจำแนกประเภทโดยใช้โมเดล ANFIS ที่พัฒนาขึ้นใหม่ โดยข้อมูลที่ใช้ทดสอบประกอบด้วยข้อมูลจากฐานข้อมูล Iris Plant ฐานข้อมูล KDD Cup 1999 และฐานข้อมูล Abalone ซึ่งในการทดลอง ทำการทดสอบเวลาที่ใช้ในการฝึกระบบ และอัตราการจำแนกประเภท

6.1 การทดลองที่ 1 การทดลองการจำแนกประเภทข้อมูลโดยใช้โมเดล ANFIS แบบเดิม

6.1.1 จุดประสงค์การทดลอง

ในการทดลองนี้ผู้วิจัยมีวัตถุประสงค์ต้องการทดสอบการประยุกต์ใช้ ANFIS แบบเดิมในการจำแนกประเภทข้อมูลกับฐานข้อมูลของ Iris Plant ฐานข้อมูล KDD Cup 1999 และฐานข้อมูล Abalone

6.1.2 ขั้นตอนการทดลอง

ผู้วิจัยได้กำหนดสภาวะในการทดลอง 6.1 และกำหนดข้อมูลที่ใช้เป็นข้อมูลสำหรับฝึกระบบและข้อมูลทดสอบ ด้วยอัตราส่วน 20/80 60/40 50/50 60/40 และ 80/20 ตามลำดับสภาพแวดล้อมของการทดลองแสดงดังตารางที่ 6.1 จำนวนข้อมูลแสดงดังตารางที่ 6.2

ตารางที่ 6.1 สภาพแวดล้อมของการทดลองด้วยโมเดล ANFIS แบบเดิม

ฐานข้อมูล	จำนวนอินพุท	จำนวนกฎ	พารามิเตอร์
Iris Plant	4	81	117
KDD Cup 1999	7	2187	2250
Abalone	8	6561	6633

ตารางที่ 6.2 แสดงจำนวนข้อมูลสำหรับฝึกระบบและข้อมูลทดสอบ

อัตราส่วนข้อมูล ฝึกสอน / ทดสอบ	Iris Plant (เรคคอร์ด)	KDD Cup 1999 (เรคคอร์ด)	Abalone (เรคคอร์ด)
20 / 80	30 / 120	11,914 / 47,654	835 / 3,342
40 / 60	60 / 90	23,828 / 35,740	1,670 / 2,507
50 / 50	75 / 75	29,784 / 29,784	2,087 / 2,088
60 / 40	90 / 60	35,740 / 23,828	2,507 / 1,670
80 / 20	120 / 30	47,654 / 11,914	3,342 / 835

จากการทดลองด้วยข้อมูลของฐานข้อมูลทั้งสาม ซึ่งทดลองด้วยอัตราส่วนของข้อมูลที่ใช้ฝึกสอนและทดสอบ ดังตารางที่ 6.2 ได้ผลการทดลองของการแบ่งกลุ่มข้อมูลของ ข้อมูลทั้งสาม แสดงดังตารางที่ 6.3 6.4 และ 6.5 ตามลำดับ

ตารางที่ 6.3 แสดงผลการทดลองด้วยฐานข้อมูล Iris Plant

อัตราส่วนข้อมูล ฝึกสอน / ทดสอบ	RMSE	อัตราการทำนายประเภท (%)	เวลา(วินาที)
20 / 80	0.005	99.84	67
40 / 60	0.022	99.87	75
50 / 50	0.023	99.89	78
60 / 40	0.012	99.87	84
80 / 20	0.036	99.95	90
เฉลี่ย	0.0196	99.884	78.8

ตารางที่ 6.4 แสดงผลการทดลองด้วยฐานข้อมูล KDD Cup 1999

อัตราส่วนข้อมูล ฝึกสอน / ทดสอบ	RMSE	อัตราการทำนายประเภท (%)	เวลา(วินาที)
20 / 80	0.033	99.025	3,500
40 / 60	0.033	98.34	7,000
50 / 50	0.086	98.29	8,750
60 / 40	0.10	99.08	10,500
80 / 20	0.093	98.63	14,000
เฉลี่ย	0.069	98.673	8,750

ตารางที่ 6.5 แสดงผลการทดลองด้วยข้อมูล Abalone

อัตราส่วนข้อมูล ฝึกสอน / ทดสอบ	RMSE	อัตราการทำนายประเภท(%)	เวลา(วินาที)
20 / 80	2.14	95.64	1200
40 / 60	2.04	97.43	2400
50 / 50	2.01	97.69	3010
60 / 40	1.86	97.61	3600
80 / 20	1.75	96.94	4800
เฉลี่ย	1.96	97.062	3002

ในการทดลองที่ 1 นี้ผู้วิจัยนำเสนอการทดลองในปัญหาการทำนายประเภทข้อมูล ของข้อมูล Iris Plant ข้อมูลจาก KDD Cup 1999 และข้อมูล Abalone ซึ่งทำการทดลองด้วยโครงสร้างเดิมของ ANFIS ในสัดส่วนข้อมูลฝึกสอนและข้อมูลทดสอบ หลายๆ สัดส่วน ผลการทดลองในข้อมูล Iris Plant ได้อัตราการทำนายประเภทข้อมูลดีที่สุดในสัดส่วน 80/20 และให้อัตราการทำนายประเภทเฉลี่ย 99.88 % ในข้อมูล KDD Cup 1999 ได้อัตราการทำนายประเภทข้อมูลดีที่สุดในสัดส่วน 60/40 และให้อัตราการทำนายประเภทข้อมูลเฉลี่ย 98.67 % และในข้อมูล Abalone ได้อัตราการทำนายประเภทข้อมูลดีที่สุดในสัดส่วน 50/50 และให้อัตราการทำนายประเภทข้อมูลเฉลี่ย 97.06 %

ส่วนในการทดลองที่ 2 จะเป็นการทดลองที่ผู้วิจัยทำการทดลองเพื่อนำเสนอแนวคิดในการปรับปรุงโครงสร้างของ ANFIS ขึ้นใหม่ ด้วยการสร้างกฎ fuzzy if-then ให้กับชั้น Rule antecedent layer โดยคาดหวังว่าจะช่วยลดเวลาในการฝึกสอนระบบ และยังให้อัตราการทำนายประเภทข้อมูลคงเดิม หรือดีขึ้น ซึ่งรายละเอียดการทดลองแสดงในหัวข้อถัดไป

6.2 การทดลองที่ 2 ทดลองการทำนายประเภทข้อมูลโดยใช้โมเดล ANFIS ปรับปรุงใหม่

6.2.1 จุดประสงค์ของการทดลอง

เพื่อทดสอบประสิทธิภาพ ในส่วนของอัตราการทำนายประเภทข้อมูลและเวลาในการฝึกสอนของ ANFIS ที่ปรับปรุงขึ้นใหม่ โดยคาดหวังช่วยลดเวลาในการฝึกสอนระบบและยังให้อัตราการทำนายประเภทข้อมูลคงเดิม หรือดีขึ้น โดยมีการกำหนดกฎ fuzzy if-then ให้กับชั้น Rule antecedent layer

6.2.2 ขั้นตอนการทดลอง

ผู้วิจัยได้ปรับปรุงโครงสร้างของ ANFIS ขึ้นใหม่ ด้วยการสร้าง กฎ fuzzy if-then ในชั้น Rule antecedent โดยการใช้หลักการของการคำนวณแกรนูลาร์มาใช้ในการสร้างกฎ ซึ่งมีสภาพแวดล้อมของโครงสร้าง ANFIS แสดงดังตารางที่ 6.6 แล้วทำการฝึกทดลองฝึกสอนและทดสอบกับข้อมูลทั้งสาม ผลการทดลองแสดงดังตารางที่ 6.7 6.8 และตารางที่ 6.9 ตามลำดับ

ตารางที่ 6.6 สภาพแวดล้อมของการทดลองด้วยโมเดล ANFIS ที่ปรับปรุงใหม่

ฐานข้อมูล	จำนวนอินพุต	จำนวนกฎ	พารามิเตอร์
Iris Plant	4	10	40
KDD Cup 1999	7	12	51
Abalone	8	40	85

ตารางที่ 6.7 แสดงผลการทดลองด้วยฐานข้อมูล Iris Plant

อัตราส่วนข้อมูล	RMSE	อัตราการทำนายประเภท (%)	เวลา(วินาที)
20/80	0.113	99.86	15
40/60	0.137	99.86	16
50/50	0.134	99.85	17
60/40	0.133	99.86	18
80/20	0.141	99.86	18.5
เฉลี่ย	0.131	99.858	16.9

ตารางที่ 6.8 แสดงผลการทดลองด้วยฐานข้อมูล KDD Cup 1999

อัตราส่วนข้อมูล	RMSE	อัตราการทำนายประเภท (%)	เวลา(วินาที)
20/80	0.12	99.74	200
40/60	0.15	99.75	400
50/50	0.19	99.78	540
60/40	0.20	99.70	600
80/20	0.20	99.78	810
เฉลี่ย	0.172	99.75	510

ตารางที่ 6.9 แสดงผลการทดลองด้วยฐานข้อมูล Abalone

อัตราส่วนข้อมูล	RMSE	อัตราการจำแนกประเภท(%)	เวลา(วินาที)
20/80	2.51	96.17	31
40/60	2.28	97.88	62
50/50	2.18	97.89	76
60/40	2.02	97.64	84
80/20	1.89	96.93	104
เฉลี่ย	2.176	97.30	71.4

จากผลของการทดลองด้วยโครงสร้าง ANFIS ที่ปรับปรุงใหม่ ในปัญหาการจำแนกประเภทข้อมูลทั้งสาม ยังคงให้อัตราการจำแนกประเภทข้อมูล ที่ไม่ต่างกับ การทดลองที่ 1 โดย ในข้อมูล Iris Plant ได้อัตราการจำแนกประเภทเฉลี่ย 99.858 % ข้อมูล KDD Cup 1999 ได้อัตราการจำแนกประเภทเฉลี่ย 99.75% และข้อมูล Abalone ได้อัตราความถูกต้องของการจำแนกประเภทข้อมูลเฉลี่ย 97.3% ซึ่งการทดลองกับข้อมูลทั้งสามด้วยโครงสร้างใหม่ของ ANFIS เวลาที่ใช้ในการฝึกสอนลดลงอย่างมาก

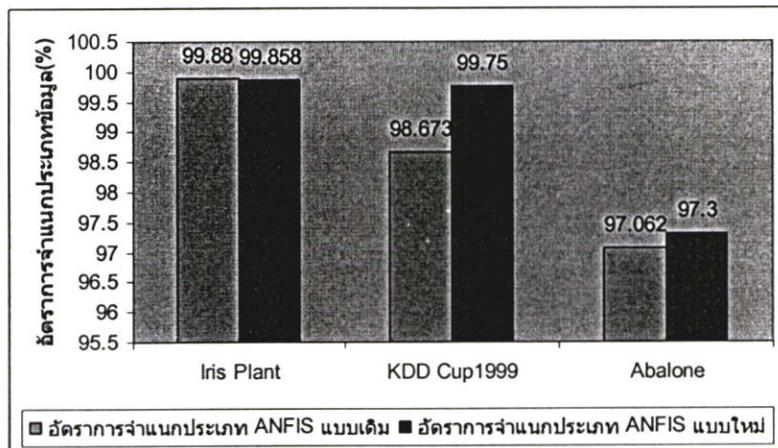
6.3 สรุปและวิเคราะห์ผลการทดลอง

จากการทดลองผลการทดลองที่ 1 และการทดลองที่ 2 ปรากฏว่า ในการปรับปรุง ANFIS โดยการใช้หลักการคำนวณเกรนูลาร์ ทำให้จำนวนกฎ fuzzy if-then และจำนวนพารามิเตอร์ลดลง และเมื่อพิจารณารูปที่ 6.1 ก็แสดงให้เห็นถึงประสิทธิภาพของ การจำแนกประเภทข้อมูลของ ANFIS ที่ปรับปรุงใหม่ ยังคงให้เปอร์เซ็นต์ของการจำแนกประเภทข้อมูลที่ลดลงจาก ANFIS แบบเดิมไม่มากซึ่งลดลงเพียง 0.03 % และในการจำแนกประเภทข้อมูลของ KDD Cup 1999 ให้อัตราการจำแนกประเภทที่ดีขึ้น และในการพิจารณาเวลาที่ใช้ในการฝึกสอน ANFIS ทำให้เวลาที่ใช้ลดลงอย่างมากซึ่งแสดงกราฟเปรียบเทียบเวลาฝึกสอนของ ANFIS แบบเดิมและ ANFIS แบบใหม่ ของข้อมูลทั้ง 3 ข้อมูล แสดงดังรูปที่ 6.2 รูปที่ 6.3 และรูปที่ 6.4 และตารางที่ 6.10 แสดงสัดส่วนเวลาฝึกสอนระบบที่ลดลงจากการฝึกสอนด้วย ANFIS แบบเดิม


สำหรับการจำแนกประเภทข้อมูลของ KDD Cup 1999 ซึ่งเมื่อเปรียบเทียบระหว่าง ANFIS แบบเดิมและ ANFIS ที่กำหนดกฎขึ้นมาใหม่นั้นให้อัตราการจำแนกประเภทข้อมูลที่เพิ่มขึ้น แต่ในขณะที่การเปรียบเทียบกับการจำแนกประเภทข้อมูลของ Iris Plant นั้นให้อัตราการจำแนกประเภทข้อมูลที่ลดลงเนื่องจาก ข้อกำหนดในการฝึกสอน ANFIS เพื่อทำการปรับค่าพารามิเตอร์นั้น จำนวนข้อมูลที่น่ามาฝึกสอนควรจะมากกว่าจำนวนพิตติงพารามิเตอร์(Fitting parameter) ทั้งหมด

หลาย ๆ เท่า ซึ่งส่วนต่างของข้อมูลฝึกสอนและพิตติงพารามิเตอร์ของ Iris Plant คิดเป็น 3.75 เท่า แต่ในขณะที่ส่วนต่างของข้อมูลฝึกสอนและพิตติงพารามิเตอร์ของ KDD Cup 1999 เป็น 1168 เท่า ซึ่งทำให้ข้อมูลที่ใช้ฝึกสอนนั้นครอบคลุมความถูกต้องของการจำแนกข้อมูลได้มากกว่า ทำให้ผลของการทดสอบข้อมูลให้อัตราการจำแนกประเภทข้อมูลสูงกว่า


จากการพิจารณาอัตราการจำแนกประเภทข้อมูลและจำนวนข้อมูลฝึกสอนนั้น ในการทดสอบระบบนั้นจำนวนข้อมูลฝึกสอนมีผลต่ออัตราการจำแนกประเภทข้อมูล โดยข้อกำหนดการฝึกสอนจำนวนข้อมูลฝึกสอนต้องมากกว่าจำนวนพิตติงพารามิเตอร์ทั้งหมด และจากการทดลองปรับเปลี่ยนจำนวนข้อมูลที่นำมาฝึกสอนแล้วทำการทดสอบระบบของการจำแนกประเภทข้อมูลของ KDD Cup 1999 ซึ่งเมื่อลดจำนวนข้อมูลที่นำมาใช้ฝึกสอนลงนั้น ทำให้อัตราการจำแนกประเภทข้อมูลลดลง ซึ่งแสดงผลการเปรียบเทียบดังตารางที่ 6.11



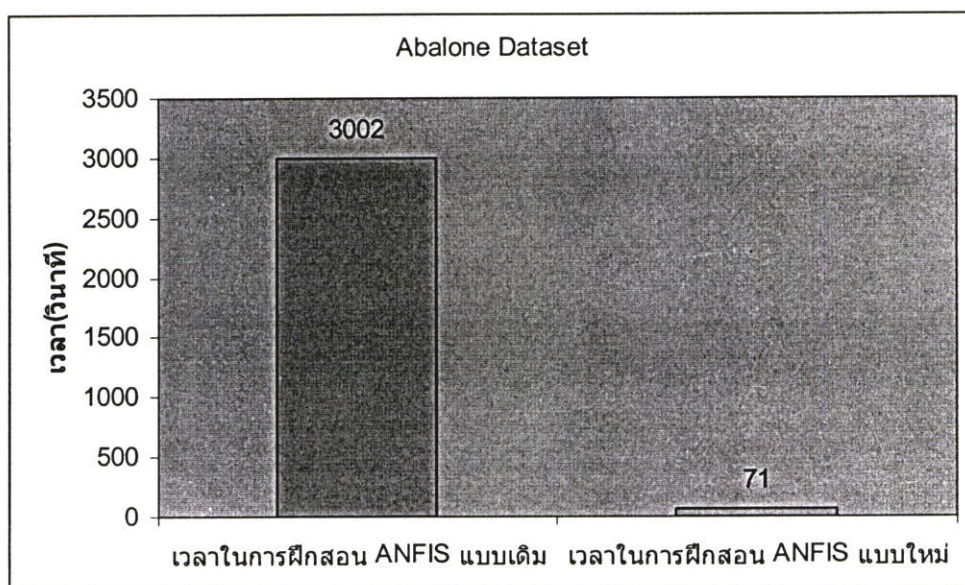
รูปที่ 6.1 กราฟเปรียบเทียบอัตราการจำแนกประเภทของ ANFIS แบบเดิมและแบบใหม่



รูปที่ 6.2 กราฟเปรียบเทียบเวลาฝึกสอนของ ANFIS แบบเดิมและแบบใหม่ของการจำแนกประเภทข้อมูลของ Iris Plant Dataset



รูปที่ 6.3 กราฟเปรียบเทียบเวลาฝึกสอนของ ANFIS แบบเดิมและแบบใหม่ของการจำแนกประเภทข้อมูลของ KDD Cup 1999



รูปที่ 6.4 กราฟเปรียบเทียบเวลาฝึกสอนของ ANFIS แบบเดิมและแบบใหม่ของการจำแนกประเภทข้อมูลของ Abalone Dataset

ตารางที่ 6.10 อัตราส่วนของเวลาที่ลดลงในการฝึกสอนระบบของ ANFIS แบบเดิมและแบบใหม่

ข้อมูล	อัตราส่วนของเวลาที่ลดลง (%)
Iris Plant	78.2 %
KDD Cup 1999	93.8 %
Abalone	97.4 %

ตารางที่ 6.11 แสดงจำนวนข้อมูลฝึกสอนที่มีผลต่ออัตราการจำแนกประเภทข้อมูลที่ถูกต้อง

จำนวนข้อมูล	อัตราการจำแนกประเภท
255	96.97
510	98.33
2550	99.716
5100	99.717
25500	99.81

บทที่ 7

สรุปผลการวิจัย และข้อเสนอแนะ

7.1 สรุปผลการวิจัย

ในงานวิจัยนี้ผู้วิจัยได้นำเสนอแนวคิดแก้ปัญหาในงานด้านการจำแนกประเภทข้อมูล โดยการนำเทคโนโลยีอัจฉริยะแบบผสมผสาน มาใช้เป็นเครื่องมือหลักในการจำแนกประเภทข้อมูล ซึ่งงานวิจัยนี้นำเทคโนโลยีการผสมผสานการทำงานของ อะติฟิเชียลนิวรอลเน็ตเวิร์ค (Artificial Neural Network) และ ฟัซซี่ลอจิก (Fuzzy Logic) ภายใต้อัฒติฟิซึออะแดพทีฟนิวโรฟัซซี่อินเฟอร์เรนซ์ซิสเต็ม (Adaptive Neuro-Fuzzy Inference System :ANFIS) ซึ่งมีจุดเด่นการทำงานที่ให้อัตราการจำแนกประเภทข้อมูลสูง

ในการทดลองที่ 1 ทำการทดลองกับข้อมูลสามชนิด คือข้อมูล Iris Plant ข้อมูลจาก KDD Cup 1999 และข้อมูล Abalone ผลการทดลอง ANFIS ให้อัตราการจำแนกประเภทข้อมูลสูง แต่ในการจำแนกประเภทข้อมูลที่มีอินพุตจำนวนมาก และข้อมูลฝึกสอนมีมาก เช่นข้อมูลจาก KDD Cup 1999 ในการฝึกสอนระบบ ANFIS สิ้นเปลืองเวลาในการฝึกสอนมาก

และในปัญหานี้เองผู้วิจัยจึงนำเสนอการแก้ไขโดยการ ปรับปรุงโครงสร้างของ ANFIS ซึ่งโครงสร้างเดิมของ ANFIS มีจุดอ่อนในด้านเวลาในการคำนวณเพื่อฝึกสอนระบบ ในกรณีที่ที่จำนวนอินพุตมากๆ ทำให้จำนวนโหนดในการคำนวณมากตาม การแก้ปัญหาลดจำนวนโหนดของ รูลแอนทีซีเดนต์ (Rule Antecedent) ซึ่งอยู่ในรูปของกฎ fuzzy if-then ด้วยการสร้างโหนดเริ่มต้นให้กับ ANFIS ซึ่งนำหลักการคำนวณแกรนูลาร์ มาใช้ในการสร้างกฎ ด้วยจุดเด่นของอัลกอริทึมในการสร้างกฎ ที่สามารถปรับค่าเทรสโพลของค่าความถูกต้องของกฎให้เข้ากับข้อมูลแต่ละอย่างได้ จึงทำให้สามารถสร้างกฎได้อย่างถูกต้อง จากการทดลองที่ 2 โครงสร้างของ ANFIS ที่ปรับปรุงใหม่ยังคงให้อัตราความถูกต้องของการจำแนกประเภทข้อมูลสูง แต่สามารถลดเวลาในการฝึกสอนระบบลงได้มาก

7.2 ปัญหาและข้อเสนอแนะ

ประการที่ 1 เนื่องจากในการฝึกสอนและทดสอบระบบกับข้อมูลบางตัวซึ่งมีกลุ่มของข้อมูลจำนวนมากเช่นข้อมูล Abalone ซึ่งมีกลุ่มของข้อมูลมากถึง 25 กลุ่ม ในการแบ่งข้อมูลมาฝึกสอนและทดสอบ เนื่องข้อมูลมีการกระจายที่ไม่แน่นอนทำให้อัตราการจำแนกประเภทข้อมูลต่ำกว่า การจำแนกประเภทข้อมูลประเภทอื่น เช่นเมื่อเทียบกับอัตราการจำแนกประเภทของข้อมูล KDD Cup 1999 ซึ่งในงานวิจัยนี้เลือกกลุ่มของข้อมูลมาทำการฝึกสอนและทดสอบเพียง 3 กลุ่ม

ประการที่ 2 โมเดลที่นำเสนอในงานวิจัยนี้ เป็นการนำเสนอแนวคิดในการแก้ปัญหาการจำแนกประเภทข้อมูล ซึ่งในการฝึกสอนและทดสอบระบบ จะแบ่งข้อมูลเป็นสองส่วนส่วนที่หนึ่งสำหรับฝึกสอนและส่วนที่สองสำหรับทดสอบ จากผลการทดลองแบ่งข้อมูลหลายๆสัดส่วน ได้ผลของอัตราการจำแนกประเภทข้อมูลที่ไม่เท่ากัน เนื่องจาก ลักษณะการกระจายของกลุ่มข้อมูลที่ไม่เท่ากัน

ประการที่ 3 จากการทดลองแสดงให้เห็นว่า โมเดลของ ANFIS ที่ปรับปรุงใหม่ ยังคงให้ประสิทธิภาพในการจำแนกประเภทข้อมูลสูง อีกทั้งจากการปรับปรุงกฎ fuzzy if-then ด้วยหลักการคำนวณแกรนูลาร์ ทำให้สามารถลดเวลาในการฝึกสอน ANFIS ลงได้ ในโอกาสต่อไปผู้วิจัยจะวิจัยศึกษาถึง ผลกระทบของการสร้างกฎ fuzzy if-then จากตารางสารสนเทศที่ข้อมูลไม่ครบถ้วนสมบูรณ์

บรรณานุกรม

- [1] J. S. Jang, "ANFIS: Adaptive-network based fuzzy inference Systems", *IEEE Transactions on Systems, Man and Cybernetics*, vol. 23, no. 3, May 1993
- [2] Branimir B. Jovanovic, Irini S. Reljin, "Modified ANFIS Architecture—Improving Efficiency of ANFIS Technique", *7th Seminar on Neural Network Applications in Electrical Engineering*, Sep 2004
- [3] Zadeh, L.A. "Towards a theory of fuzzy information granulation and its centrality in human reasoning and fuzzy logic", *Fuzzy Sets and Systems*, 19, 1997.
- [4] Y.Y. Yao, "A Generalized Decision Logic Language for Granular Computing Fuzzy Systems," *Proceedings of the 2002 IEEE International Conference*, 2002.
- [5] J. J. An, G. Y. Wang, Y. Wu, Q. Gan, "A Rule Generation Algorithm based on Granular Computing", in *Proc. IEEE Int. Conf. on Granular Computing, Beijing, P. R. China*, 2005, pp.102-108.
- [6] Jonatan Gomez and Dipankar Dasgupta, "Evolving Fuzzy Classifiers for Intrusion Detection", *Proceedings of the 2002 IEEE Workshop on Information Assurance United States Military Academy, West Point, NY*, June 2001
- [7] Quan Gan, Guoyin Wang, Jun Hu, "A Self-Learning Model based on Granular Computing.", *IEEE International Conference on Granular Computing*, 10-12 May 2006
- [8] Y. Y. Yao, "Granular computing: basic issues and possible solutions", in *Proc. 5th Joint Conf. on Information Sciences*, vol. 1, Atlantic City, USA, 2000, pp. 186-189.
- [9] DE-SHENG YIN, GUO-YIN WANG, YU WU, "A SELF-LEARNING ALGORITHM FOR DECISION TREE PRE-PRUNING", *Proceedings of the Third International Conference on Machine Learning and Cybernetics, Shanghai*, 26-29 August 2004
- [10] "UCI Machine Learning Repository" [online] เข้าถึงได้จาก:
<http://www.ics.uci.edu/~mllearn/databases>
- [11] Negnevitsky, M., "Artificial Intelligence: A Guide to Intelligent Systems", pp.266-283 , Addison Wesley, Harlow, England, 2002.
- [12] Jang S.R., Sun C.T. and Mizutani E., "Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence.", Prentice-Hall, 1997

ภาคผนวก

การปรับปรุงแอนฟิสโดยใช้แกรนูลาร์คอมพิวติง Modified ANFIS using Granular Computing

เอื้อน ปิ่นเงิน¹ และ พรประสิทธิ์ บุญทอง²

ภาควิชาวิศวกรรมคอมพิวเตอร์ คณะวิศวกรรมศาสตร์
โครงการสำนักวิจัยการสื่อสารและเทคโนโลยีสารสนเทศ
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
E-mail: ¹kpouen@kmitl.ac.th, ²pornprasitb@hotmail.com

บทคัดย่อ

ปัจจุบันมีการใช้เทคโนโลยีระบบอัจฉริยะแบบผสมผสานในการแก้ปัญหาทางด้านการแบ่งกลุ่มข้อมูลกันอย่างแพร่หลาย ด้วยจุดเด่นของการผสมผสานการทำงานของระบบอัจฉริยะ แต่ละตัว โดยเฉพาะ การผสมผสานการทำงานของ *Neural Network* และ *Fuzzy Logic* ภายใต้ชื่อ *Adaptive Neuro-Fuzzy Inference System (ANFIS)* แต่เนื่องจากโหนดในชั้น *Rule Layer* มีจำนวนมากตามจำนวน ฟังก์ชันความเป็นสมาชิกของฟuzzy และจำนวน อินพุต ทำให้ *ANFIS* ต้องใช้เวลาในการฝึกสอนมาก บทความนี้ นำเสนอการปรับปรุง *ANFIS* โดยนำหลักการ *Granular Computing* มาใช้สร้าง โหนดของ *Rule Layer* ที่เหมาะสมให้กับ *ANFIS* ผลการทดลองได้จำนวน โหนดของ *Rule layer* ลดลง ทำให้เวลาในการฝึกสอนและทดสอบลดลง

Abstract

Recently hybrid intelligent system is the popular kind of method for solving problem especially classification problem. *Neural Network* and *Fuzzy Logic* combine into integrated system call *Adaptive Neuro-Fuzzy Inference system (ANFIS)*. Due to large number of nodes in rule layer, conventional *ANFIS* spend much more time for training and testing. This paper propose a method to modify *ANFIS* based on *Granular Computing* to reducing number of rule nodes, with intention of making *ANFIS* more efficient regarding to training time. Simulation results promised that modified *ANFIS* can reduce training time.

Keywords: Adaptive Neuro-Fuzzy Inference System , Granular Computing

1. บทนำ

Fuzzy Logic (FL) และ *Artificial Neural Network (ANN)* เป็นเทคนิคสำหรับสร้าง ระบบอัจฉริยะ ซึ่งเมื่อ ออกแบบให้ทำงานร่วมกัน จะทำให้เครื่องมือทั้งสอง ทำงานในลักษณะส่งเสริมซึ่งกันและกัน โดย *ANN* มีคุณสมบัติเด่นทางด้าน การเรียนรู้จากข้อมูลที่เป็นข้อมูล คิบ ในขณะที่ *FL* มีข้อดีทางด้าน การให้เหตุผล โดยการ ใช้ linguistic information ที่ได้จาก domain expert

อย่างไรก็ตาม *FL* ก็มีจุดอ่อนทางด้าน การเรียนรู้กับการปรับระบบ ให้เข้ากับสภาพแวดล้อมของปัญหา ต่างๆ ถึงแม้ว่า *ANN* มีจุดเด่นในด้านการเรียนรู้และการปรับตัวเองแต่ก็มีจุดอ่อนเนื่องจาก การทำงานใน ลักษณะการคำนวณที่ซับซ้อน ทำให้ผู้ใช้ไม่สามารถ เข้าถึงขบวนการคำนวณภายใน ทำให้ขบวนการ นำเสนอความรู้แก่ผู้ใช้ทำได้ไม่ดี การรวมการทำงาน ของ *ANN* และ *FL* ภายใต้ชื่อ neuro-fuzzy[1] ทำให้ ระบบเกิดการผสมผสานการทำงาน ในการนำเสนอองค์ ความรู้ แล้วนำความรู้ที่นำมาวิจัยประกอบ

ตัดสินใจ อีกทั้งทำให้ระบบยังสามารถเรียนรู้ และปรับตัวในสภาพแวดล้อมขององค์ความรู้เหล่านั้น ได้อย่างที่มนุษย์สามารถทำได้

Neuro-Fuzzy เป็น Multilayer Neural Network ที่ออกแบบให้ทำงานเทียบเท่ากับ Fuzzy Inference System ภายใต้ชื่อ Adaptive Neuro-Fuzzy Inference System (ANFIS) [1] ซึ่งทำให้ระบบถูกฝึกให้มีการเรียนรู้และปรับค่าพารามิเตอร์ (parameter) ของกฎ if-then และกำหนด membership function ของอินพุตและเอาต์พุตของระบบ ซึ่งโครงสร้างของ ANFIS ประกอบด้วย ชั้นอินพุต ชั้นเอาต์พุตและ ชั้นซ่อน ซึ่งแทน membership function และกฎ fuzzy if-then โดยส่วนจำนวนโหนดของกฎ fuzzy if-then มีจำนวน p [2] โดยที่ p แทนจำนวนการแบ่ง membership function ของอินพุตและ n แทนจำนวนอินพุต ซึ่งในปัญหาการจำแนกประเภทข้อมูล ในปัญหามีอินพุตจำนวนมาก ทำให้จำนวนโหนดของกฎ Fuzzy if-then มีจำนวนมาก ซึ่ง ANFIS สิ้นเปลืองเวลา ในการฝึกสอนเพื่อปรับค่าพารามิเตอร์

งานวิจัยนี้ นำเสนอ การปรับปรุง ANFIS ในส่วนของการกำหนดค่าเริ่มต้นของกฎ Fuzzy if-then โดยนำทฤษฎี Granular Computing เพื่อใช้สร้างโหนดของกฎที่เหมาะสมของ Fuzzy Rule Layer ให้กับ ANFIS เพื่อช่วยลดเวลาในการฝึกสอน ANFIS

เนื้อหาส่วนที่เหลือของบทความนี้ ประกอบด้วย เนื้อหาต่อไปนี หัวข้อที่ 2 โครงสร้างและการทำงานพื้นฐานของ ANFIS หัวข้อที่ 3 ทฤษฎีแนวคิดพื้นฐานของ Granular Computing หัวข้อที่ 4 การปรับปรุง ANFIS ด้วยหลักการของ Granular Computing หัวข้อที่ 5 การทดลองและอธิบายผล หัวข้อที่ 6 บทสรุป


2. โครงสร้างของ ANFIS

ปี ค.ศ 1993 R. Jang [1] ได้เสนองานวิจัยทางด้าน Neural Network ซึ่งทำงานเทียบเท่ากับ Fuzzy Inference ตามแบบของ Sugeno Fuzzy Inference โดยใช้ชื่อว่า Adaptive Neuro-Fuzzy Inference System หรือ ANFIS ซึ่งมี 2 อินพุต 1 เอาต์พุต มีกฎ fuzzy if-then :

Rule1: If x is A_1 and y is B_1 , then $f_1 = p_1x + q_1y + r_1$

Rule2: If x is A_2 and y is B_2 , then $f_2 = p_2x + q_2y + r_2$

โครงสร้าง ANFIS แสดงดังรูปที่ 1 พิจารณาการทำงานของ ANFIS ใน layer ต่างๆ ดังนี้



รูปที่ 1 โครงสร้าง ANFIS แบบ 2 อินพุต

Layer1 Fuzzification layer: แต่ละ node ในชั้นนี้เขียนอยู่ในรูปของ membership function

$$O_i^1 = \mu_{A_i}(x), i=1,2$$

$$O_i^1 = \mu_{B_i}(y), i=3,4$$

โดยที่ x (หรือ y) แทนอินพุตของ node i , และ A_i (หรือ B_i) แทนค่าปริมาณ linguistic label ซึ่งในชั้นนี้ใช้การกำหนด membership function แบบ bell ด้วยสมการ

$$\mu_{A_i}(x) = \frac{1}{1 + \left(\frac{x - c_i}{a_i}\right)^{2b_i}}$$

โดยที่ a_i , b_i และ c_i เป็นพารามิเตอร์แทนจุดศูนย์กลาง (center) ความกว้าง (width) และ slope ของ bell function

Layer2 Rule antecedent layer: node ในชั้นนี้ทำงานตามหลักของ Fuzzy rule ตามแบบของ Sugeno เออร์ทฟุตของชั้นนี้แทน firing strength ของ fuzzy rule.

$$O_i^2 = w_i = \mu_{A_i}(x) \times \mu_{B_i}(y), i = 1, 2$$

Layer3 Rule consequent layer: ในชั้นนี้รับอินพุตจาก rule antecedent layer แล้วคำนวณหาค่า normalized firing strength.

$$O_i^3 = \bar{w}_i = \frac{w_i}{\sum_i w_i}, i = 1, 2$$

Layer4 Combination and defuzzification layer: แต่ละ node ในชั้นนี้เป็น square node กำหนดโดย

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x_1 + q_i x_2 + r_i), i = 1, 2$$

โดยที่ \bar{w}_i เป็นเออร์ทฟุตของ layer 3, และ (p_i, q_i, r_i) เป็นเซตของ consequent parameter ซึ่งใช้ least means square algorithm เพื่อกำหนดค่า consequent parameters

Layer5 Rule inference layer: เป็น summation neuron ซึ่งคำนวณค่าผลรวมของเออร์ทฟุตของ defuzzification neuron ทุกตัว และให้ค่าเออร์ทฟุตของ ANFIS ดังนี้

$$\text{Overall output} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i}$$

3. หลักการพื้นฐานของ Granular Computing

Information Granulation เป็นหลักปัจจัยสำคัญของการแก้ปัญหา ของมนุษย์ โดยเฉพาะการออกแบบและสร้าง Intelligent System โดย Professor L.A. Zadeh [3] นำเสนอแนวคิดพื้นฐาน ของการแก้ปัญหา ด้านการรู้จำของมนุษย์ โดยใช้ชื่อ Granulation , Organization และ Causation ซึ่ง Granulation เป็นแนวคิดเกี่ยวกับการแบ่งส่วนประกอบออกเป็น ส่วนย่อย Organization เป็น

หลักของการรวมส่วนประกอบ เข้าด้วยกัน และ Causation เกี่ยวข้องกับการรวมหลักของเหตุและผล โดยแนวคิดของ Granular Computing (GrC) ในการแก้ปัญหา ทำการแบ่งปัญหาออกเป็น ส่วนย่อยเรียกว่า Granules โดยโครงสร้างของ Granules กำหนดให้อยู่ในรูปของ ความสัมพันธ์คล้ายกัน ความน่าจะเป็น และความสัมพันธ์ในรูปของกฎ Fuzzy if-then

การแก้ปัญหา โดยใช้หลักการของ Granular Computing [4] ชั้นแรกแบ่งปัญหาออกเป็น granules ย่อย จากนั้นในการคำนวณในแต่ละลำดับชั้น granules จะประกอบกัน หรือ แยกส่วนได้เป็น granules ใหม่แล้วทำการประมวลผล ไปจนกระทั่ง granule ใหม่แก้ปัญหา นั้น ได้อย่างถูกต้อง ซึ่งหลักการเบื้องต้นของ GrC ดังนี้

นิยามที่ 1 [5] กำหนดให้ปัญหาอยู่ในรูปของตารางสารสนเทศที่มีส่วนประกอบดังนี้

$$S = (U, A, (C \cup D), L, \{V_a | a \in A\}, \{I_a | a \in A\})$$

โดย U แทนเซตของวัตถุ A_i แทนเซตของคุณลักษณะซึ่งประกอบด้วยเซตของส่วนเงื่อนไข (C) และเซตของส่วนตัดสินใจ (D) L แทนภาษาที่ใช้ในการตัดสินใจอยู่ในรูปแบบ $a=v$ โดยที่ $a \in A_i$ และ $v \in V_a$. V_a แทนเซตของค่าของคุณลักษณะ และ $I_a: U \rightarrow V_a$ แทนฟังก์ชันของสารสนเทศ ซึ่ง ภาษาที่ใช้ตัดสินใจอยู่ในรูปของสมการลอจิก ถ้ากำหนดให้วัตถุ x สัมกับสมการลอจิก ϕ เขียนอยู่ในรูปของ $x|\phi$ แล้ว $m(\phi) = \{x \in U | x|\phi\}$ แทนเซตของวัตถุ x ทั้งหมดที่มีคุณสมบัติตรงตามสมการ ϕ ในการกำหนด granule พื้นฐานจากตารางสารสนเทศ อยู่ในรูปของ $(\phi, m(\phi))$ โดยที่ $\phi \in L$

นิยามที่ 2 [5] กำหนดให้ในตารางสารสนเทศ S มี granule พื้นฐานคือ $(\phi, m(\phi))$ และ $(\phi', m(\phi'))$ การคำนวณของ granule โดยใช้สมการบูลีนใช้ตัวกระทำ $\text{not}(\sim)$, $\text{or}(\oplus)$, $\text{and}(\otimes)$, $\text{inclusion}(\supseteq)$ และ $\text{equivalence}(\equiv)$ ซึ่งการใช้ตัวกระทำทางบูลีนต่าง ๆ ใช้ในการประกอบและแยกส่วน ของ granule ได้เป็น granule ใหม่

นิยามที่ 3 กำหนดให้ granule พื้นฐานคือ $(\phi, m(\phi))$ และ $(\phi', m(\phi'))$ การกระทำ minus (-) กำหนดโดย

$$(\phi, m(\phi)) - (\phi', m(\phi')) = (\phi, m(\phi)) \otimes (\sim(\phi', m(\phi')))$$

นิยามที่ 4 [5] กำหนดให้สมการลอจิกสองสมการ ϕ และ φ ซึ่งค่า confidence support ของสมการ φ ที่ถูกกำหนดโดยสมการ ϕ

$$AS(\phi \Rightarrow \varphi) = |m(\phi) \cap m(\varphi)| / |m(\phi)|$$

โดย ค่า Absolute Support (AS) แสดงในรูปของค่า support เชิงปริมาณ

4. การปรับปรุง ANFIS

โครงสร้าง ANFIS เดิมที่มีจำนวนอินพุต n และจำนวนของการแบ่ง membership function ของอินพุตแต่ละตัวออกเป็น p ดังนั้นจำนวนกฎที่ได้เป็น p^n ให้ m แทนจำนวน fitting parameter ของแต่ละ membership function จำนวน premise fitting parameter ของแต่ละอินพุตเป็น pm ดังนั้นจำนวน premise fitting parameter ทั้งหมดเป็น npm ซึ่งในงานวิจัยนี้ทำการลดจำนวน premise fitting parameter ด้วยการสร้าง กฎ if-then โดยใช้หลักการ Granular Computing

กระบวนการทำงานของระบบแสดงดังรูปที่ 2 โดยมีลำดับขั้นตอน การทำงานของระบบดังนี้

4.1 การแปลงข้อมูล Continuous เป็น Discrete

การแปลงข้อมูล Continuous เป็น Discrete เพื่อใช้ในการสร้างกฎ ซึ่งการแปลงข้อมูลใช้หลักของ Fuzzy Discretization [7] โดยขั้นแรกจะทำการแปลงค่าของแต่ละคุณลักษณะให้มีค่าอยู่ระหว่าง 0 ถึง 1 โดยใช้สมการต่อไปนี้:


$$x = \frac{x - MIN}{MAX - MIN}$$

โดยที่ x คือค่าของคุณลักษณะ


MIN คือค่าต่ำที่สุดของคุณลักษณะ

MAX คือค่าสูงที่สุดของคุณลักษณะ

จากนั้นแปลงค่าที่คำนวณได้เป็นค่าฟัซซีโดยใช้ 3 ฟัซซี ซับเซต ประกอบด้วย Low(L), Medium(M) และ High(H) ตามลำดับดังรูปที่ 3



รูปที่ 2 แสดงกระบวนการทำงานของระบบ



รูปที่ 3 Fuzzy space ของแต่ละคุณลักษณะ



4.2 การสร้างกฎด้วย Granular Computing

อัลกอริทึมที่ใช้ในการสร้างกฎ if-then ภายใต้หลักการของ Granular Computing [6] จะทำการแทนตารางสารสนเทศด้วยภาษาที่ใช้ตัดสินใจอยู่ในรูปแบบของ $a=v$ ตามนิยามที่ 1 ซึ่งเรียกว่า Granule จำนวน 2 Granules คือ Condition attribute granule (CG) และ Decision attribute granule (DG) แล้วทำตามลำดับขั้นตอนดังนี้

ขั้นที่ 1. กำหนดค่าเริ่มต้นของเซตของ Rule granule $RGS = \{\emptyset\}$ และเซตของคุณลักษณะของเงื่อนไข $CS = \{\emptyset\}$

ขั้นที่ 2. แบ่งตารางสารสนเทศออกเป็น Granule ย่อยจำนวน 2 Granules คือ CG และ DG

ขั้นที่ 3. คำนวณค่า confident support $AS(CG_i \Rightarrow DG_k)$ ตามนิยามที่ 4

ขั้นที่ 4. ถ้าค่า confident support=1 ให้ $RGS = RGS \cup \{CG_i\}$

ตรวจสอบ RGS ครอบคลุม instance ทั้งหมดหรือไม่ ถ้าไม่ทำการขยาย Solution space ด้วยตัวกระทำ AND


ขั้นที่ 5. ปรับ CG และ DG ด้วยการทำ minus operation กับ RGS ตามนิยามที่ 3

$$(CG_i - RGS, DG_i - RGS)$$


ขั้นที่ 6. ทำซ้ำขั้นที่ 3, 4 และ 5 จนกระทั่ง RGS ครอบคลุมทุก ๆ Instance ใน ตารางสารสนเทศ

4.3 กระบวนการปรับปรุง ANFIS

จากกฎ if-then ที่ได้ภายใต้หลักการของ Granular Computing นำกฎ if-then มาใช้ทำการปรับปรุง ANFIS ด้วยการปรับ layer ที่ 2 จากนั้นทำการฝึกสอนระบบซึ่งโครงสร้างเดิมและโครงสร้างใหม่ของ ANFIS แสดงดังรูปที่ 4 และรูปที่ 5 ตามลำดับ



รูปที่ 4 โครงสร้างเดิมของ ANFIS แบบ 4 อินพุต



รูปที่ 5 โครงสร้างใหม่ของ ANFIS แบบ 4 อินพุต

5. การทดลองและอภิปรายผล


ข้อมูลที่ใช้สำหรับสร้างกฎ ฝึกสอนและทดสอบ ANFIS ในงานวิจัยนี้ นำมาจาก UCI Machine Learning Repository [8] โดยเลือกทดลองกับข้อมูล Iris Plant dataset [8] ซึ่งประกอบด้วยจำนวน 4 คุณลักษณะ เซตของคุณลักษณะที่ใช้ตัดสินใจ 1 คุณลักษณะ และกลุ่มของข้อมูลมี 3 กลุ่ม จำนวนข้อมูลที่ใช้สร้างกฎ 150 รายการ เมื่อดำเนินการตามอัลกอริทึมได้กฎ Fuzzy if-then แสดงตามตารางที่ 1

เงื่อนไข	กลุ่ม
if C3 = c3L	Iris-setosa
if C4 = c4L	Iris-setosa
if C2 = c2H	Iris-setosa
if c1=c1L and c2=c2L	Iris-versicolor
if c1=c1L and c3=c3M	Iris-versicolor
if c1=c1L and c4=c4M	Iris-versicolor
if c2=c2L and c4=c4M	Iris-versicolor
if c3=c3M and c4=c4M	Iris-virginica
if C1 = c1H	Iris-virginica
if C3 = c3H	Iris-virginica
if C4 = c4H	Iris-virginica

ตารางที่ 1 ผลที่ได้จากการสร้างกฎ



ในการทดลองจำแนกประเภทข้อมูลในงานวิจัยนี้ ใช้ ANFIS toolbox ใน MatLAB เวอร์ชัน 7.0 ซึ่งจำนวนพารามิเตอร์ทั้งหมดของ Default ANFIS เป็น $(n \cdot p \cdot m) + p$ เมื่อให้อินพุตเป็น 4 ($n=4$) จำนวนการแบ่ง membership function เป็น 3 ($p=3$) และพารามิเตอร์ของ membership function แต่ละตัวเป็น 3 ($m=3$) จะได้พารามิเตอร์ทั้งหมดเป็น $(4 \cdot 3 \cdot 3) + 3 = 117$ และเมื่อนำกฎจากตารางที่ 1 ซึ่งจำนวนกฎเป็น 11 กฎ มาสร้างเป็นกฎเริ่มต้นของ Modified ANFIS จะได้พารามิเตอร์ทั้งหมดเป็น $((2 \cdot 3) + (2 \cdot 3) + (3 \cdot 3) + (3 \cdot 3)) + 11 = 41$ ซึ่งจำนวนพารามิเตอร์ลดลงจากเดิม 65% จากนั้นฝึกสอนกับข้อมูลจำนวน 1000 รายการ ผลการทดสอบ เวลาในการฝึกสอนลดลง 91% และทดสอบกับข้อมูล 1000 รายการ ซึ่ง Modified ANFIS ให้ประสิทธิภาพของการจำแนกประเภทข้อมูลลดลงจากเดิม เพียง 0.096% รูปที่ 6 เป็นกราฟแท่งแสดงการเปรียบเทียบประสิทธิภาพโดยรวมของ Default ANFIS และ Modified ANFIS



รูปที่ 6 การเปรียบเทียบประสิทธิภาพโดยรวมของ Default ANFIS และ Modified ANFIS

6. บทสรุป

งานวิจัยนี้นำเสนอการปรับปรุง ANFIS ด้วยการสร้างกฎ if-then ให้กับ ANFIS ซึ่งการสร้างกฎ if-then นำหลักการ Granular Computing ซึ่งสามารถลดจำนวนกฎ if-then และลดจำนวนพารามิเตอร์จากการทดสอบประสิทธิภาพของ ANFIS โดยการ

ทดสอบกับข้อมูลจำนวนมากๆ ยังคงให้อัตราการจำแนกประเภทข้อมูลที่ไม่ต่างกันมากนัก แต่จำนวนพารามิเตอร์และเวลาที่ใช้ในการฝึกสอนลดลง

อย่างไรก็ตามในการทดลองสร้างกฎกับข้อมูลที่มีกลุ่มของข้อมูลมีหลายๆ กลุ่มทำให้ อัลกอริทึมไม่สามารถสร้างกฎได้เนื่องจากประเภทของข้อมูลที่กระจายอีกทั้ง confident support ของกฎเป็น 1 สำหรับงานที่จะทำต่อไปคือการปรับ confident support ของกฎให้เหมาะกับข้อมูลแต่ละชนิด

7. เอกสารอ้างอิง

- [1] J. S. Jang, "ANFIS: Adaptive-network based fuzzy inference Systems, *IEEE Transactions on Systems, Man and Cybernetics*, vol. 23, no. 3, pp. 665-685, May 1993
- [2] Branimir B. Jovanovic, Irlin S. Reljin, "Modified ANFIS Architecture-Improving Efficiency of ANFIS Technique", *7th Seminar on Neural Network Applications in Electrical Engineering*, September 2004
- [3] Zadeh, L.A. "Towards a theory of fuzzy information granulation and its centrality in human reasoning and fuzzy logic", *Fuzzy Sets and Systems*, 19, 111-127, 1997.
- [4] Y. Y. Yao, "Granular computing: basic issues and possible solutions", in *Proc. 5th Joint Conf. on Information Sciences*, vol. 1, Atlantic City, USA, 2000, pp. 186-189.
- [5] Y.Y. Yao, "A Generalized Decision Logic Language for Granular Computing Fuzzy Systems," *Proceedings of the 2002 IEEE International Conference*, Vol.1, 2002, 773-778.
- [6] J. J. An, G. Y. Wang, Y. Wu, Q. Gan, "A Rule Generation Algorithm based on Granular Computing", in *Proc. IEEE Int. Conf. on Granular Computing*, Beijing, P. R. China, 2005, pp.102-108.
- [7] Jonatan Gomez and Dipankar Dasgupta, "Evolving Fuzzy Classifiers for Intrusion Detection", *Proceedings of the 2002 IEEE Workshop on Information Assurance United States Military Academy*, West Point, NY, June 2001
- [8] "Iris data set" [online] เข้าถึงได้จาก: <http://www.ics.uci.edu/~mlearn/databases/iris/>

ประวัติผู้เขียน

ชื่อ-สกุล	นายพรประสิทธิ์ บุญทอง
วันเดือนปีเกิด	วันที่ 23 กรกฎาคม พ.ศ. 2516 ณ จังหวัดกระบี่
ที่อยู่	มหาวิทยาลัยเทคโนโลยีราชมงคลรัตนโกสินทร์ ตำบลหัวหิน อำเภอหัวหิน จังหวัดประจวบคีรีขันธ์ 77110
ประวัติการศึกษา	
พ.ศ. 2539	สำเร็จการศึกษาวิศวกรรมศาสตรบัณฑิต สาขาวิศวกรรมคอมพิวเตอร์ ศูนย์กลางสถาบันเทคโนโลยีราชมงคล
พ.ศ. 2545	เข้าศึกษาต่อในระดับวิศวกรรมศาสตรมหาบัณฑิต สาขาวิศวกรรมคอมพิวเตอร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
ประสบการณ์ทำงาน	
พ.ศ. 2539-ปัจจุบัน	เข้ารับราชการตำแหน่งอาจารย์ ประจำสาขาวิชาเทคโนโลยีคอมพิวเตอร์ คณะอุตสาหกรรมและเทคโนโลยี มหาวิทยาลัยเทคโนโลยีราชมงคล รัตนโกสินทร์