

การประยุกต์ใช้แบ็กพรอพาทะชันนิรอลเน็ตเวิร์กเพื่อจำแนกประเภท
จากกฎความสัมพันธ์ของประเภท



นางสาวนภาพรณ ยิงชาญกุล

สถาบันวิทยบริการ จุฬาลงกรณ์มหาวิทยาลัย

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

สาขาวิชาวิทยาศาสตร์คอมพิวเตอร์ ภาควิชาวิศวกรรมคอมพิวเตอร์

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

ปีการศึกษา 2548

ISBN 974-17-3886-2

ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

APPLYING BACKPROPAGATION NEURAL NETWORKS FOR CLASSIFICATION
FROM CLASS ASSOCIATION RULES

Miss Napaparn Yingchankul



สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

A Thesis Submitted in Partial Fulfillment of the Requirements
for the Degree of Master of Science Program in Computer Science

Department of Computer Engineering

Faculty of Engineering

Chulalongkorn University

Academic Year 2005

ISBN 974-17-3886-2

หัวข้อวิทยานิพนธ์

การประยุกต์ใช้แบคทีเรียรื้อซากสัตว์เพื่อจัดการกับของเสีย
เพื่อจำแนกประเภทจากกฎความสัมพันธ์ของประเภท

โดย

นางสาวนภาพรพรณ ยิ่งชาญกุล

สาขาวิชา

วิทยาศาสตร์คอมพิวเตอร์

อาจารย์ที่ปรึกษา


ผู้ช่วยศาสตราจารย์ ดร.ญาใจ ลืมปิยะกรณ์

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้นำวิทยานิพนธ์ฉบับนี้
เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญามหาบัณฑิต

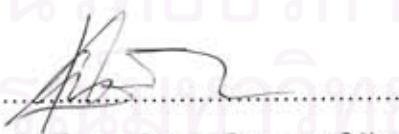

..... คณะบดีคณะวิศวกรรมศาสตร์
(ศาสตราจารย์ ดร.ดิเรก ลาวัณย์ศิริ)

คณะกรรมการสอบวิทยานิพนธ์


..... ประธานกรรมการ
(รองศาสตราจารย์ ดร.บุญเสริม กิจศิริกุล)


..... อาจารย์ที่ปรึกษา
(ผู้ช่วยศาสตราจารย์ ดร.ญาใจ ลืมปิยะกรณ์)


..... กรรมการ
(อาจารย์ ดร.อาทิตย์ ทองทัช)


..... กรรมการ
(อาจารย์ ดร.เจลิ้มเอ็ก อินทนกรวิวัฒน์)

นภาพรณ ยิ่งชาญกุล : การประยุกต์ใช้แบ็กพรอพาเกชันนิรอลเน็ตเวิร์กเพื่อจำแนกประเภทจากกฎความสัมพันธ์ของประเภท. (APPLYING BACKPROPAGATION NEURAL NETWORKS FOR CLASSIFICATION FROM CLASS ASSOCIATION RULES) อ. ที่ปรึกษา : ผศ.ดร.ญาใจ ลิมปิยะภรณ์, 70 หน้า. ISBN 974-17-3886-2.

การจำแนกประเภทเชิงความสัมพันธ์เป็นวิธีการหนึ่งที่ใช้สร้างตัวจำแนกประเภทข้อมูลที่มีความแม่นยำและให้กฎจำแนกประเภทที่เข้าใจได้ง่าย อย่างไรก็ตาม ขั้นตอนวิธี CBA ซึ่งเป็นต้นแบบของการจำแนกประเภทเชิงความสัมพันธ์ ยังมีข้อจำกัดเกี่ยวกับวิธีการสร้างตัวจำแนกประเภทข้อมูล ส่งผลให้ความแม่นยำของขั้นตอนวิธี CBA ต่ำกว่าขั้นตอนวิธีประเภทเดียวกันที่เกิดขึ้นในภายหลัง งานวิจัยนี้จึงนำเสนอการประยุกต์ใช้แบ็กพรอพาเกชันนิรอลเน็ตเวิร์กเพื่อจำแนกประเภทจากกฎความสัมพันธ์ของประเภท ผู้วิจัยได้นำนิรอลเน็ตเวิร์กมาใช้ในการจำแนกประเภทข้อมูลใน 2 ลักษณะ คือ เพื่อคัดเลือกกฎความสัมพันธ์ของประเภทที่ใช้จำแนกประเภทข้อมูล และเพื่อจำแนกประเภทข้อมูลโดยตรง ข้อดีของวิธีการที่นำเสนอ คือ การนำความรู้ก่อนหน้าซึ่งอยู่ในรูปแบบกฎความสัมพันธ์ของประเภทที่ค้นพบในขั้นตอนการค้นหากฎความสัมพันธ์ของประเภท มาช่วยกำหนดโครงสร้างของนิรอลเน็ตเวิร์กที่จะใช้ทำการเรียนรู้เพื่อสร้างตัวจำแนกประเภทข้อมูลสำหรับข้อมูลใหม่ด้วยความแม่นยำที่มากยิ่งขึ้น ผลการทดลองโดยเปรียบเทียบวิธีการที่นำเสนอกับวิธีการเรียนรู้ของเครื่องแบบ C4.5 ขั้นตอนวิธี CBA เดิม และ CPAR แสดงให้เห็นว่าวิธีการที่นำเสนอนี้ให้ผลลัพธ์ความแม่นยำของการจำแนกประเภทข้อมูลที่ดีที่สุด

สถาบันวิทยบริการ จุฬาลงกรณ์มหาวิทยาลัย

ภาควิชา..... วิศวกรรมคอมพิวเตอร์.....ลายมือชื่อนิสิต.....หญิงชาญกุล.....
สาขาวิชา.....วิทยาศาสตร์คอมพิวเตอร์.....ลายมือชื่ออาจารย์ที่ปรึกษา.....
ปีการศึกษา ...2548.....

46703457 : MAJOR COMPUTER SCIENCE

KEY WORD: ASSOCIATIVE CLASSIFICATION / CLASS ASSOCIATION RULES / BACKPROPAGATION NEURAL NETWORKS

NAPAPARN YINGCHANKUL : APPLYING BACKPROPAGATION NEURAL NETWORKS FOR CLASSIFICATION FROM CLASS ASSOCIATION RULES.

THESIS ADVISOR : ASST. PROF. YACHAI LIMPIYAKORN, Ph.D., 70 pp.

ISBN 974-17-3886-2.

Associative Classification is a promising approach for building accurate classifiers and producing human understandable classification rules. However, the original algorithm, CBA, has some drawbacks during the classifier builder phase. Several subsequent algorithms have been invented for better performance. Unlike CBA, this thesis proposes applying Backpropagation Neural Networks to Class Association Rules (CARs) during the classifier construction phase, rather than ranking them. The method applies Neural Network for classifying in two ways. First is to select a CAR used for classifying new data. The other is to directly use it for predicting the class label of new data. The advantage of our approach is the ability of employing prior knowledge uncovered in the previous CARs Discovery phase to help defining the structure of Neural Networks that would yield more accuracy rate. Compared with C4.5 learning method, the original CBA and CPAR, the experimental results showed that the proposed method gave the best classification accuracy.



Department..... Computer Engineering.....Student's..... Napaparn Yingchankul
 Field of study.....Computer Science.....Advisor's..... Y. Limpiyakorn
 Academic year ...2005.....

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงไปได้ด้วยความอนุเคราะห์อย่างยิ่งของผู้ช่วยศาสตราจารย์ ดร.ญาใจ ลิ้มปิยะภรณ์ อาจารย์ที่ปรึกษา ซึ่งท่านได้ให้ความรู้ คำแนะนำ และข้อคิดเห็นอันเป็นประโยชน์ต่องานวิจัย จนทำให้การวิจัยในครั้งนี้สำเร็จออกมาด้วยดี

ขอขอบคุณรองศาสตราจารย์ ดร.บุญเสริม กิจศิริกุล อาจารย์ ดร.อาทิตย์ ทองทักษ์ และอาจารย์ ดร.เฉลิมเอก อินทนากรวิวัฒน์ กรรมการสอบวิทยานิพนธ์ ที่กรุณาเสียสละเวลาให้คำแนะนำ ตรวจสอบ และแก้ไขวิทยานิพนธ์ฉบับนี้

ขอบคุณสมาชิกห้องปฏิบัติการวิศวกรรมซอฟต์แวร์ (SE-LAB) และห้องปฏิบัติการอื่นๆ ที่คอยช่วยเหลือ ให้คำแนะนำ และให้กำลังใจด้วยดีเสมอมา

ท้ายที่สุด ผู้วิจัยใคร่ขอกราบขอบพระคุณบิดา มารดา และทุกคนในครอบครัว ที่ให้กำลังใจ และให้การสนับสนุนเรื่อยมาจนสำเร็จการศึกษา

สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

สารบัญ

	หน้า
บทคัดย่อภาษาไทย	ง
บทคัดย่อภาษาอังกฤษ.....	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ.....	ช
สารบัญภาพ.....	ญ
สารบัญตาราง.....	ฎ
บทที่	
1 บทนำ.....	1
1.1 ความเป็นมาและความสำคัญของปัญหา	1
1.2 วัตถุประสงค์ของการวิจัย	2
1.3 ขอบเขตของการวิจัย.....	2
1.4 ขั้นตอนและวิธีดำเนินการวิจัย.....	3
1.5 ประโยชน์ที่คาดว่าจะได้รับ	4
1.6 ลำดับการจัดเรียงเนื้อหาในวิทยานิพนธ์	4
1.7 ผลงานที่ตีพิมพ์จากวิทยานิพนธ์.....	4
2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง	5
2.1 ทฤษฎีที่เกี่ยวข้อง.....	5
2.1.1 การจำแนกประเภทเชิงความสัมพันธ์.....	5
2.1.1.1 การจำแนกประเภทข้อมูล.....	5
2.1.1.2 การค้นหากฎความสัมพันธ์.....	5
2.1.1.3 การค้นหากฎความสัมพันธ์ของประเภท	6
2.1.1.4 การค้นหากฎความสัมพันธ์ของประเภทตามขั้นตอนวิธี CBA	7
2.1.2 นิเวศน์เน็ตเวิร์ก	10
2.1.2.1 เพอร์เซปตรอน	10
2.1.2.2 แบ็กพรอพพาเกชันนิเวศน์เน็ตเวิร์ก.....	11
2.1.3 การเปรียบเทียบขั้นตอนวิธี.....	14

	หน้า
2.2 งานวิจัยที่เกี่ยวข้อง	16
2.2.1 Integrating Classification and Association Rule Mining.....	16
2.2.2 CMAR: Accurate and Efficient Classification Based on Multiple Class-Association Rules	17
2.2.3 CPAR: Classification based on Predictive Association Rules.....	18
2.2.4 Approximate Match of Rules Using Backpropagation Neural Networks	18
2.2.5 การใช้เทคนิค Association Rule Discovery เพื่อการจัดสรรกฎหมาย ในการพิจารณาคดีความ และระบบจำแนกประเภทโครงสร้างของโปรตีน โดยใช้เทคนิคด้าไมนิ่ง	19
3 การประยุกต์ใช้แบ็กพรอพาเกชันนิวรอลเน็ตเวิร์กเพื่อจำแนกประเภท จากกฎความสัมพันธ์ของประเภท	20
3.1 ภาพรวมของวิธีการที่นำเสนอ	20
3.2 การค้นหาความสัมพันธ์ของประเภท	22
3.3 การสร้างโครงสร้างของแบ็กพรอพาเกชันนิวรอลเน็ตเวิร์กจากกฎความสัมพันธ์ ของประเภท.....	27
3.4 การสร้างข้อมูลที่ใช้ในการเรียนรู้	31
3.4.1 การกำหนดค่าให้กับข้อมูลไม่ทราบค่า	32
3.5 การเรียนรู้เพื่อปรับค่าน้ำหนักของเน็ตเวิร์ก	33
4 การทดลองและผลการทดลอง	36
4.1 ชุดข้อมูลที่ใช้ในการทดลอง	36
4.2 วิธีการทดลอง	37
4.3 ผลการทดลอง.....	38
5 สรุปผลการวิจัยและข้อเสนอแนะ.....	50
5.1 สรุปผลการวิจัย	50
5.2 ข้อเสนอแนะ	52
รายการอ้างอิง.....	53

ภาคผนวก

ภาคผนวก ก การค้นหากฎความสัมพันธ์ของประเภทตามขั้นตอนวิธี CBA	57
ภาคผนวก ข ผลการทดลองการจำแนกประเภทข้อมูลด้วยแบ็กพรอพาทาเกชันนิรอรลเน็ตเวิร์ก ที่กำหนดโครงสร้างจากชุดข้อมูล	59
ภาคผนวก ค รายละเอียดของชุดข้อมูลที่ใช้ในการทดลอง	63
ภาคผนวก ง ตารางแจกแจงค่าที่แบบทางเดียว	69
ประวัติผู้เขียนวิทยานิพนธ์	70



สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

สารบัญภาพ

	หน้า
รูปที่ 2.1 ขั้นตอนวิธี CBA ที่ใช้ในการค้นหาความสัมพันธ์ของประเภท.....	8
รูปที่ 2.2 เพอร์เซปตรอนที่ใช้ฟังก์ชันสองชั้นเป็นฟังก์ชันกระตุ้น	11
รูปที่ 2.3 โครงสร้างของแบ็กพรอปาเกชันนิวรอลเน็ตเวิร์ก	12
รูปที่ 2.4 เพอร์เซปตรอนที่ใช้ฟังก์ชันซิกมอยด์เป็นฟังก์ชันกระตุ้น	12
รูปที่ 3.1 ภาพรวมของการประยุกต์ใช้แบ็กพรอปาเกชันนิวรอลเน็ตเวิร์กเพื่อจำแนกประเภท จากกฎความสัมพันธ์ของประเภท	21
รูปที่ 3.2 ขั้นตอนวิธี CBA ที่ไม่มีการตัดเสริมกฎความสัมพันธ์ของประเภท.....	23
รูปที่ 3.3 ต้นไม้ตัดสินใจในตัวอย่งการเรียนรู้แนวคิดผิวใหม่จากการอบแดด	25
รูปที่ 3.4 ต้นไม้ตัดสินใจในตัวอย่งการเรียนรู้แนวคิดการตัดสินใจเล่นเทนนิส.....	27
รูปที่ 3.5 โครงสร้างของแบ็กพรอปาเกชันนิวรอลเน็ตเวิร์กที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ ของประเภทในตัวอย่งการเรียนรู้แนวคิดการตัดสินใจเล่นเทนนิส	30
รูปที่ 3.6 โครงสร้างของแบ็กพรอปาเกชันนิวรอลเน็ตเวิร์กที่ใช้เพื่อจำแนกประเภทข้อมูล ในตัวอย่งการเรียนรู้แนวคิดการตัดสินใจเล่นเทนนิส.....	30
รูปที่ 3.7 ตัวอย่างการสร้างข้อมูลที่ใช้ในการเรียนรู้ของนิวรอลเน็ตเวิร์ก.....	31
รูปที่ 3.8 ค่าน้ำหนักเริ่มต้นที่กำหนดให้กับโครงสร้างของแบ็กพรอปาเกชันนิวรอลเน็ตเวิร์ก แบบเชื่อมต่ออย่างสมบูรณ์ที่ใช้ในตัวอย่งการเรียนรู้แนวคิดการตัดสินใจ เล่นเทนนิส	35

สารบัญตาราง

	หน้า
ตารางที่ 3.1 ข้อมูลที่ใช้ในตัวอย่างการเรียนรู้แนวคิดผิวใหม่จากการอาบแดด	24
ตารางที่ 3.2 ข้อมูลที่ใช้ในตัวอย่างการเรียนรู้แนวคิดการตัดสินใจเล่นเทนนิส	25
ตารางที่ 3.3 การนำนิรอลเน็ตเวิร์กมาประยุกต์ใช้กับการจำแนกประเภทข้อมูล.....	28
ตารางที่ 4.1 รายละเอียดของชุดข้อมูลที่ใช้ในการทดลอง	37
ตารางที่ 4.2 ผลลัพธ์ความแม่นยำของการจำแนกประเภทข้อมูลที่ได้จากการประยุกต์ใช้ แบ็กพรอพากชันนิรอลเน็ตเวิร์กเพื่อจำแนกประเภทจากกฎความสัมพันธ์ ของประเภท เปรียบเทียบกับวิธีการเรียนรู้ของเครื่องแบบ C4.5 ขั้นตอนวิธี CBA เดิม และ CPAR.....	39
ตารางที่ 4.3 การเปรียบเทียบผลลัพธ์ความแม่นยำด้วยค่าระดับความเชื่อมั่น ระหว่างนิรอลเน็ตเวิร์กที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภท ซึ่งเชื่อมต่อบางส่วน กับนิรอลเน็ตเวิร์กที่นำเสนอในงานวิจัยนี้แบบอื่นๆ วิธีการเรียนรู้ของเครื่องแบบ C4.5 ขั้นตอนวิธี CBA เดิม และ CPAR	40
ตารางที่ 4.4 การเปรียบเทียบผลลัพธ์ความแม่นยำด้วยค่าระดับความเชื่อมั่น ระหว่างนิรอลเน็ตเวิร์กที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภท ซึ่งเชื่อมต่อบางส่วน กับนิรอลเน็ตเวิร์กที่นำเสนอในงานวิจัยนี้แบบอื่นๆ วิธีการเรียนรู้ของเครื่องแบบ C4.5 ขั้นตอนวิธี CBA เดิม และ CPAR	41
ตารางที่ 4.5 การเปรียบเทียบผลลัพธ์ความแม่นยำด้วยค่าระดับความเชื่อมั่น ระหว่างนิรอลเน็ตเวิร์กที่ใช้เพื่อจำแนกประเภทข้อมูล ซึ่งเชื่อมต่อบางส่วน กับนิรอลเน็ตเวิร์กที่นำเสนอในงานวิจัยนี้แบบอื่นๆ วิธีการเรียนรู้ของเครื่อง แบบ C4.5 ขั้นตอนวิธี CBA เดิม และ CPAR	42
ตารางที่ 4.6 การเปรียบเทียบผลลัพธ์ความแม่นยำด้วยค่าระดับความเชื่อมั่น ระหว่างนิรอลเน็ตเวิร์กที่ใช้เพื่อจำแนกประเภทข้อมูล ซึ่งเชื่อมต่อบางส่วน กับนิรอลเน็ตเวิร์กที่นำเสนอในงานวิจัยนี้แบบอื่นๆ วิธีการเรียนรู้ของเครื่อง แบบ C4.5 ขั้นตอนวิธี CBA เดิม และ CPAR	43
ตารางที่ 4.7 ผลลัพธ์ความแม่นยำในการจำแนกประเภทข้อมูลของนิรอลเน็ตเวิร์กที่ใช้ เพื่อคัดเลือกกฎความสัมพันธ์ของประเภท ที่ได้จากการใช้กฎที่ตรงพอดีร่วมกับ กฎที่มีความเหมาะสมที่สุด เปรียบเทียบกับการใช้กฎที่ตรงพอดีเพียงอย่างเดียว...	47

	หน้า
ตารางที่ ก.1 ข้อมูลที่ใช้ในการค้นหาความสัมพันธภาพของประเภท.....	57
ตารางที่ ก.2 การค้นหาความสัมพันธภาพของประเภทตามขั้นตอนวิธี CBA.....	58
ตารางที่ ข.1 ผลลัพธ์ความแม่นยำของการจำแนกประเภทข้อมูลที่ได้จากแบ็กพรอพาทเกชัน นิเวรอลเน็ตเวิร์กที่ใช้เพื่อคัดเลือกความสัมพันธภาพของประเภท และใช้เพื่อจำแนก ประเภทข้อมูล ซึ่งกำหนดโครงสร้างจากความสัมพันธภาพของประเภท เปรียบเทียบ กับแบ็กพรอพาทเกชันนิเวรอลเน็ตเวิร์กที่กำหนดโครงสร้างจากชุดข้อมูล	61
ตารางที่ ข.2 การเปรียบเทียบผลลัพธ์ความแม่นยำด้วยค่าระดับความเชื่อมั่น ระหว่าง แบ็กพรอพาทเกชันนิเวรอลเน็ตเวิร์กที่ใช้เพื่อคัดเลือกความสัมพันธภาพของประเภท และใช้เพื่อจำแนกประเภทข้อมูล ซึ่งกำหนดโครงสร้างจากความสัมพันธภาพของ ประเภท เปรียบเทียบกับแบ็กพรอพาทเกชันนิเวรอลเน็ตเวิร์กที่กำหนดโครงสร้าง จากชุดข้อมูล	62

บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

ในปัจจุบัน งานวิจัยทางด้านการทำเหมืองข้อมูล (Data Mining) และการเรียนรู้ของเครื่อง (Machine Learning) ส่วนหนึ่ง มุ่งเน้นที่การพัฒนาตัวจำแนกประเภทข้อมูล (classifier) ให้มีความแม่นยำและมีประสิทธิภาพมากยิ่งขึ้น วิธีการเรียนรู้ของเครื่อง เช่น ต้นไม้ตัดสินใจ (Decision Tree) [1] การเรียนรู้จากกฎ (Rule Learning) [2] ตัวจำแนกประเภทเบย์อย่างง่าย (Naive-Bayes Classifier) [3] และวิธีการทางสถิติ [4] อาศัยเทคนิคการค้นหาแบบฮิวริสติก (heuristic search) หรือการค้นหาแบบตะกราม (greedy search) ในการค้นหาซับเซตของกฎ เพื่อนำไปใช้สร้างตัวจำแนกประเภทข้อมูล ซึ่งอาจจะทำให้กฎที่ค้นพบนั้น เป็นกฎที่ไม่น่าสนใจ หรือในทางกลับกัน กฎที่น่าสนใจหรือสามารถทำความเข้าใจได้ ไม่ถูกค้นพบ ส่งผลให้ตัวจำแนกประเภทข้อมูลที่ได้มีความแม่นยำลดน้อยลง [5]

Liu et al. [5] ได้นำเสนอวิธีการใหม่ เรียกว่า การจำแนกประเภทเชิงความสัมพันธ์ (Associative Classification) ซึ่งเป็นการนำสองเทคนิคที่สำคัญของการทำเหมืองข้อมูล คือ การจำแนกประเภทข้อมูล (Data Classification) [6] และการค้นหากฎความสัมพันธ์ (Association Rules Discovery) [7, 8] มารวมเข้าด้วยกัน กล่าวคือ เลือกรูปแบบความสัมพันธ์ของประเภทหรือคาร์ส (Class Association Rules: CARs) จำนวนหนึ่ง จากกฎความสัมพันธ์ของประเภททั้งหมดที่ได้จากกระบวนการค้นหากฎความสัมพันธ์ มาใช้ในการสร้างตัวจำแนกประเภทข้อมูล จากงานวิจัย [5, 9, 10] แสดงให้เห็นว่าตัวจำแนกประเภทข้อมูลที่ได้จากวิธีการจำแนกประเภทเชิงความสัมพันธ์ มีความแม่นยำสูงกว่าวิธีการเรียนรู้ของเครื่อง เช่น C4.5 [1] แต่เนื่องจากขั้นตอนวิธี (algorithm) ที่นำเสนอโดย Liu et al. ที่เรียกว่า CBA (Classification Based on Associations) จำเป็นต้องมีการเรียงอันดับ (ranking) กฎความสัมพันธ์ของประเภทก่อนนำไปใช้สร้างตัวจำแนกประเภทข้อมูล ซึ่งวิธีการเรียงอันดับนั้น ขึ้นอยู่กับค่าความเชื่อมั่น (confidence) และค่าสนับสนุน (support) ของแต่ละกฎความสัมพันธ์ของประเภท ทำให้ความแม่นยำของขั้นตอนวิธี CBA ต่ำกว่าขั้นตอนวิธีทางการจำแนกประเภทเชิงความสัมพันธ์ที่เกิดขึ้นในภายหลัง เช่น CMAR (Classification based on Multiple Association Rules) [9] และ CPAR (Classification based on Predictive Association Rules) [10]

อย่างไรก็ตาม ขั้นตอนวิธี CBA มีข้อดีคือ สามารถทำความเข้าใจได้ง่ายและถือเป็นต้นแบบของการจำแนกประเภทเชิงความสัมพันธ์ ในขณะที่นิวรอลเน็ตเวิร์ก (Neural Network) มีความสามารถในการจำแนกประเภทข้อมูลสูง และทนทานต่อข้อมูลรบกวน (noise) งานวิจัยนี้จึงมุ่งเน้นที่จะปรับปรุงขั้นตอนวิธี CBA ให้มีความแม่นยำสูงขึ้น โดยการประยุกต์ใช้นิวรอลเน็ตเวิร์กแทนการเรียงอันดับกฎความสัมพันธ์ของประเภท ในขั้นตอนการสร้างตัวจำแนกประเภทข้อมูล ข้อดีของวิธีการที่นำเสนอ คือ การนำความรู้ที่ค้นพบก่อนหน้านี้ในขั้นตอนการค้นหากฎความสัมพันธ์ของประเภท มาช่วยกำหนดโครงสร้างของนิวรอลเน็ตเวิร์กที่จะใช้ทำการเรียนรู้เพื่อสร้างตัวจำแนกประเภทข้อมูลสำหรับข้อมูลใหม่ที่ไม่ได้นำมาใช้ในการเรียนรู้ด้วยความแม่นยำที่มากยิ่งขึ้นได้

1.2 วัตถุประสงค์ของการวิจัย

1. เพื่อศึกษาการประยุกต์ใช้นิวรอลเน็ตเวิร์กกับขั้นตอนวิธี CBA เพื่อสร้างตัวจำแนกประเภทข้อมูล
2. เพื่อศึกษาเปรียบเทียบการนำนิวรอลเน็ตเวิร์กมาใช้ในการจำแนกประเภทเชิงความสัมพันธ์ใน 2 ลักษณะ คือ เพื่อคัดเลือกกฎความสัมพันธ์ของประเภทที่จะใช้จำแนกประเภทข้อมูล และเพื่อใช้จำแนกประเภทข้อมูลโดยตรง

1.3 ขอบเขตของการวิจัย

1. ใช้เครื่องมือ DM2 CBA ในการค้นหากฎความสัมพันธ์ของประเภทตามขั้นตอนวิธี CBA
2. ใช้เครื่องมือ Qnet for Windows V2K ในการเรียนรู้ของนิวรอลเน็ตเวิร์ก
3. ใช้ชุดข้อมูลจาก Department of Information and Computer Science, University of California, Irvine [11] จำนวนอย่างน้อย 10 ชุด เป็นข้อมูลในการทดสอบ
4. กำหนดให้ค่าสนับสนุนขั้นต่ำ = 1% และค่าความเชื่อมั่นขั้นต่ำ = 50% โดยอ้างอิงจากงานวิจัย [5] ซึ่งกล่าวไว้ว่า การกำหนดค่าสนับสนุนขั้นต่ำที่มีค่าสูงเกินไปจะส่งผลให้กฎความสัมพันธ์ของประเภท ที่มีค่าสนับสนุนน้อยกว่าค่าสนับสนุนขั้นต่ำแต่มีความเชื่อมั่นสูงไม่ถูกค้นพบ ทำให้กฎความสัมพันธ์ของประเภทที่ได้

ไม่ครอบคลุมชุดข้อมูลสอน อีกทั้งนิรอลเน็ตเวิร์กสามารถทำการเรียนรู้ได้อย่างมีประสิทธิภาพแม้ว่าชุดข้อมูลสอนจะมีข้อมูลรบกวน

5. เปรียบเทียบความถูกต้องของการจำแนกประเภทข้อมูลกับวิธีการเรียนรู้ของเครื่องแบบ C4.5 ขั้นตอนวิธี CBA เดิม และ CPAR

1.4 ขั้นตอนและวิธีดำเนินการวิจัย

1. ศึกษาแนวคิดและทฤษฎีการจำแนกประเภทเชิงความสัมพันธ์ ขั้นตอนวิธีที่ใช้ในการค้นหาความสัมพันธ์ของประเภท และนิรอลเน็ตเวิร์ก
2. ศึกษางานวิจัยที่เกี่ยวข้อง
3. เลือกชุดข้อมูลที่ใช้ในการทดสอบ และปรับให้อยู่ในรูปแบบที่สามารถนำมาทำการค้นหาความสัมพันธ์ของประเภทได้
4. นำชุดข้อมูลทดสอบมาค้นหาความสัมพันธ์ของประเภท
5. ออกแบบและพัฒนาโครงสร้างของนิรอลเน็ตเวิร์ก
6. พัฒนาเครื่องมือเพื่อปรับชุดข้อมูลให้สัมพันธ์กับความสัมพันธ์ของประเภทที่ได้ และอยู่ในรูปแบบที่นิรอลเน็ตเวิร์กสามารถนำไปใช้เพื่อทำการเรียนรู้ได้
7. ทดสอบวิธีการที่น่าเสนอ
8. พัฒนาเครื่องมือเพื่อแปลงความสัมพันธ์ของประเภทซึ่งเป็นผลลัพธ์จากการเรียนรู้ของนิรอลเน็ตเวิร์กให้เป็นฉลากประเภท และพัฒนาเครื่องมือเพื่อคำนวณผลลัพธ์ความแม่นยำของการจำแนกประเภทข้อมูล
9. วิเคราะห์และเปรียบเทียบผลการทดลองกับวิธีการเรียนรู้ของเครื่องแบบ C4.5 ขั้นตอนวิธี CBA เดิม และ CPAR
10. สรุปผลการวิจัยและจัดทำรายงานวิทยานิพนธ์

1.5 ประโยชน์ที่คาดว่าจะได้รับ

ได้ตัวจำแนกประเภทข้อมูลจากกฎความสัมพันธ์ของประเภทที่มีความแม่นยำมากยิ่งขึ้น จากการนำสองเทคนิคที่สำคัญของการทำเหมืองข้อมูล คือ การจำแนกประเภทข้อมูล และการค้นหากฎความสัมพันธ์ มารวมเข้าด้วยกัน

1.6 ลำดับการจัดเรียงเนื้อหาในวิทยานิพนธ์

วิทยานิพนธ์นี้แบ่งเนื้อหาออกเป็น 5 บทดังต่อไปนี้ บทที่ 1 เป็นบทนำซึ่งกล่าวถึงความเป็นมาและความสำคัญของปัญหา รวมถึงวัตถุประสงค์ของการวิจัย บทที่ 2 กล่าวถึงทฤษฎีพื้นฐานและงานวิจัยที่เกี่ยวข้องในงานวิจัยนี้ บทที่ 3 กล่าวถึงรายละเอียดทั้งหมดของการประยุกต์ใช้แบ็กพรอพาเกชันนิวรอลเน็ตเวิร์กเพื่อจำแนกประเภทจากกฎความสัมพันธ์ของประเภท บทที่ 4 แสดงรายละเอียดของการทดลองและผลการทดลอง และบทที่ 5 เป็นข้อสรุปและข้อเสนอแนะจากการวิจัย

1.7 ผลงานที่ตีพิมพ์จากวิทยานิพนธ์

ส่วนหนึ่งของวิทยานิพนธ์นี้ได้รับการตีพิมพ์เป็นบทความทางวิชาการในหัวข้อเรื่อง “การประยุกต์ใช้แบ็กพรอพาเกชันนิวรอลเน็ตเวิร์กเข้ากับการจำแนกประเภทเชิงความสัมพันธ์” โดย นภาพรณ ยิงชาญกุล และ ญาใจ ลิ้มปิยะภรณ์ ในงานประชุมวิชาการ “The 9th National Computer Science and Engineering Conference (NCSEC 2005)” ณ มหาวิทยาลัยหอการค้าไทย กรุงเทพมหานคร ระหว่างวันที่ 27-28 ตุลาคม 2548

สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

บทนี้จะแบ่งเนื้อหาออกเป็น 2 ส่วนด้วยกัน โดยเนื้อหาในส่วนแรกจะกล่าวถึงทฤษฎีและแนวคิดพื้นฐาน ซึ่งประกอบด้วย การจำแนกประเภทเชิงความสัมพันธ์ นิเวศน์เน็ตเวิร์ก และการเปรียบเทียบขั้นตอนวิธี และเนื้อหาในส่วนที่สองจะกล่าวถึงงานวิจัยที่เกี่ยวข้องกับงานวิจัยนี้

2.1 ทฤษฎีที่เกี่ยวข้อง

2.1.1 การจำแนกประเภทเชิงความสัมพันธ์

การจำแนกประเภทเชิงความสัมพันธ์ [5, 12, 13] เป็นการนำสองเทคนิคที่สำคัญของการทำเหมืองข้อมูล คือ การจำแนกประเภทข้อมูล และการค้นหากฎความสัมพันธ์ มารวมเข้าด้วยกัน กล่าวคือ

2.1.1.1 การจำแนกประเภทข้อมูล

การจำแนกประเภทข้อมูล เป็นรูปแบบหนึ่งของการเรียนรู้แบบสอน (supervised learning) โดยนำข้อมูลส่วนหนึ่งมาใช้สอนเพื่อให้ระบบทำการเรียนรู้ เรียกว่า ชุดข้อมูลสอน (training dataset) และนำข้อมูลอีกส่วนหนึ่งที่แตกต่างจากชุดข้อมูลสอนมาใช้ทำการทดสอบ เรียกว่า ชุดข้อมูลทดสอบ (test dataset) ผลลัพธ์ที่ได้จากการเรียนรู้ คือ ตัวจำแนกประเภทข้อมูล ซึ่งนำไปใช้ในการจำแนกข้อมูลใหม่เพื่อหาประเภทของข้อมูลใหม่ได้

2.1.1.2 การค้นหากฎความสัมพันธ์

การค้นหากฎความสัมพันธ์ เป็นการวิเคราะห์ความสัมพันธ์ที่แฝงอยู่ในข้อมูล จากฐานข้อมูลขนาดใหญ่ เพื่อบอกว่าไอเท็ม (item) ตัวหนึ่งๆ มีความสัมพันธ์กับไอเท็มตัวใดบ้าง โดยแสดงความสัมพันธ์ที่ได้ในรูปของกฎความสัมพันธ์ (Association Rule) กฎความสัมพันธ์ที่ได้ทั้งหมดจะต้องมีความน่าสนใจ โดยวัดจากค่าสนับสนุนและค่าความเชื่อมั่น กล่าวคือ มีค่าสนับสนุนไม่น้อยกว่าค่าสนับสนุนขั้นต่ำ (minimum support) และมีค่าความเชื่อมั่นไม่น้อยกว่าค่าความเชื่อมั่นขั้นต่ำ (minimum confidence) ที่ผู้ใช้กำหนดไว้ ค่าจำกัดความที่เกี่ยวข้องมีดังต่อไปนี้

กำหนดให้

$D = \{d_1, d_2, \dots, d_n\}$ คือ ฐานข้อมูลซึ่งประกอบด้วยเซตของข้อมูล n ตัว
โดย $d \subseteq I$

$I = \{i_1, i_2, \dots, i_m\}$ คือ เซตของไอเท็มทั้งหมดที่ปรากฏใน D

กฎความสัมพันธ์ที่ได้จากกระบวนการค้นหากฎความสัมพันธ์ มีรูปแบบดังต่อไปนี้

$A \rightarrow B$	ค่าสนับสนุน = $s\%$, ค่าความเชื่อมั่น = $c\%$ โดยที่ $A, B \subseteq I$ และ $A \cap B = \emptyset$
-------------------	--

โดย ค่าสนับสนุน คือ ความถี่ของจำนวนข้อมูลทั้งหมดที่ประกอบด้วย A และ B
หรือ $P(A \cup B)$

ค่าความเชื่อมั่น คือ ความถี่ของจำนวนข้อมูลที่เมื่อประกอบด้วย A แล้ว
ประกอบด้วย B ด้วย หรือ $P(B|A)$

ค่าสนับสนุนและค่าความเชื่อมั่น มักแสดงเป็นค่าร้อยละ

2.1.1.3 การค้นหากฎความสัมพันธ์ของประเภท

กฎความสัมพันธ์ของประเภท คือ กฎความสัมพันธ์ที่ได้จากกระบวนการค้นหา
กฎความสัมพันธ์จากชุดข้อมูลเข้าที่มีการระบุประเภท (class) ของข้อมูล เพื่อบอกถึง
ความสัมพันธ์ของไอเท็มเซต (itemset) หรือคุณลักษณะ (attribute) ที่มีต่อประเภทของข้อมูลนั้นๆ
กฎความสัมพันธ์ของประเภทที่ได้ทั้งหมดจะต้องมีค่าสนับสนุนไม่น้อยกว่าค่าสนับสนุนขั้นต่ำ
และมีค่าความเชื่อมั่นไม่น้อยกว่าค่าความเชื่อมั่นขั้นต่ำที่ผู้ใช้กำหนดไว้ ค่าจำกัดความที่เกี่ยวข้อง
มีดังต่อไปนี้

กำหนดให้

$D = \{d_1, d_2, \dots, d_i\}$ คือ ฐานข้อมูลซึ่งประกอบด้วยเซตของข้อมูลที่มี
คุณลักษณะ n ตัว และฉลากประเภท (class label)
โดย $d = \{a_1, a_2, \dots, a_n, y_k\}; k = 1, \dots, m$

$I = \{X_1, X_2, \dots, X_j\}$ คือ เซตของไอเท็มเซตทั้งหมดที่ปรากฏใน D

$Y = \{y_1, y_2, \dots, y_m\}$ คือ เซตของฉลากประเภทจำนวน m ประเภท

กฎความสัมพันธ์ของประเภทที่ได้จากกระบวนการค้นหากฎความสัมพันธ์ มีรูปแบบดังต่อไปนี้

$X \rightarrow y$	ค่าสนับสนุน = $s\%$, ค่าความเชื่อมั่น = $c\%$ โดยที่ $X \subseteq I$ และ $y \in Y$
-------------------	--

โดย ค่าสนับสนุน คือ ความถี่ของจำนวนข้อมูลทั้งหมดที่ประกอบด้วยไอเท็มเซต X และมีฉลากประเภทเป็น y

ค่าความเชื่อมั่น คือ ความถี่ของจำนวนข้อมูลที่เมื่อประกอบด้วยไอเท็มเซต X แล้ว มีฉลากประเภทเป็น y ด้วย

ค่าสนับสนุนและค่าความเชื่อมั่น มักแสดงเป็นค่าร้อยละ

2.1.1.4 การค้นหากฎความสัมพันธ์ของประเภทตามขั้นตอนวิธี CBA

การค้นหาความสัมพันธ์ของประเภทตามขั้นตอนวิธี CBA มีแนวคิดมาจากขั้นตอนวิธี Apriori [8] ซึ่งเป็นขั้นตอนวิธีพื้นฐานที่ใช้ในการค้นหาความสัมพันธ์ของข้อมูล คำจำกัดความที่เกี่ยวข้องมีดังต่อไปนี้

กำหนดให้

ruleitem มีรูปแบบ คือ $\langle (\text{condset}, \text{condsupCount}), (y, \text{rulesupCount}) \rangle$
ซึ่งใช้แทนกฎความสัมพันธ์ของประเภท $\text{condset} \rightarrow y$ โดยที่
 condset คือ ไอเท็มเซต และ $y \in Y$

k -ruleitem คือ ruleitem ที่ condset ประกอบด้วยสมาชิก k ตัว

condsupCount คือ จำนวนข้อมูลทั้งหมดที่ประกอบด้วย condset

rulesupCount คือ จำนวนข้อมูลทั้งหมดที่ประกอบด้วย condset และมีฉลากประเภทเป็น y

ดังนั้น จะได้ว่า ค่าสนับสนุน $= (\text{rulesupCount} / |D|) * 100\%$

ค่าความเชื่อมั่น $= (\text{rulesupCount} / \text{condsupCount}) * 100\%$

ขั้นตอนวิธี CBA ที่ใช้ในการค้นหากฎความสัมพันธ์ของประเภท สามารถแสดงได้ดังรูปที่ 2.1

```

1   F1 = {large 1-ruleitems};
2   CAR1 = genRules(F1);
3   prCAR1 = pruneRules(CAR1);
4   for (k = 2; Fk-1 ≠ ∅; k++) do
5       Ck = candidateGen(Fk-1);
6       for each data case d ∈ D do
7           Cd = ruleSubset(Ck, d);
8           for each candidate c ∈ Cd do
9               c.condsupCount++;
10              if d.class = c.class then c.rulesupCount++
11              end
12          end
13          Fk = {c ∈ Ck | c.rulesupCount ≥ minsup};
14          CARk = genRules(Fk);
15          prCARk = pruneRules(CARk);
16      end
17      CARs = ∪k CARk;
18      prCARs = ∪k prCARk;

```

รูปที่ 2.1 ขั้นตอนวิธี CBA ที่ใช้ในการค้นหากฎความสัมพันธ์ของประเภท

จากรูปที่ 2.1 ขั้นตอนวิธี CBA ประกอบด้วยการทำงาน 3 ส่วน ซึ่งมีรายละเอียดดังต่อไปนี้

1. การค้นหาขุมทรัพย์บ่อย (frequent rule items)

ขุมทรัพย์บ่อย คือ ขุมทรัพย์ที่มีค่าสนับสนุนไม่น้อยกว่าค่าสนับสนุนขั้นต่ำที่ผู้ใช้กำหนดไว้ ซึ่งการค้นหาขุมทรัพย์บ่อยของขั้นตอนวิธี CBA มีขั้นตอนการทำงานเช่นเดียวกันกับการค้นหาเซตของขุมทรัพย์บ่อย (frequent itemsets) ของขั้นตอนวิธี Apriori

2. การสร้างกฎความสัมพันธ์ของประเภท

นำขุมทรัพย์บ่อย ซึ่งมีรูปแบบ $\langle (\text{condset}, \text{condsupCount}), (y, \text{rulesupCount}) \rangle$ ที่ได้จากข้อ 1. ที่มีค่าความเชื่อมั่นมากกว่าหรือเท่ากับค่าความเชื่อมั่นขั้นต่ำที่ผู้ใช้กำหนดไว้ มาแปลงให้อยู่ในรูปของกฎความสัมพันธ์ของประเภท ซึ่งมีรูปแบบ $\text{condset} \rightarrow y$ ในกรณีที่ขุมทรัพย์มี condset เหมือนกัน จะทำการเลือกขุมทรัพย์ที่มีค่าความเชื่อมั่นมากที่สุด และเรียกขุมทรัพย์นั้นๆ ว่ากฎที่เป็นไปได้ (possible rule) เช่น

$$\langle \{(A, 1), (B, 1)\}, (\text{class}: 1) \rangle \dots\dots\dots (1)$$

$$\langle \{(A, 1), (B, 1)\}, (\text{class}: 2) \rangle \dots\dots\dots (2)$$

กำหนดให้ $|D|$ มีค่าเท่ากับ 10, ค่าสนับสนุนของ condset มีค่าเท่ากับ 3, ค่าสนับสนุนของขุมทรัพย์ที่ 1 และ 2 มีค่าเท่ากับ 2 และ 1 ตามลำดับ ดังนั้น ค่าความเชื่อมั่นของขุมทรัพย์ที่ 1 จึงมีค่าเป็น 66.7% และค่าความเชื่อมั่นของขุมทรัพย์ที่ 2 มีค่าเป็น 33.3% และได้กฎที่เป็นไปได้คือ $(A, 1), (B, 1) \rightarrow (\text{class}: 1)$ ซึ่งมีค่าสนับสนุนเท่ากับ 20% และมีค่าความเชื่อมั่นเท่ากับ 66.7%

ในกรณีที่ขุมทรัพย์มี condset เหมือนกัน และมีค่าความเชื่อมั่นเท่ากัน จะทำการเลือกกฎที่เป็นไปได้แบบสุ่ม (random)

3. การตัดเล็ม (pruning) กฎความสัมพันธ์ของประเภท

การตัดเล็มกฎความสัมพันธ์ของประเภทของขั้นตอนวิธี CBA ใช้วิธีการ pessimistic error rate based pruning เช่นเดียวกันกับที่ใช้ใน C4.5 ซึ่งมีหลักการว่า ถ้ากฎ r' ที่ได้จากการตัดเงื่อนไขของกฎ r ออกไป 1 เงื่อนไข มีค่า pessimistic error rate ต่ำกว่าค่า pessimistic error rate ของกฎ r แล้ว จะทำการตัดเล็มกฎ r

หลังจากเสร็จสิ้นการทำงานทั้ง 3 ส่วนของขั้นตอนวิธี CBA แล้ว จะได้กฎความสัมพันธ์ของประเภทจำนวนหนึ่ง ซึ่งสามารถนำไปใช้สร้างตัวจำแนกประเภทข้อมูลต่อไป ตัวอย่างของการค้นหาความสัมพันธ์ของประเภทตามขั้นตอนวิธี CBA สามารถศึกษาเพิ่มเติมได้จากภาคผนวก ก

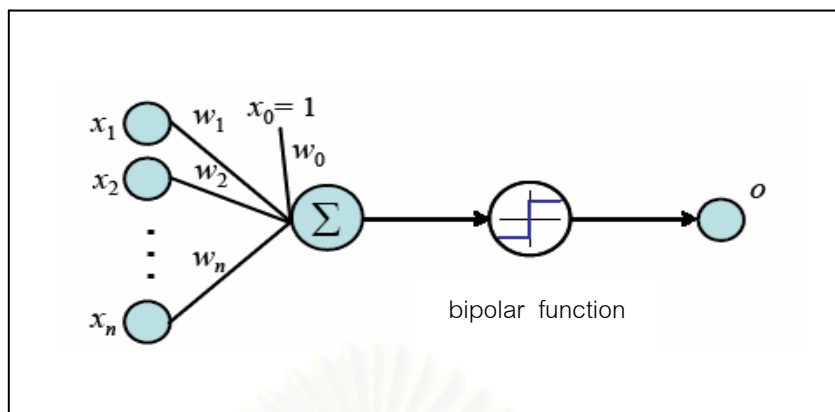
2.1.2 นิวรอลเน็ตเวิร์ก

นิวรอลเน็ตเวิร์กเทียม (Artificial Neural Network) [3, 14] เป็นวิธีการเรียนรู้ของเครื่องรูปแบบหนึ่ง ซึ่งมีแนวคิดมาจากการจำลองการทำงานบางส่วนของสมองมนุษย์ มีลักษณะเป็นเซลล์ประสาท (neuron) หลายๆ เซลล์มาเชื่อมต่อกัน โดยเดนไดรต์ (dendrite) ทำหน้าที่รับสัญญาณไฟฟ้าเคมีจากเซลล์ประสาทใกล้เคียง และเมื่อเซลล์ถูกกระตุ้นจะทำการส่งสัญญาณต่อไปยังเซลล์อื่นๆ ผ่านทางแอกซอน (axon) ดังนั้น นิวรอลเน็ตเวิร์กที่จำลองการทำงานเหล่านี้จึงประกอบไปด้วยโนด (node) จำนวนหนึ่งมาเชื่อมต่อกัน โดยมีค่าน้ำหนัก (weight) ค่าหนึ่งในการเชื่อมต่อ โครงสร้างของนิวรอลเน็ตเวิร์กจะแบ่งออกเป็นชั้นๆ (layer) โดยที่แต่ละชั้นจะประกอบด้วยจำนวนโนดที่แตกต่างกันออกไปตามความเหมาะสมของการทำงาน การแบ่งประเภทของนิวรอลเน็ตเวิร์กจะแบ่งตามจำนวนชั้นของการทำงาน ซึ่งสามารถแบ่งออกได้เป็น 2 ประเภท คือ แบบข่ายงานประสาทชั้นเดียว (single layer neural network) และข่ายงานประสาทหลายชั้น (multilayer neural network)

2.1.2.1 เพอร์เซปตรอน (perceptron)

เพอร์เซปตรอน เป็นนิวรอลเน็ตเวิร์กเทียมแบบข่ายงานประสาทชั้นเดียวที่มีหน่วยเล็กที่สุด กล่าวคือ โครงสร้างของเพอร์เซปตรอนแต่ละตัว จะมีจำนวนชั้นของโนดเพียง 2 ชั้นเท่านั้น โดยชั้นแรกเป็นชั้นที่ทำหน้าที่รับข้อมูลเพื่อนำมาใช้ทำการเรียนรู้ เรียกว่า ชั้นอินพุต (input layer) ส่วนอีกชั้นหนึ่งเป็นชั้นที่ใช้แสดงผลที่ได้เมื่อเสร็จสิ้นกระบวนการเรียนรู้แล้ว เรียกว่า ชั้นเอาต์พุต (output layer)

รูปที่ 2.2 แสดงเพอร์เซปตรอนที่ใช้ฟังก์ชันสองขั้ว (bipolar function) เป็นฟังก์ชันกระตุ้น (activation function) โดยการทำงานจะเริ่มต้นจากการรับข้อมูลซึ่งเป็นเวกเตอร์ของจำนวนจริงมาคำนวณหาค่าผลรวมเชิงเส้น (linear combination) จากนั้นนำค่าผลรวมที่คำนวณได้มาเปรียบเทียบกับค่าขีดแบ่ง (threshold) ที่กำหนดไว้ โดยถ้าค่าผลรวมมีค่ามากกว่าค่าขีดแบ่งนั้นๆ เพอร์เซปตรอนจะให้ผลลัพธ์เป็น “1” แต่ถ้าค่าผลรวมที่ได้มีค่าน้อยกว่า ก็จะให้ผลลัพธ์เป็น “-1”



รูปที่ 2.2 เพอร์เซปตรอนที่ใช้ฟังก์ชันสองขั้วเป็นฟังก์ชันกระตุ้น


นอกจากฟังก์ชันสองขั้วแล้ว ฟังก์ชันไบนารี (binary function) ซึ่งให้ผลลัพธ์เป็น “1” และ “0” ก็เป็นฟังก์ชันกระตุ้นอีกแบบหนึ่งที่เพอร์เซปตรอนนิยมนำมาใช้ในกระบวนการเรียนรู้เช่นกัน

เมื่อพิจารณาระนาบตัดตัดสินใจ (decision surface) ของเพอร์เซปตรอน จะเห็นว่าการใช้ฟังก์ชันกระตุ้นที่มีลักษณะดังกล่าวข้างต้น ทำให้ระนาบตัดตัดสินใจที่มีลักษณะเป็นเส้นตรง ดังนั้นเพอร์เซปตรอนจึงสามารถนำมาใช้ทำการเรียนรู้ฟังก์ชันแยกได้เชิงเส้น (linearly separable function) เช่น ฟังก์ชัน AND และ OR ได้ ส่วนฟังก์ชันแยกไม่ได้เชิงเส้น (linearly non-separable function) เช่น ฟังก์ชัน XOR เพอร์เซปตรอนจะไม่สามารถทำการเรียนรู้ได้สำเร็จ

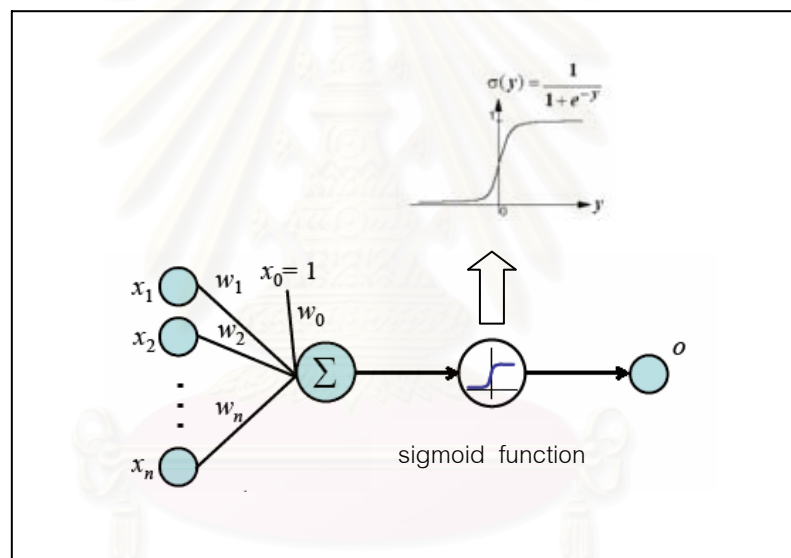
2.1.2.2 แแบ็กพรอพาเกชันนิวรอลเน็ตเวิร์ก (Backpropagation Neural Network)

แบ็กพรอพาเกชันนิวรอลเน็ตเวิร์ก เป็นรูปแบบหนึ่งของข่ายงานประสาทหลายชั้นที่นำเพอร์เซปตรอนหลายๆ ตัวมาเชื่อมต่อกัน และใช้ขั้นตอนวิธีแบ็กพรอพาเกชัน (backpropagation algorithm) ในการปรับค่าน้ำหนัก โครงสร้างของแบ็กพรอพาเกชันนิวรอลเน็ตเวิร์กประกอบด้วย 3 ส่วน ได้แก่ ชั้นอินพุต ซึ่งเป็นชั้นแรกของเน็ตเวิร์ก ถัดไปเป็นชั้นฮิดเดน (hidden layer) โดยที่ชั้นฮิดเดนสามารถมีได้มากกว่า 1 ชั้น และชั้นเอาต์พุต ซึ่งเป็นชั้นที่แสดงผลลัพธ์ของเน็ตเวิร์ก ดังแสดงในรูปที่ 2.3

ดังกล่าวข้างต้นว่า เพอร์เซปตรอนที่ใช้ฟังก์ชันกระตุ้นแบบฟังก์ชันสองขั้วหรือฟังก์ชันไบนารี สามารถเรียนรู้ฟังก์ชันแยกได้เชิงเส้นเท่านั้น ดังนั้น เพื่อเพิ่มความสามารถในการเรียนรู้ของแบ็กพรอพาเกชันนิวรอลเน็ตเวิร์ก จึงนำฟังก์ชันกระตุ้นอีกแบบหนึ่ง เรียกว่า ฟังก์ชันซิกมอยด์ (sigmoid function) ซึ่งให้ระนาบตัดตัดสินใจที่ไม่ใช่เชิงเส้น มาใช้ในกระบวนการเรียนรู้แทนเพอร์เซปตรอนที่ใช้ฟังก์ชันซิกมอยด์เป็นฟังก์ชันกระตุ้น สามารถแสดงได้ดังรูปที่ 2.4



รูปที่ 2.3 โครงสร้างของแบ็กพรอพพาเกชันนิวรอลเน็ตเวิร์ก



รูปที่ 2.4 เพอร์เซปตรอนที่ใช้ฟังก์ชันซิกมอยด์เป็นฟังก์ชันกระตุ้น

ข้อดีของฟังก์ชันซิกมอยด์ คือ เป็นฟังก์ชันที่สามารถแสดงอนุพันธ์ในรูปของเอาต์พุตได้โดยง่าย ซึ่งเป็นลักษณะที่ต้องการของการเรียนรู้แบบแบ็กพรอพพาเกชันนิวรอลเน็ตเวิร์ก นอกจากนี้ ฟังก์ชันซิกมอยด์ยังให้ผลลัพธ์จากการเรียนรู้เป็นค่าต่อเนื่อง (continuous) ที่มีค่าอยู่ระหว่าง “0” ถึง “1” จึงทำให้สามารถเรียนรู้ฟังก์ชันแยกไม่ได้เชิงเส้นได้สำเร็จด้วย ค่าเอาต์พุตของนิวรอลเน็ตเวิร์กที่ใช้ฟังก์ชันซิกมอยด์เป็นฟังก์ชันกระตุ้น สามารถนิยามได้ดังต่อไปนี้

$$\text{Output} = \sigma(\text{net}) = \frac{1}{1 + e^{-\text{net}}} \quad \text{โดยที่} \quad \text{net} = \sum_{i=0}^n (w_i x_i)$$

วิธีการเรียนรู้แบบแบ็กพรอพาเกชันนิรลเน็ตเวิร์ก เป็นการเรียนรู้เพื่อปรับค่าน้ำหนักของเน็ตเวิร์กให้มีค่าผิดพลาดการสอน (training error) น้อยที่สุด กล่าวคือ เมื่อเน็ตเวิร์กได้รับข้อมูลเข้ามา จะทำการคำนวณค่าเอาต์พุตจริง (actual output) ของเน็ตเวิร์ก เพื่อเปรียบเทียบกับค่าเอาต์พุตเป้าหมาย (target output) ถ้าค่าน้ำหนักเหล่านี้ทำให้ค่าความผิดพลาดมีค่ามากเกินไปกว่าที่กำหนดไว้ เน็ตเวิร์กก็จะนำค่าความผิดพลาดที่คำนวณได้แพร่ย้อนกลับจากชั้นเอาต์พุตไปยังชั้นฮิดเดนและชั้นอินพุตเพื่อทำการปรับค่าน้ำหนักต่อไป และทำการวนซ้ำการทำงานไปจนกระทั่งค่าความผิดพลาดมีค่าน้อยที่สุดหรืออยู่ในเกณฑ์ที่ยอมรับได้จึงหยุดการทำงาน

กำหนดให้ข้อมูลที่ใช้ในการเรียนรู้ มีรูปแบบ คือ (\vec{x}, \vec{t})

โดย \vec{x} คือ เวกเตอร์อินพุตของเน็ตเวิร์ก

\vec{t} คือ เวกเตอร์เป้าหมายของเอาต์พุตในเน็ตเวิร์ก

x_{ji} คือ อินพุตขององค์ประกอบ j ซึ่งมาจากองค์ประกอบ i

w_{ji} คือ ค่าน้ำหนักขององค์ประกอบ j ซึ่งมาจากองค์ประกอบ i

และ η คือ ค่าอัตราการเรียนรู้ (learning rate)

การปรับค่าน้ำหนักในระบบแบ็กพรอพาเกชันนิรลเน็ตเวิร์กประกอบด้วยขั้นตอนดังต่อไปนี้

1. กำหนดจำนวนชั้นของเน็ตเวิร์ก จำนวนโนดในแต่ละชั้น และการเชื่อมโยงกันของโนดต่างๆ ตามโครงสร้างที่ต้องการ
2. กำหนดค่าน้ำหนักเริ่มต้นแบบสุ่มให้มีค่าน้อยๆ (เช่น ระหว่าง -0.05 ถึง 0.05)
3. สำหรับ (\vec{x}, \vec{t}) แต่ละตัว ให้ทำการปรับค่าน้ำหนักด้วยขั้นตอนวิธีต่อไปนี้ จนกระทั่งค่าความผิดพลาดมีค่าน้อยกว่าที่กำหนดไว้ หรือจำนวนรอบการสอน (epoch) เกินกว่าที่กำหนดไว้

- ใช้ \vec{x} เป็นอินพุตให้กับเน็ตเวิร์ก และคำนวณค่าเอาต์พุต O ของทุกโนดในเน็ตเวิร์ก

- คำนวณค่าความผิดพลาด δ_k ของทุกโหนด k ในชั้นเอาต์พุตจาก

$$\delta_k \leftarrow o_k (1 - o_k)(t_k - o_k)$$

- คำนวณค่าความผิดพลาด δ_h ของทุกโหนด h ในชั้นฮิดเดนที่แพร่ย้อนกลับจากชั้นเอาต์พุต จาก

$$\delta_h \leftarrow o_h(1 - o_h) \sum_{k \in \text{outputs}} w_{kh} \delta_k$$

- ทำการปรับค่าน้ำหนัก w_{ji}

$$\text{โดย } w_{ji} \leftarrow w_{ji} + \Delta w_{ji} \quad \text{เมื่อ } \Delta w_{ji} = \eta \delta_j x_{ji}$$

2.1.3 การเปรียบเทียบขั้นตอนวิธี

ในการเปรียบเทียบขั้นตอนวิธีการเรียนรู้สองวิธี ว่าวิธีการใดมีประสิทธิภาพที่ดีกว่า Dietterich [15] ได้เสนอวิธีการเปรียบเทียบโดยดูจากค่าระดับความเชื่อมั่น (confidence level) ซึ่งมีวิธีการดังต่อไปนี้

สมมติว่า ในที่นี้จะทำการเปรียบเทียบระหว่างขั้นตอนวิธี A และขั้นตอนวิธี B

1. แบ่งชุดข้อมูล D_0 ออกเป็น k ส่วนเท่าๆ กัน ทำให้ได้เซตย่อย (subset) T_1, T_2, \dots, T_k
2. กำหนดให้ i มีค่าเป็น 1 ถึง k

- $S_i \leftarrow \{D_0 - T_i\}$

หมายความว่า ในการทดสอบครั้งที่ i กำหนดให้ T_i เป็นชุดข้อมูลทดสอบ และข้อมูลที่เหลือเป็นชุดข้อมูลสอน S_i

- $h_A \leftarrow L_A(S_i)$

หมายความว่า นำชุดข้อมูลสอน S_i มาทำการเรียนรู้ด้วยขั้นตอนวิธี A ซึ่งแทนด้วย $L_A(S_i)$ และได้ผลลัพธ์เป็นสมมติฐาน (hypothesis) h_A

$$- h_B \leftarrow L_B(S_i)$$

หมายความว่า นำชุดข้อมูลสอน S_i มาทำการเรียนรู้ด้วยขั้นตอนวิธี B ซึ่งแทนด้วย $L_B(S_i)$ และได้ผลลัพธ์เป็นสมมติฐาน h_B

$$- \delta_i \leftarrow \text{error}_{T_i}(h_A) - \text{error}_{T_i}(h_B)$$

หมายความว่า นำชุดข้อมูลทดสอบ T_i มาทำการทดสอบกับทั้งสองขั้นตอนวิธี จากนั้นคำนวณค่าความแตกต่าง δ_i ระหว่างค่าความผิดพลาดของขั้นตอนวิธี A ซึ่งแทนด้วย $\text{error}_{T_i}(h_A)$ และค่าความผิดพลาดของขั้นตอนวิธี B ซึ่งแทนด้วย $\text{error}_{T_i}(h_B)$

3. คำนวณค่าเฉลี่ยของความผิดพลาด $\bar{\delta}$ จาก

$$\bar{\delta} \equiv \frac{1}{k} \sum_{i=1}^k \delta_i$$

เมื่อได้ค่า $\bar{\delta}$ แล้ว สามารถนำมาคำนวณค่าระดับความเชื่อมั่นว่ามีนัยสำคัญทางสถิติ ที่ที่เปอร์เซ็นต์ได้จากช่วงความเชื่อมั่น (confidence interval)

$$\bar{\delta} \pm t_{N,k-1} S_{\bar{\delta}}$$

โดย $t_{N,k-1}$ เป็นค่าคงที่ซึ่งได้จากตารางแจกแจงแบบที (Student's t-Distribution) ที่ระดับความเชื่อมั่นเท่ากับ $N\%$ และค่าองศาเสรี (degrees of freedom) เท่ากับ $k-1$ และ $S_{\bar{\delta}}$ มีค่าเป็น

$$S_{\bar{\delta}} \equiv \sqrt{\frac{1}{k(k-1)} \sum_{i=1}^k (\delta_i - \bar{\delta})^2}$$

ในเชิงสถิติทั่วไป ค่าระดับความเชื่อมั่น [16] จะมีค่าเป็น $(1 - \alpha) 100\%$ โดย α คือโอกาสที่ผลสรุปที่ได้จากการทดสอบจะเกิดความผิดพลาด หรือเรียกอีกอย่างหนึ่งว่า ระดับนัยสำคัญ ดังนั้น จากการเปรียบเทียบข้างต้น ค่าระดับความเชื่อมั่นที่คำนวณได้ จึงแสดงให้เห็นว่าโอกาสที่ขั้นตอนวิธี A จะมีประสิทธิภาพดีกว่า (ดีกว่า) ขั้นตอนวิธี B อย่างมีนัยสำคัญ โดยมีค่าเฉลี่ยของความผิดพลาดอยู่ในช่วงความเชื่อมั่นที่คำนวณได้ จะมีค่าเท่ากับ $(1 - \alpha) 100\%$ และโอกาสที่การเปรียบเทียบขั้นตอนวิธีดังกล่าวจะเกิดความผิดพลาด จะมีค่าเท่ากับ α (100%)

2.2 งานวิจัยที่เกี่ยวข้อง

2.2.1 “Integrating Classification and Association Rule Mining” [5]

งานวิจัยนี้นำเสนอวิธีการใหม่ที่เรียกว่า การจำแนกประเภทเชิงความสัมพันธ์ โดยนำเทคนิคการจำแนกประเภทข้อมูลและการค้นหากฎความสัมพันธ์มารวมเข้าด้วยกัน ขั้นตอนวิธีที่นำเสนอในงานวิจัยนี้มีชื่อว่า CBA (Classification Based on Associations) ซึ่งอาศัยขั้นตอนวิธี Apriori ในการค้นหากฎความสัมพันธ์ของประเภท จากนั้นนำกฎความสัมพันธ์ของประเภทที่ได้มาทำการเรียงอันดับตามการทำก่อน (precedence) ซึ่งพิจารณาจากค่าความเชื่อมั่นและค่าสนับสนุน โดยมีนิยาม คือ r_i precedence r_j หรือ $r_i > r_j$ ก็ต่อเมื่อ

1. r_i มีค่าความเชื่อมั่นมากกว่า r_j
2. ถ้า r_i และ r_j มีค่าความเชื่อมั่นเท่ากันแล้ว r_i ต้องมีค่าสนับสนุนมากกว่า r_j
3. ถ้า r_i และ r_j มีค่าความเชื่อมั่นและค่าสนับสนุนเท่ากันแล้ว r_i ต้องถูกสร้างขึ้นมาก่อน r_j

กฎความสัมพันธ์ของประเภทที่ผ่านการเรียงอันดับแล้วจะถูกนำมาทดสอบกับชุดข้อมูลสอน เพื่อค้นหาเซตของกฎความสัมพันธ์ของประเภทที่มีค่าความผิดพลาดโดยรวมน้อยที่สุด และนำไปใช้ในการจำแนกประเภทข้อมูลต่อไป

ผลการทดลองแสดงให้เห็นว่า ตัวจำแนกประเภทข้อมูลที่ได้จากวิธีการจำแนกประเภทเชิงความสัมพันธ์ มีความแม่นยำสูงกว่าวิธีการเรียนรู้ของเครื่อง เช่น C4.5 จึงทำให้มีงานวิจัยทางด้านการจำแนกประเภทเชิงความสัมพันธ์เกิดขึ้นอีกมากมายในเวลาต่อมา

อย่างไรก็ตาม งานวิจัย [9] กล่าวว่า ขั้นตอนวิธี CBA มีข้อจำกัดคือ การเรียงอันดับกฎความสัมพันธ์ของประเภทตามการทำก่อน มักจะส่งผลให้การจำแนกประเภทข้อมูลมีความแม่นยำลดน้อยลง เช่น การตัดสินใจอนุมัติสินเชื่อให้กับลูกค้า โดยพิจารณาจากคุณลักษณะ no_job , $investment_immigrant$ และ $oversea_asset \geq 500k$ กฎความสัมพันธ์ของประเภทที่มีค่าความเชื่อมั่นสูงสุด 3 อันดับและนำมาใช้ในการจำแนกประเภทข้อมูล คือ

R_1 : no_job	→	credit_limit_3000 ⁻	ค่าสนับสนุน = 3000 ค่าความเชื่อมั่น = 95%
R_2 : investment_immigrant	→	credit_limit_3000 ⁺	ค่าสนับสนุน = 5000 ค่าความเชื่อมั่น = 93%
R_3 : oversea_asset \geq 500k	→	credit_limit_3000 ⁺	ค่าสนับสนุน = 8000 ค่าความเชื่อมั่น = 91%

จากกฎความสัมพันธ์ของประเภทข้างต้น ลูกค้ำที่มีคุณลักษณะ no_job แต่มี oversea_asset \geq 500k ควรจะได้รับ credit_limit_3000⁺ แต่ขั้นตอนวิธี CBA จะให้ผลลัพธ์เป็น credit_limit_3000⁻ เนื่องจากใช้ R_1 ซึ่งมีค่าความเชื่อมั่นสูงที่สุดในการจำแนกประเภทข้อมูล เมื่อพิจารณา R_2 และ R_3 จะพบว่ากฎทั้ง 2 ข้อมีค่าความเชื่อมั่นใกล้เคียงกันกับ R_1 แต่มีค่าสนับสนุนสูงกว่า R_1 มาก ดังนั้นการใช้ R_2 และ R_3 ในการจำแนกประเภทข้อมูล จึงมีความสมเหตุสมผลมากกว่าการใช้ R_1

2.2.2 “CMAR: Accurate and Efficient Classification Based on Multiple Class-Association Rules” [9]

งานวิจัยนี้เป็นงานวิจัยทางด้าน การจำแนกประเภทเชิงความสัมพันธ์ที่เกิดขึ้นหลังจากงานวิจัยที่ 2.2.1 ขั้นตอนวิธีที่นำเสนอในงานวิจัยนี้ประยุกต์ใช้โครงสร้างข้อมูลประเภท Frequent Pattern Tree หรือ FP-Tree [17] ซึ่งมีประสิทธิภาพในการค้นหาเซตของไอเท็มปรากฏบ่อยมากกว่าขั้นตอนวิธี Apriori เนื่องจากไม่จำเป็นต้องมีการค้นหา candidate itemsets และทำการอ่านข้อมูลจากฐานข้อมูลเพียง 2 ครั้ง ให้สามารถนำมาใช้ในการค้นหากฎความสัมพันธ์ของประเภทได้ จากนั้นนำกฎความสัมพันธ์ของประเภทที่ได้มาทำการเรียงอันดับตามการทำก่อน โดยกฎความสัมพันธ์ของประเภทที่มีค่า Chi-square (χ^2) มากที่สุดจะถูกใช้ในการจำแนกประเภทข้อมูล

2.2.3 “CPAR: Classification based on Predictive Association Rules” [10]

งานวิจัยนี้เป็นงานวิจัยทางการจำแนกประเภทเชิงความสัมพันธ์อีกงานหนึ่งที่เกิดขึ้นหลังจากงานวิจัยที่ 2.2.1 และ 2.2.2 ขั้นตอนวิธีที่น่าเสนอในงานวิจัยนี้ นำแนวคิดของขั้นตอนวิธี FOIL [3, 18] มาใช้ในการค้นหากฎความสัมพันธ์ของประเภท โดยขั้นตอนวิธี CPAR แตกต่างจากขั้นตอนวิธี FOIL คือ เมื่อตัวอย่างบวก (positive examples) ถูกครอบคลุม (cover) ด้วยกฎแล้ว ตัวอย่างบวกนั้นๆ จะไม่ถูกกำจัด (remove) ออกไปจากชุดข้อมูล แต่จะทำการกำหนดค่าน้ำหนักของตัวอย่างนั้นๆ ให้มีค่าลดลงโดยการคูณด้วยค่าๆ หนึ่ง ดังนั้นตัวอย่างบวกแต่ละตัวจึงมีกฎที่ครอบคลุมตัวอย่างนั้นๆ ได้มากกว่า 1 กฎ และทำการวนซ้ำการทำงานไปจนกระทั่งตัวอย่างบวกทั้งหมดถูกครอบคลุมด้วยกฎแล้วจึงหยุดการทำงาน จากนั้นนำกฎความสัมพันธ์ของประเภทที่ได้มาทำการคำนวณค่า Laplace expected error estimate เพื่อคัดเลือกกฎที่จะนำไปใช้ในการจำแนกประเภทข้อมูลต่อไป

ผลการทดลองแสดงให้เห็นว่า ค่าเฉลี่ยของผลลัพธ์ความถูกต้องจากการจำแนกประเภทข้อมูลด้วยขั้นตอนวิธี CPAR มีค่ามากกว่าค่าเฉลี่ยของผลลัพธ์ความถูกต้องจากขั้นตอนวิธี CBA และ CMAR

2.2.4 “Approximate Match of Rules Using Backpropagation Neural Networks” [19]

งานวิจัยนี้นำเสนอแนวคิดในการแก้ปัญหาของการโปรแกรมตรรกะเชิงอุปนัย (Inductive Logic Programming: ILP) [18] ในการจำแนกตัวอย่างแบบหลายกลุ่ม โดยใช้ขั้นตอนวิธี การดึงลักษณะสำคัญ (feature extraction) และใช้ลักษณะสำคัญที่ได้เป็นอินพุตให้กับแบ็กพรอพากาชันนิวรอลเน็ตเวิร์ก เพื่อให้เน็ตเวิร์กทำการเรียนรู้และสามารถนำไปใช้จำแนกตัวอย่างที่ไม่เคยเห็นมาก่อนได้ และในส่วนตัวของงานวิจัยนี้ นำเสนอว่าขั้นตอนวิธีดังกล่าวข้างต้น สามารถนำมาประยุกต์ใช้ในลักษณะของการตัดเล็มอย่างอ่อน (soft-pruning) สำหรับกฎประพจน์ (propositional rules) ที่ได้จากต้นไม้ตัดสินใจได้ กล่าวคือ ไม่ได้ทำการตัดเล็มส่วนของต้นไม้ออกไปจริงๆ เนื่องจากว่าส่วนที่จะทำการตัดเล็มออกไปอาจเป็นส่วนที่มีความสำคัญ แต่ประยุกต์ใช้แบ็กพรอพากาชันนิวรอลเน็ตเวิร์กเพื่อทำการปรับค่าน้ำหนักให้กับแต่ละโนดในต้นไม้ตัดสินใจ ตามความสำคัญของแต่ละโนด ทำให้ต้นไม้ตัดสินใจที่ได้มีประสิทธิภาพในการจำแนกประเภทข้อมูลมากยิ่งขึ้น

ผู้วิจัยได้นำแนวคิดของงานวิจัยที่ 2.2.4 มาประยุกต์ใช้กับการสร้างตัวจำแนกประเภทข้อมูลจากกฎความสัมพันธ์ของประเภทที่นำเสนอในงานวิจัยนี้ทั้ง 2 ลักษณะ กล่าวคือ สำหรับนิรอลเน็ตเวิร์กที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภท จะนำแนวคิดดังกล่าวมาใช้ในลักษณะของการจับคู่กฎความสัมพันธ์ของประเภท เพื่อประมาณการคัดเลือกกฎที่มีความเหมาะสมที่สุด หรืออีกนัยหนึ่งคือ เมื่อนำนิรอลเน็ตเวิร์กที่เรียนรู้แล้วมาทดสอบกับชุดข้อมูลทดสอบ จึงมีความเป็นไปได้ที่ผลลัพธ์ของการจำแนกประเภทข้อมูลจะมีความแม่นยำมากขึ้น เนื่องจากได้มีการปรับค่าน้ำหนักของเน็ตเวิร์กให้สอดคล้องกับชุดข้อมูลสอน กล่าวคือ กฎที่สอดคล้องกับชุดข้อมูลนั้นๆ จะได้รับค่าน้ำหนักมากกว่ากฎที่มีความสอดคล้องน้อยกว่า และกฎที่มีค่าน้ำหนักมากที่สุดจะถูกเลือกเพื่อนำไปใช้จำแนกประเภทข้อมูล ส่วนอีกลักษณะหนึ่งซึ่งนำนิรอลเน็ตเวิร์กมาใช้เพื่อจำแนกประเภทข้อมูลโดยตรง การนำแนวคิดนี้มาประยุกต์ใช้ จะมีลักษณะเช่นเดียวกันกับกรณีข้างต้น กล่าวคือ นิรอลเน็ตเวิร์กจะทำการเรียนรู้เพื่อปรับค่าน้ำหนักของเน็ตเวิร์กให้สอดคล้องกับชุดข้อมูลสอน เพื่อให้สามารถเลือกกฎประเภทที่มีความเหมาะสมที่สุดให้กับชุดข้อมูลนั้นๆ ได้

2.2.5 “การใช้เทคนิค Association Rule Discovery เพื่อการจัดสรรกฎหมายในการพิจารณาคดีความ” [12] และ “ระบบจำแนกประเภทโครงสร้างของโปรตีนโดยใช้เทคนิคดาต้าไมน์นิ่ง” [13]

งานวิจัยทั้งสองงานนี้เป็นตัวอย่างของการนำขั้นตอนวิธี CBA มาประยุกต์ใช้กับการทำงานด้านการจำแนกประเภทข้อมูลในลักษณะต่างๆ จากผลการทดลองแสดงให้เห็นว่าเทคนิคการจำแนกประเภทข้อมูลและการค้นหาความสัมพันธ์ของการทำเหมืองข้อมูล สามารถทำงานร่วมกันได้อย่างมีประสิทธิภาพ ทำให้ได้ตัวจำแนกประเภทข้อมูลที่มีผลลัพธ์ความถูกต้องเป็นที่น่าพอใจและสามารถแก้ปัญหาที่เกิดขึ้นกับระบบงานแบบเก่าได้ นอกจากนี้ ระบบที่นำเสนอ ยังช่วยให้การทำงานดำเนินไปได้โดยสะดวกมากยิ่งขึ้นอีกด้วย

เนื่องจาก CBA เป็นขั้นตอนวิธีทางการจำแนกประเภทเชิงความสัมพันธ์ที่ถูกนำมาใช้กับการทำงานจริงอย่างแพร่หลาย ดังนั้น ผู้วิจัยจึงสนใจที่จะปรับปรุงขั้นตอนวิธี CBA เพื่อสร้างตัวจำแนกประเภทข้อมูลที่มีความแม่นยำมากยิ่งขึ้น และสามารถนำแนวคิดที่ได้จากงานวิจัยนี้ไปประยุกต์ใช้กับระบบงานในปัจจุบัน เพื่อพัฒนาระบบให้มีประสิทธิภาพที่ดียิ่งขึ้นได้

บทที่ 3

การประยุกต์ใช้แบ็กพรอพาทกชันนิรอลเน็ตเวิร์กเพื่อจำแนกประเภท จากกฎความสัมพันธ์ของประเภท

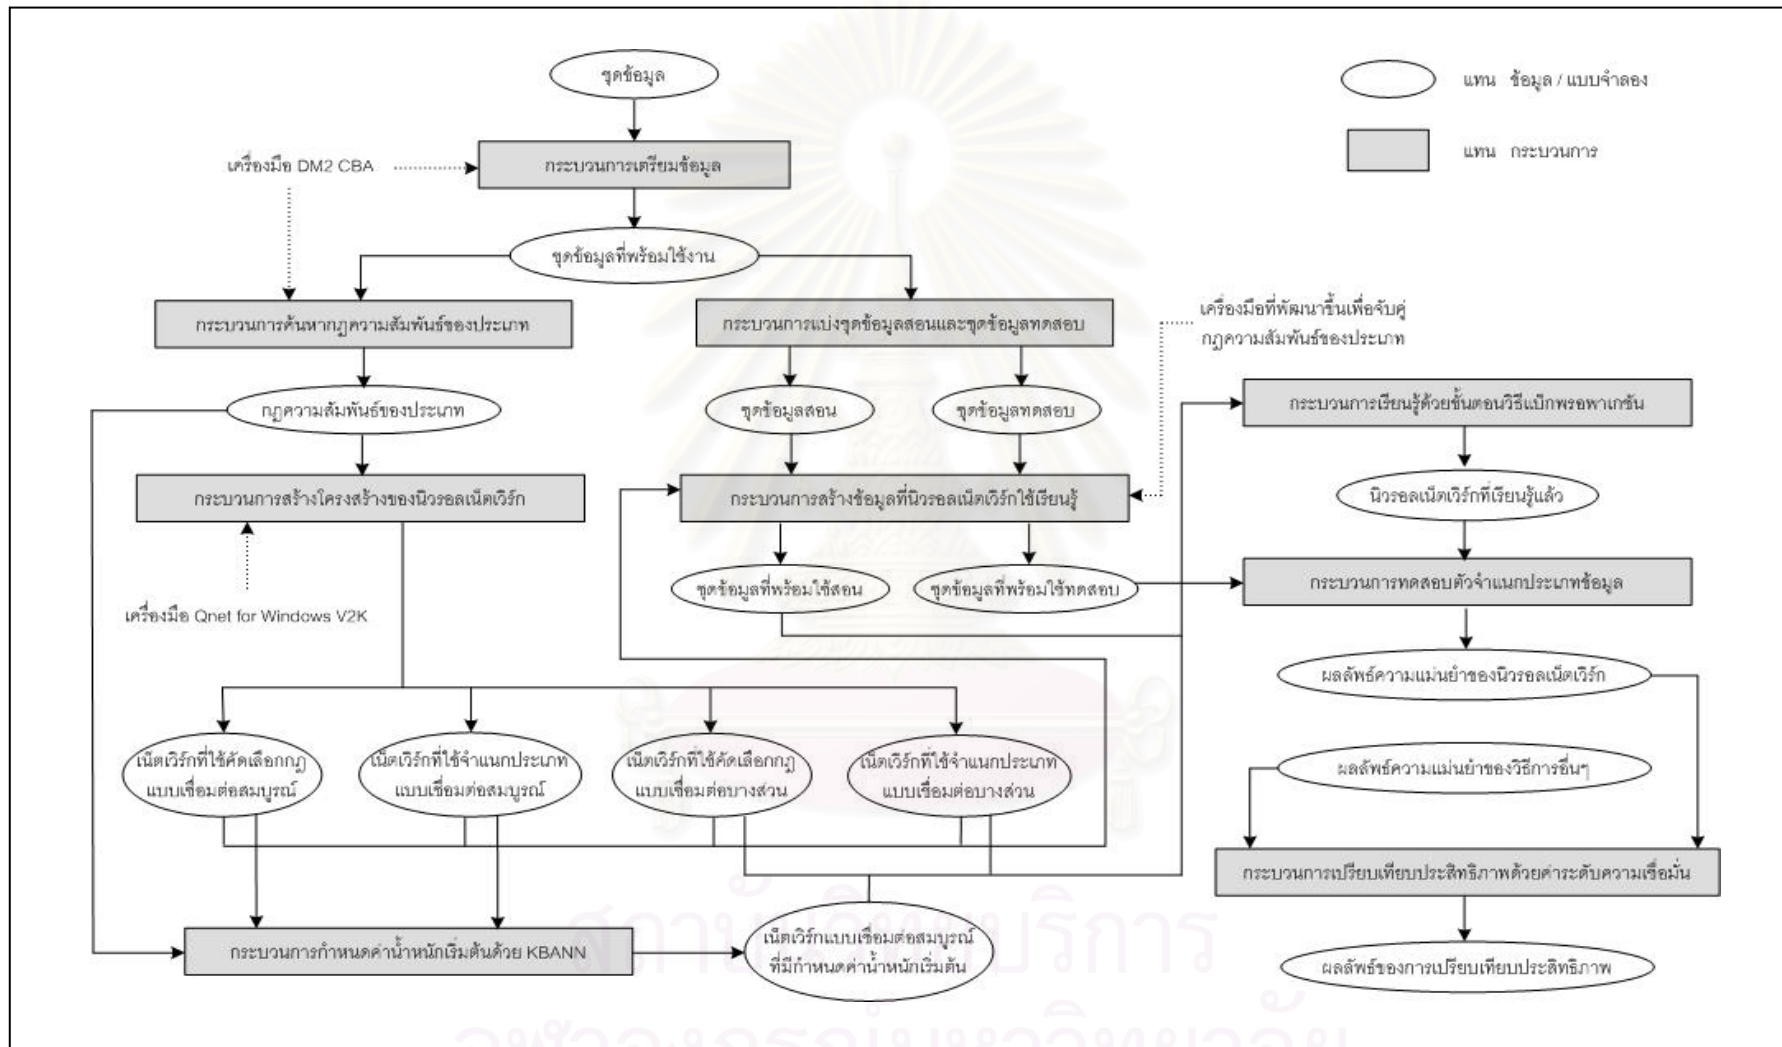
บทนี้จะกล่าวถึงรายละเอียดของการประยุกต์ใช้แบ็กพรอพาทกชันนิรอลเน็ตเวิร์กเพื่อจำแนกประเภทจากกฎความสัมพันธ์ของประเภท ซึ่งแบ่งเนื้อหาออกเป็น 2 ส่วนด้วยกัน โดยเนื้อหาในส่วนแรกจะกล่าวถึงภาพรวมของขั้นตอนวิธีดำเนินการวิจัย ต่อมาเนื้อหาในส่วนที่สองจะกล่าวถึงรายละเอียดทั้งหมดของวิธีการที่นำเสนอ ซึ่งประกอบด้วยการทำงาน 4 ส่วน คือ

- 1) การค้นหากฎความสัมพันธ์ของประเภท
- 2) การสร้างโครงสร้างของแบ็กพรอพาทกชันนิรอลเน็ตเวิร์กจากกฎความสัมพันธ์ของประเภท
- 3) การสร้างข้อมูลที่ใช้ในการเรียนรู้ และ
- 4) การเรียนรู้เพื่อปรับค่าน้ำหนักของเน็ตเวิร์ก

3.1 ภาพรวมของวิธีการที่นำเสนอ

การประยุกต์ใช้แบ็กพรอพาทกชันนิรอลเน็ตเวิร์กเพื่อจำแนกประเภทจากกฎความสัมพันธ์ของประเภท เป็นวิธีการที่นำเสนอขึ้นเพื่อปรับปรุงประสิทธิภาพของขั้นตอนวิธี CBA ซึ่งเป็นต้นแบบของการจำแนกประเภทเชิงความสัมพันธ์ ให้มีความแม่นยำในการจำแนกประเภทข้อมูลที่ดีขึ้น โดยวิธีการที่นำเสนอนี้ ได้นำนิรอลเน็ตเวิร์กที่มีความสามารถในการจำแนกประเภทข้อมูลสูงและทนทานต่อข้อมูลรบกวน มาประยุกต์ใช้กับการจำแนกประเภทเชิงความสัมพันธ์ เพื่อสร้างตัวจำแนกประเภทข้อมูลจากความรู้ก่อนหน้าในรูปแบบกฎความสัมพันธ์ของประเภทด้วยความแม่นยำที่มากยิ่งขึ้นได้

รูปที่ 3.1 แสดงภาพรวมของการประยุกต์ใช้แบ็กพรอพาทกชันนิรอลเน็ตเวิร์กเพื่อจำแนกประเภทจากกฎความสัมพันธ์ของประเภท โดยการทำงานจะเริ่มจากการนำชุดข้อมูลมาทำการเตรียมข้อมูลด้วยเครื่องมือ DM2 CBA เพื่อแปลงชุดข้อมูลที่มีข้อมูลต่อเนื่อง (continuous) ให้เป็นข้อมูลไม่ต่อเนื่อง (discretize) ก่อนที่จะนำไปใช้งาน จากนั้นก็จะนำชุดข้อมูลที่ได้มาทำการค้นหากฎความสัมพันธ์ของประเภทด้วยเครื่องมือ DM2 CBA โดยกฎที่ค้นพบเหล่านั้นจะถูกนำมาใช้กำหนดโครงสร้างให้กับนิรอลเน็ตเวิร์กทั้ง 4 ลักษณะ ซึ่งประกอบด้วย 1) นิรอลเน็ตเวิร์กที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภทแบบเชื่อมต่อบางส่วน 2) นิรอลเน็ตเวิร์กที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภทแบบเชื่อมต่อสมบูรณ์ 3) นิรอลเน็ตเวิร์กที่ใช้เพื่อจำแนกประเภทข้อมูลแบบเชื่อมต่อบางส่วน และ 4) นิรอลเน็ตเวิร์กที่ใช้เพื่อจำแนกประเภทข้อมูลแบบเชื่อมต่อสมบูรณ์ ในขณะที่เดียวกัน ชุดข้อมูลที่ผ่านการเตรียมข้อมูลแล้ว จะถูกนำมาแบ่งออกเป็นชุดข้อมูลสอนและชุดข้อมูลทดสอบ เพื่อนำไปใช้ในการเรียนรู้ของนิรอลเน็ตเวิร์กต่อไป



รูปที่ 3.1 ภาพรวมของการประยุกต์ใช้แบ็กพรอพาคชันนิเวศเน็ตเวิร์กเพื่อจำแนกประเภทจากภูมิศาสตร์ของประเภท

หลังจากทำการกำหนดโครงสร้างให้กับนิรอลเน็ตเวิร์กด้วยเครื่องมือ Qnet for Windows V2K แล้ว ต่อมาจะนำชุดข้อมูลสอนและชุดข้อมูลทดสอบที่แบ่งไว้ มาแปลงให้อยู่ในรูปแบบที่นิรอลเน็ตเวิร์กสามารถนำไปใช้งานได้ โดยในขั้นตอนนี้ ถ้าชุดข้อมูลที่นำมาใช้งานมีบางส่วนขาดหายไปหรือไม่ทราบค่า จะมีการกำหนดค่าให้กับข้อมูลไม่ทราบค่าเหล่านั้นดังรายละเอียดในหัวข้อที่ 3.4.1 และเพื่อให้ผลลัพธ์จากการเรียนรู้ของนิรอลเน็ตเวิร์กที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภทเป็นกฎความสัมพันธ์ของประเภท ผู้วิจัยได้พัฒนาเครื่องมือที่ใช้จับคู่กฎความสัมพันธ์ของประเภทขึ้น เพื่อหากฎที่สอดคล้องให้กับชุดข้อมูลสอนและชุดข้อมูลทดสอบ ก่อนที่จะนำชุดข้อมูลเหล่านั้นไปใช้ในการเรียนรู้ของนิรอลเน็ตเวิร์กต่อไป

ในส่วนของขั้นตอนการเรียนรู้เพื่อปรับค่าน้ำหนัก ก่อนที่นิรอลเน็ตเวิร์กที่ใช้การเชื่อมต่อของโครงสร้างแบบสมบรูณ์จะทำการเรียนรู้ จะมีการนำแนวคิดของ KBANN มาช่วยกำหนดค่าน้ำหนักเริ่มต้นให้กับเน็ตเวิร์กด้วย ส่วนนิรอลเน็ตเวิร์กที่ใช้การเชื่อมต่อของโครงสร้างแบบบางส่วน ซึ่งมีการกำหนดค่าน้ำหนักเริ่มต้นแบบสุ่มตามรูปแบบของขั้นตอนแบ็กพรอพagation จะไม่มีการกำหนดค่าน้ำหนักในลักษณะดังกล่าวข้างต้น จากนั้นชุดข้อมูลสอนจะถูกนำมาใช้สอนนิรอลเน็ตเวิร์กที่สร้างขึ้นทั้งหมด เพื่อทำการปรับค่าน้ำหนักของเส้นเชื่อมในเน็ตเวิร์กตามขั้นตอนวิธีแบ็กพรอพagation

เมื่อเสร็จสิ้นขั้นตอนการเรียนรู้แล้ว จะนำนิรอลเน็ตเวิร์กที่ได้มาทดสอบความสามารถในการจำแนกประเภทข้อมูลกับชุดข้อมูลทดสอบ ซึ่งผลลัพธ์ความแม่นยำที่ได้จากวิธีการที่นำเสนอทั้งหมด จะถูกนำมาเปรียบเทียบกับค่าระดับความเชื่อมั่น กับผลลัพธ์ที่ได้จากวิธีการจำแนกประเภทข้อมูลอื่นๆ เพื่อแสดงว่าวิธีการใดมีประสิทธิภาพในการจำแนกประเภทข้อมูลมากที่สุด

3.2 การค้นหากฎความสัมพันธ์ของประเภท

ในขั้นตอนการค้นหาความสัมพันธ์ของประเภท เพื่อบอกถึงความสัมพันธ์ของคุณลักษณะต่างๆ ที่มีต่อประเภทของข้อมูล งานวิจัยนี้ได้นำขั้นตอนวิธี CBA มาปรับใช้ โดยไม่มีการตัดเล็มกฎความสัมพันธ์ของประเภทที่ค้นพบ เนื่องจากการตัดเล็มกฎออกไปโดยสมบรูณ์อาจจะทำให้กฎที่น่าสนใจถูกทำการตัดเล็มออกไปได้ ในขณะที่นิรอลเน็ตเวิร์กก็สามารถทำการเรียนรู้ได้อย่างมีประสิทธิภาพแม้ว่าชุดข้อมูลสอนจะมีข้อมูลรบกวน ดังนั้น ขั้นตอนวิธีที่ใช้ค้นหาความสัมพันธ์ของประเภทในงานวิจัยนี้ จึงจะตัดบรรทัดที่ 3, 15 และ 18 ของขั้นตอนวิธี CBA ที่แสดงในรูปที่ 2.1 ออก ซึ่งสามารถแสดงได้ดังรูปที่ 3.2

```

1   F1 = {large 1-ruleitems};
2   CAR1 = genRules(F1);
3   for (k = 2; Fk-1 ≠ ∅; k++) do
4       Ck = candidateGen(Fk-1);
5       for each data case d ∈ D do
6           Cd = ruleSubset(Ck, d);
7           for each candidate c ∈ Cd do
8               c.condsupCount++;
9               if d.class = c.class then c.rulesupCount++
10          end
11      end
12      Fk = {c ∈ Ck | c.rulesupCount ≥ minsup};
13      CARk = genRules(Fk);
14  end
15  CARs = ∪k CARk;

```

รูปที่ 3.2 ขั้นตอนวิธี CBA ที่ไม่มีการตัดเต็มกฎความสัมพันธ์ของประเภท

จากรูปที่ 3.2 ขั้นตอนวิธี CBA ที่ไม่มีการตัดเต็มกฎประกอบด้วยการทำงาน 2 ส่วน คือ การค้นหาชุดไอเท็มปรากฏบ่อย และการสร้างกฎความสัมพันธ์ของประเภท โดยรายละเอียดของการทำงานทั้ง 2 ส่วน จะมีลักษณะเช่นเดียวกันกับการค้นหาชุดไอเท็มปรากฏบ่อย และการสร้างกฎความสัมพันธ์ของประเภทตามขั้นตอนวิธี CBA ดังแสดงในหัวข้อที่ 2.1.1.4

ข้อดีของขั้นตอนวิธีแบบกฎ (Rule-based Algorithm) อาทิ วิธีการเรียนรู้ของเครื่องแบบต้นไม้ตัดสินใจ และการค้นหาความสัมพันธ์ของประเภท คือ เป็นกฎที่มนุษย์สามารถทำความเข้าใจได้ง่าย อย่างไรก็ตาม การค้นหาความสัมพันธ์ของประเภทที่มีข้อได้เปรียบกว่าต้นไม้ตัดสินใจ คือ ให้กฎที่มีนัยทั่วไปมากกว่า (more general) และสามารถทำการค้นหาเซตของกฎได้อย่างสมบูรณ์

ยกตัวอย่างเช่น ตัวอย่างการเรียนรู้แนวคิด (concept) ผิวไหม้จากการอาบแดด ซึ่งมีข้อมูลที่ใช้ในการเรียนรู้ดังแสดงในตารางที่ 3.1

ตารางที่ 3.1 ข้อมูลที่ใช้ในตัวอย่างการเรียนรู้แนวคิดผิวใหม่จากการอาบแดด

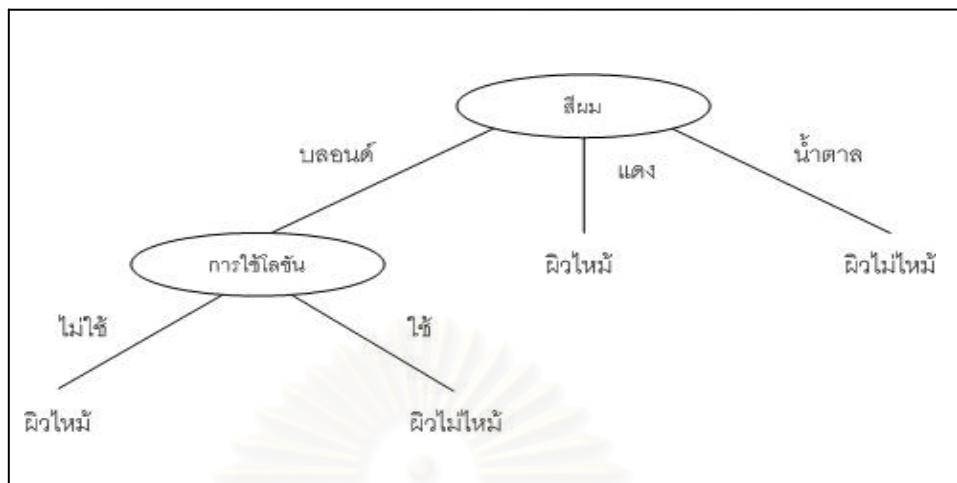
คนที่	ชื่อ	สีผม	ส่วนสูง	น้ำหนัก	การใช้โลชั่น	ผลลัพธ์
1	ซาราห์	บลอนด์	มาตรฐาน	น้อย	ไม่ใช้	ผิวใหม่
2	ดانا	บลอนด์	สูง	มาตรฐาน	ใช้	ผิวไม่ใหม่
3	อเล็กซ์	น้ำตาล	เตี้ย	มาตรฐาน	ใช้	ผิวไม่ใหม่
4	แอนนี่	บลอนด์	เตี้ย	มาตรฐาน	ไม่ใช้	ผิวใหม่
5	เอมิลี	แดง	มาตรฐาน	มาก	ไม่ใช้	ผิวใหม่
6	พีท	น้ำตาล	สูง	มาก	ไม่ใช้	ผิวไม่ใหม่
7	จอห์น	น้ำตาล	มาตรฐาน	มาก	ไม่ใช้	ผิวไม่ใหม่
8	เคท	บลอนด์	เตี้ย	น้อย	ใช้	ผิวไม่ใหม่

เมื่อนำข้อมูลจากตารางที่ 3.1 มาทำการค้นหาหาความสัมพันธ์ของประเภทตามขั้นตอนวิธี CBA ที่ไม่มีการตัดเล็ม โดยกำหนดให้ค่าสนับสนุนขั้นต่ำ = 15% และค่าความเชื่อมั่นขั้นต่ำ = 60% (ค่าสนับสนุนและค่าความเชื่อมั่นขั้นต่ำที่ใช้ อ้างอิงจากงานวิจัย [5]) จะได้ความสัมพันธ์ของประเภท ดังต่อไปนี้

1. (สีผม, บลอนด์), (การใช้โลชั่น, ไม่ใช้) → ผิวใหม่
2. (การใช้โลชั่น, ใช้) → ผิวไม่ใหม่
3. (สีผม, แดง) → ผิวใหม่
4. (สีผม, น้ำตาล) → ผิวไม่ใหม่

เปรียบเทียบกับต้นไม้ตัดสินใจที่ทำการสร้างจากข้อมูลในตารางที่ 3.1 ดังแสดงในรูปที่ 3.3 กฎที่ได้จากต้นไม้ตัดสินใจ สามารถแสดงได้ดังต่อไปนี้

1. (สีผม, บลอนด์), (การใช้โลชั่น, ไม่ใช้) → ผิวใหม่
2. (สีผม, บลอนด์), (การใช้โลชั่น, ใช้) → ผิวไม่ใหม่
3. (สีผม, แดง) → ผิวใหม่
4. (สีผม, น้ำตาล) → ผิวไม่ใหม่



รูปที่ 3.3 ต้นไม้ตัดสินใจในตัวอย่งการเรียนรู้แนวคิดผิวไหม้จากการอาบแดด

เมื่อทำการเปรียบเทียบกฎความสัมพันธ์ของประเภทที่ได้จากขั้นตอนวิธี CBA ที่ไม่มีการตัดเล็ม กับกฎที่ได้จากต้นไม้ตัดสินใจข้างต้น จะพบว่าได้กฎที่เหมือนกัน คือ กฎข้อที่ 1, 3 และ 4 แต่กฎข้อที่ 2 มีความแตกต่างกัน โดยกฎที่ได้จากขั้นตอนวิธี CBA จะเป็นกฎที่มีนัยทั่วไปมากกว่ากฎที่ได้จากต้นไม้ตัดสินใจ ซึ่งเป็นผลดีกับการจำแนกประเภทข้อมูลในกรณีที่มีข้อมูลที่ใช้ในการเรียนรู้มีขนาดเล็ก

อีกตัวอย่างหนึ่งซึ่งกฎความสัมพันธ์ของประเภทที่ได้จากขั้นตอนวิธี CBA ที่ไม่มีการตัดเล็ม กับกฎที่ได้จากต้นไม้ตัดสินใจมีความแตกต่างกัน คือ ตัวอย่างการเรียนรู้แนวคิดการตัดสินใจเล่นเทนนิส ซึ่งมีข้อมูลที่ใช้ในการเรียนรู้ดังแสดงในตารางที่ 3.2

ตารางที่ 3.2 ข้อมูลที่ใช้ในตัวอย่งการเรียนรู้แนวคิดการตัดสินใจเล่นเทนนิส

วันที่	สภาพแวดล้อม	อุณหภูมิ	ความชื้น	กระแสดม	การเล่นเทนนิส
1	แดดจ้า	สูง	สูง	ลมปกติ	ไม่เล่น
2	แดดจ้า	สูง	สูง	ลมแรง	ไม่เล่น
3	แดดร่ม	สูง	สูง	ลมปกติ	เล่น
4	ฝนตก	ปานกลาง	สูง	ลมปกติ	เล่น
5	ฝนตก	ต่ำ	ปานกลาง	ลมปกติ	เล่น
6	ฝนตก	ต่ำ	ปานกลาง	ลมแรง	ไม่เล่น
7	แดดร่ม	ต่ำ	ปานกลาง	ลมแรง	เล่น
8	แดดจ้า	ปานกลาง	สูง	ลมปกติ	ไม่เล่น

ตารางที่ 3.2 ข้อมูลที่ใช้ในตัวอย่างการเรียนรู้แนวความคิดตัดสินใจเล่นเทนนิส (ต่อ)

วันที่	สภาพแวดล้อม	อุณหภูมิต่ำ	ความชื้น	กระแสดลม	การเล่นเทนนิส
9	แดดจ้า	ต่ำ	ปานกลาง	ลมปกติ	เล่น
10	ฝนตก	ปานกลาง	ปานกลาง	ลมปกติ	เล่น
11	แดดจ้า	ปานกลาง	ปานกลาง	ลมแรง	เล่น
12	แดดร่ม	ปานกลาง	สูง	ลมแรง	เล่น
13	แดดร่ม	สูง	ปานกลาง	ลมปกติ	เล่น
14	ฝนตก	ปานกลาง	สูง	ลมแรง	ไม่เล่น

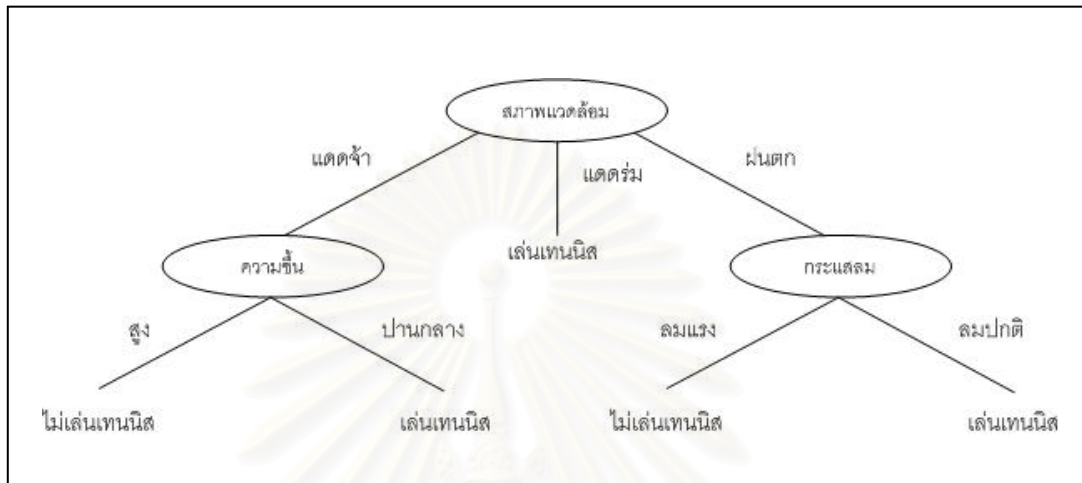
เมื่อนำข้อมูลจากตารางที่ 3.2 มาทำการค้นหาหาความสัมพันธ์ของประเภทตามขั้นตอนวิธี CBA ที่ไม่มีการตัดเล็ม โดยกำหนดให้ค่าสนับสนุนขั้นต่ำ = 15% และค่าความเชื่อมั่นขั้นต่ำ = 60% (อ้างอิงจากงานวิจัย [5]) จะได้กฎความสัมพันธ์ของประเภท ดังต่อไปนี้

1. (สภาพแวดล้อม, แดดจ้า), (ความชื้น, สูง) → ไม่เล่นเทนนิส
2. (สภาพแวดล้อม, แดดจ้า), (ความชื้น, ปานกลาง) → เล่นเทนนิส
3. (สภาพแวดล้อม, แดดร่ม) → เล่นเทนนิส
4. (สภาพแวดล้อม, ฝนตก), (กระแสดลม, ลมแรง) → ไม่เล่นเทนนิส
5. (สภาพแวดล้อม, ฝนตก), (กระแสดลม, ลมปกติ) → เล่นเทนนิส
6. (ความชื้น, ปานกลาง), (กระแสดลม, ลมปกติ) → เล่นเทนนิส

เปรียบเทียบกับต้นไม้ตัดสินใจที่ทำการสร้างจากข้อมูลในตารางที่ 3.2 ดังแสดงในรูปที่ 3.4 กฎที่ได้จากต้นไม้ตัดสินใจ สามารถแสดงได้ดังต่อไปนี้

1. (สภาพแวดล้อม, แดดจ้า), (ความชื้น, สูง) → ไม่เล่นเทนนิส
2. (สภาพแวดล้อม, แดดจ้า), (ความชื้น, ปานกลาง) → เล่นเทนนิส
3. (สภาพแวดล้อม, แดดร่ม) → เล่นเทนนิส

4. (สภาพแวดล้อม, ฝนตก), (กระแสดลม, ลมแรง) → ไม่เล่นเทนนิส
5. (สภาพแวดล้อม, ฝนตก), (กระแสดลม, ลมปกติ) → เล่นเทนนิส



รูปที่ 3.4 ต้นไม้ตัดสินใจในตัวอย่างการเรียนรู้แนวคิดการตัดสินใจเล่นเทนนิส

เมื่อทำการเปรียบเทียบกฎความสัมพันธ์ของประเภทที่ได้จากขั้นตอนวิธี CBA ที่ไม่มีการตัดเล็ม กับกฎที่ได้จากต้นไม้ตัดสินใจข้างต้น จะพบว่าได้กฎที่เหมือนกัน คือ กฎข้อที่ 1-5 แต่ขั้นตอนวิธี CBA จะให้กฎข้อที่ 6 ด้วย ซึ่งเป็นกฎที่น่าสนใจและสามารถบอกได้จากข้อมูลที่ใช้ในการเรียนรู้ แต่เนื่องด้วยข้อจำกัดของต้นไม้ตัดสินใจที่คุณลักษณะตัวหนึ่งๆ จะมีความสัมพันธ์กับคุณลักษณะตัวอื่นที่อยู่ในกิ่งเดียวกันเท่านั้น และความสัมพันธ์ไม่สามารถเกิดขึ้นในลักษณะการข้ามกิ่งได้ ดังนั้นกฎที่น่าสนใจข้อที่ 6 จึงไม่ถูกค้นพบด้วยวิธีการเรียนรู้แบบต้นไม้ตัดสินใจ

3.3 การสร้างโครงสร้างของแบ็กพรอพาเกชันนิรอลเน็ตเวิร์กจากกฎความสัมพันธ์ของประเภท

หลังจากทำการค้นหากฎความสัมพันธ์ของประเภทแล้ว ขั้นตอนต่อมาคือการนำกฎที่ค้นพบทั้งหมดมากำหนดโครงสร้างให้กับแบ็กพรอพาเกชันนิรอลเน็ตเวิร์กที่จะใช้ทำการเรียนรู้ โดยงานวิจัยนี้ได้นำนิรอลเน็ตเวิร์กมาประยุกต์ใช้กับการจำแนกประเภทข้อมูลใน 2 ลักษณะได้แก่

1. เพื่อคัดเลือกกฎที่จะนำไปใช้ในการจำแนกประเภทข้อมูล กล่าวคือ การเรียนรู้ของเน็ตเวิร์กจะให้ผลลัพธ์เป็นกฎความสัมพันธ์ของประเภท โดยเงื่อนไขของกฎ (antecedent) และผลากประเภทของกฎนั้นๆ จะถูกนำไปใช้จำแนกประเภทข้อมูล

2. เพื่อใช้ในการจำแนกประเภทข้อมูล กล่าวคือ การเรียนรู้ของเน็ตเวิร์กจะให้ผลลัพธ์เป็นฉลากประเภท ซึ่งสามารถนำไปใช้จำแนกประเภทข้อมูลได้โดยตรง

ธรรมชาติของการเรียนรู้ของนิวรอลเน็ตเวิร์กจะให้ผลลัพธ์เป็นฉลากประเภท โดยไม่สามารถระบุกฎที่ใช้จำแนกประเภทข้อมูลได้โดยตรง ซึ่งแตกต่างจากวิธีการเรียนรู้ของเครื่องแบบต้นไม้ตัดสินใจ และการจำแนกประเภทเชิงความสัมพันธ์ ซึ่งให้ผลลัพธ์เป็นเซตของกฎประพจน์ที่มนุษย์สามารถทำความเข้าใจได้ ดังนั้น งานวิจัยนี้จึงได้ทำการศึกษาเปรียบเทียบการนำนิวรอลเน็ตเวิร์กมาใช้ในการจำแนกประเภทข้อมูลใน 2 ลักษณะดังกล่าวข้างต้น โดยจะใช้การเชื่อมต่อของโครงสร้างนิวรอลเน็ตเวิร์กที่มีการเชื่อมต่อระหว่างชั้นฮิดเดนกับชั้นเอาต์พุตเป็นแบบเชื่อมต่ออย่างสมบูรณ์ (fully connected) แต่การเชื่อมต่อระหว่างชั้นอินพุตกับชั้นฮิดเดนมีความแตกต่างกันเป็น 2 แบบ คือ

1. แบบเชื่อมต่อบางส่วน (partially connected)
2. แบบเชื่อมต่ออย่างสมบูรณ์

ตารางที่ 3.3 แสดงการศึกษาเปรียบเทียบการนำนิวรอลเน็ตเวิร์กมาประยุกต์ใช้กับการจำแนกประเภทข้อมูล ซึ่งแบ่งออกได้เป็น 4 กรณี

ตารางที่ 3.3 การนำนิวรอลเน็ตเวิร์กมาประยุกต์ใช้กับการจำแนกประเภทข้อมูล

การนำนิวรอลเน็ตเวิร์กมาใช้ในการจำแนกประเภทข้อมูล	การเชื่อมต่อของโครงสร้างของนิวรอลเน็ตเวิร์ก	
	เชื่อมต่อบางส่วน	เชื่อมต่ออย่างสมบูรณ์
เพื่อคัดเลือกกฎความสัมพันธ์ของประเภทที่จะใช้จำแนกประเภทข้อมูล	☑	☑
เพื่อใช้จำแนกประเภทข้อมูลโดยตรง	☑	☑

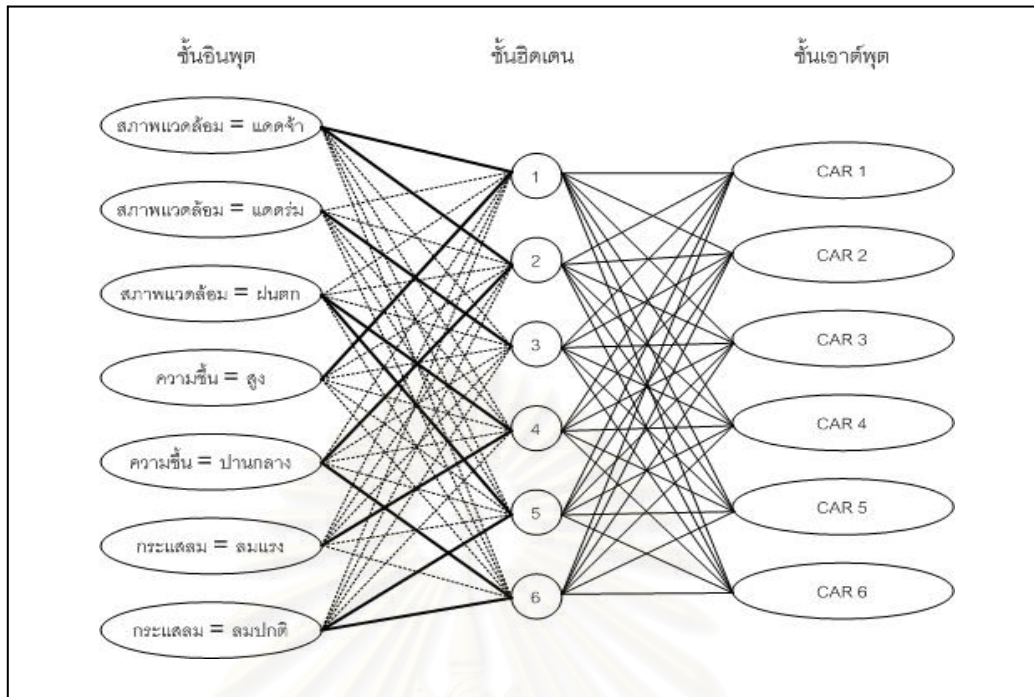
โครงสร้างของแบ็กพรอพากเกจันนิวรอลเน็ตเวิร์กที่รับกฎความสัมพันธ์ของประเภทมาใช้ในการเรียนรู้ ประกอบด้วย 3 ส่วน ได้แก่

1. ชั้นอินพุต เป็นชั้นแรกของเน็ตเวิร์กที่รับอินพุตเข้ามา ในชั้นนี้จะนำคุณลักษณะต่างๆ ที่ได้จากกฎความสัมพันธ์ของประเภทแต่ละข้อมาสร้างเป็นอินพุตโนด (input node) โดยค่าคุณลักษณะ 1 ตัว จะถูกแทนด้วยโนด 1 โนด ทำให้จำนวนโนดในชั้นอินพุตนี้ มีค่าเท่ากับจำนวนค่าของคุณลักษณะที่ไม่มีการซ้ำซ้อนกัน

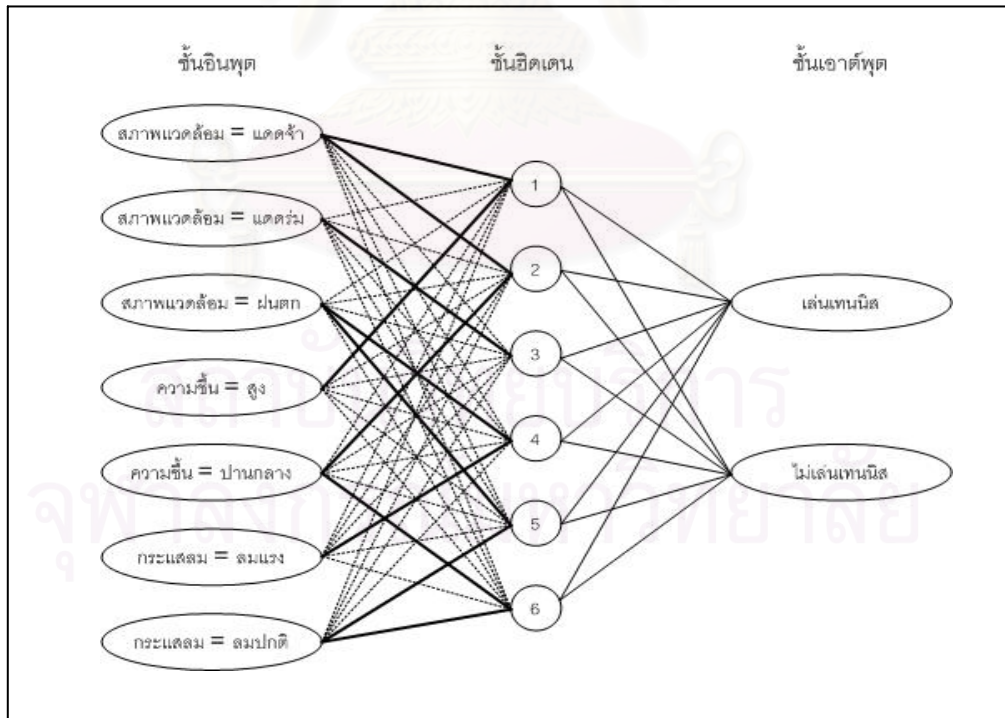
ของกฎความสัมพันธ์ของประเภททุกข้อรวมกัน โดยโครงสร้างของนิวรอลเน็ตเวิร์กที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภทและใช้เพื่อจำแนกประเภทข้อมูลทั้ง 4 กรณี จะมีลักษณะของอินพุตโนดในชั้นอินพุตเหมือนกัน

2. ชั้นฮิดเดน เป็นชั้นที่อยู่ถัดมาจากชั้นอินพุต โดยโครงสร้างของนิวรอลเน็ตเวิร์กที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภทและใช้เพื่อจำแนกประเภทข้อมูลซึ่งมีการเชื่อมต่อเพียงบางส่วน ฮิดเดนโนด (hidden node) แต่ละโนดจะเปรียบเสมือนเป็นการเชื่อมกันด้วย “และ” ของคุณลักษณะที่ได้จากกฎความสัมพันธ์ของประเภท กล่าวคือ ฮิดเดนโนดหนึ่งๆ จะเชื่อมต่อกับคุณลักษณะของกฎความสัมพันธ์ของประเภทแต่ละข้อ เพื่อรวบรวมคุณลักษณะเหล่านั้นให้กลับมาเป็นกฎที่สมบูรณ์ ส่วนอีก 2 กรณีซึ่งโครงสร้างมีการเชื่อมต่ออย่างสมบูรณ์ ฮิดเดนโนดแต่ละโนดจะมีการเชื่อมต่อกับทุกๆ อินพุตโนด ดังนั้นทั้ง 4 กรณีจึงมีจำนวนโนดในชั้นฮิดเดนเท่ากับจำนวนกฎความสัมพันธ์ของประเภทที่นำมาใช้ในการเรียนรู้
3. ชั้นเอาต์พุต เป็นชั้นที่แสดงผลลัพธ์ของเน็ตเวิร์ก โดยทั้ง 4 กรณี เอาต์พุตโนด (output node) แต่ละโนด จะมีการเชื่อมต่ออย่างสมบูรณ์กับทุกๆ โนดในชั้นฮิดเดนเหมือนกัน แต่มีจำนวนโนดในชั้นนี้แตกต่างกัน โดยโครงสร้างของนิวรอลเน็ตเวิร์กที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภท จะมีจำนวนเอาต์พุตโนดเท่ากับจำนวนกฎความสัมพันธ์ของประเภท ส่วนโครงสร้างของนิวรอลเน็ตเวิร์กที่ใช้เพื่อจำแนกประเภทข้อมูลโดยตรง จะมีจำนวนเอาต์พุตโนดเท่ากับจำนวนประเภทของข้อมูลที่ต้องการให้เน็ตเวิร์กเรียนรู้

จากกฎความสัมพันธ์ของประเภทของตัวอย่างการเรียนรู้แนวคิดการตัดสินใจเล่นเทนนิสทั้ง 6 ข้อดังกล่าวข้างต้น จะได้โครงสร้างของแบ็กพรอพาทเกชันนิวรอลเน็ตเวิร์กที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภท ดังแสดงในรูปที่ 3.5 และโครงสร้างของนิวรอลเน็ตเวิร์กที่ใช้เพื่อจำแนกประเภทข้อมูลโดยตรง ดังแสดงในรูปที่ 3.6 โดยโครงสร้างแบบที่มีการเชื่อมต่อเพียงบางส่วน จะแสดงเส้นเชื่อม (link) ด้วยเส้นทึบ ส่วนโครงสร้างแบบที่มีการเชื่อมต่ออย่างสมบูรณ์ จะแสดงเส้นเชื่อมด้วยเส้นทึบและเส้นประ



รูปที่ 3.5 โครงสร้างของแบ็กพรอพาทาเกชันนิวรอลเน็ตเวิร์กที่ใช้เพื่อคัดเลือก
กฎความสัมพันธ์ของประเภทในตัวอย่างการเรียนรู้แนวคิดการตัดสินใจเล่นเทนนิส

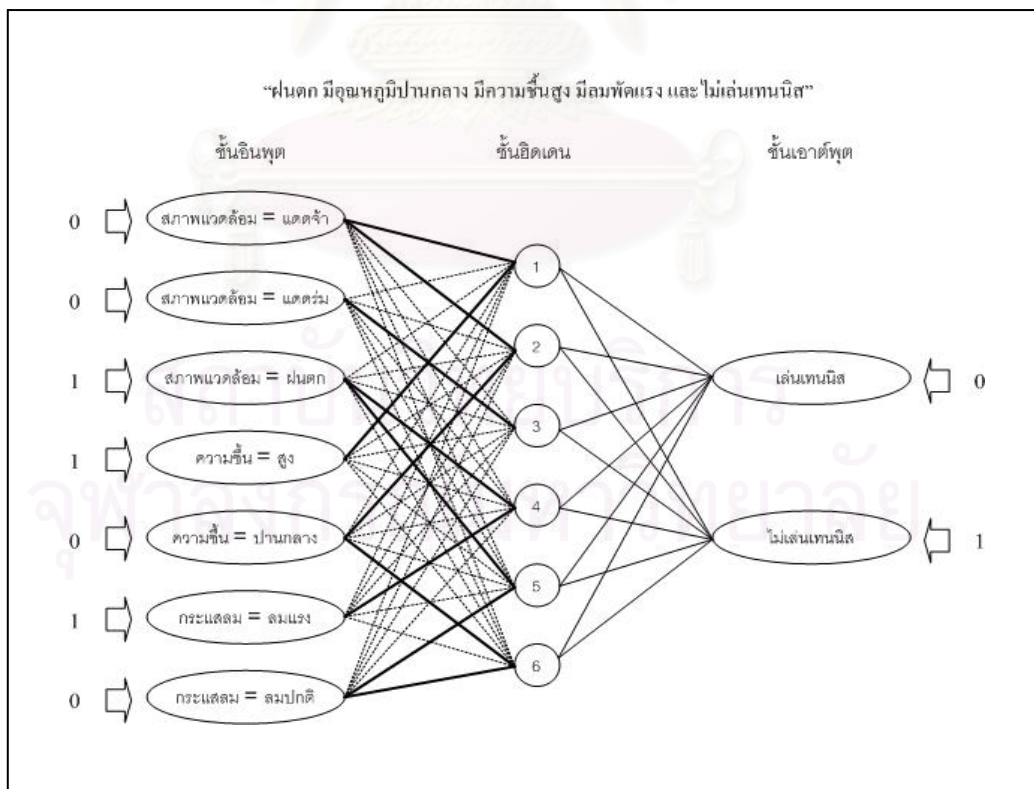


รูปที่ 3.6 โครงสร้างของแบ็กพรอพาทาเกชันนิวรอลเน็ตเวิร์กที่ใช้เพื่อจำแนกประเภทข้อมูล
ในตัวอย่างการเรียนรู้แนวคิดการตัดสินใจเล่นเทนนิส

3.4 การสร้างข้อมูลที่ใช้ในการเรียนรู้

เมื่อได้โครงสร้างของแบ็กพรอพาทเกชันนิเวรอลเน็ตเวิร์กที่สร้างขึ้นจากกฎความสัมพันธ์ของประเภทแล้ว ขั้นตอนต่อไปจะนำชุดข้อมูลสอนและชุดข้อมูลทดสอบที่แบ่งไว้ มาแปลงให้อยู่ในรูปแบบที่นิเวรอลเน็ตเวิร์กสามารถใช้งานได้ โดยการสร้างข้อมูลที่ใช้ในการเรียนรู้ของนิเวรอลเน็ตเวิร์ก จะพิจารณาจากค่าของคุณลักษณะของข้อมูลที่ใช้เรียนรู้กับค่าของคุณลักษณะในแต่ละอินพุตโนดและเอาต์พุตโนดของเน็ตเวิร์กว่าสอดคล้องกันหรือไม่ ถ้าคุณลักษณะของข้อมูลมีค่าตรงกับค่าของคุณลักษณะในอินพุตโนดและเอาต์พุตโนด โนดนั้นๆ จะมีค่าความจริงเป็น “จริง” ซึ่งแทนด้วยค่า “1” แต่ถ้ามีค่าขัดแย้งกับค่าของคุณลักษณะในอินพุตโนดและเอาต์พุตโนด โนดนั้นๆ จะมีค่าความจริงเป็น “เท็จ” ซึ่งแทนด้วยค่า “0”

ยกตัวอย่างเช่น ข้อมูลสำหรับโครงสร้างของนิเวรอลเน็ตเวิร์กที่ใช้เพื่อจำแนกประเภทข้อมูลโดยตรง คือ “ฝนตก มีอุณหภูมิปานกลาง มีความชื้นสูง มีลมพัดแรง และไม่เล่นเทนนิส” เมื่อนำมาสร้างเป็นข้อมูลให้กับเน็ตเวิร์ก จะมีค่าของอินพุตโนดเป็น “0 0 1 1 0 1 0” และเอาต์พุตโนดเป็น “0 1” ดังแสดงในรูปที่ 3.7



รูปที่ 3.7 ตัวอย่างการสร้างข้อมูลที่ใช้ในการเรียนรู้ของนิเวรอลเน็ตเวิร์ก

เนื่องจากการเรียนรู้ของนิเวศเน็ตเวิร์กโดยทั่วไปจะให้ผลลัพธ์เป็นฉลากประเภท ดังนั้น การสร้างข้อมูลที่ใช้ในการเรียนรู้ของนิเวศเน็ตเวิร์กที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภท จึงจำเป็นต้องเพิ่มขึ้นขั้นตอนการเตรียมข้อมูล โดยผู้วิจัยได้พัฒนาเครื่องมือที่ใช้ทำการจับคู่กฎความสัมพันธ์ของประเภทขึ้น เพื่อหากฎที่สอดคล้องให้กับชุดข้อมูลก่อนที่จะนำชุดข้อมูลนั้นๆ ไปใช้ในการเรียนรู้ของนิเวศเน็ตเวิร์ก เพื่อให้ผลลัพธ์ที่ได้จากการเรียนรู้เป็นกฎความสัมพันธ์ของประเภท จากนั้นจึงจะนำชุดข้อมูลมาทำการทดสอบค่าความจริงตามวิธีการข้างต้น โดยการจับคู่กฎความสัมพันธ์ของประเภทนั้น จะพิจารณาจากสอดคล้องของฉลากประเภท จำนวนค่าของคุณลักษณะที่กฎแต่ละข้อสอดคล้องกับข้อมูล และค่าความเชื่อมั่นของกฎข้อนั้น ซึ่งมีแนวคิดคล้ายกับการเลือกกฎที่เป็นไปได้ในการสร้างกฎความสัมพันธ์ของประเภทของขั้นตอนวิธี CBA โดยมีรายละเอียดดังต่อไปนี้

1. ถ้ากฎความสัมพันธ์ของประเภทที่มีฉลากประเภทตรงกับข้อมูลและมีจำนวนค่าของคุณลักษณะสอดคล้องกับข้อมูลมากที่สุด มีเพียงข้อเดียว จะเลือกกฎข้อนั้น โดยไม่นำค่าความเชื่อมั่นของกฎมาร่วมพิจารณา
2. ถ้ากฎความสัมพันธ์ของประเภทที่มีฉลากประเภทตรงกับข้อมูลและมีจำนวนค่าของคุณลักษณะสอดคล้องกับข้อมูลมากที่สุด มีมากกว่า 1 ข้อ จะเลือกกฎที่มีค่าความเชื่อมั่นมากที่สุดจากเซตของกฎข้างต้นให้กับข้อมูลนั้นๆ
3. ถ้ากฎความสัมพันธ์ของประเภทที่มีฉลากประเภทตรงกับข้อมูลและมีจำนวนค่าของคุณลักษณะสอดคล้องกับข้อมูลมากที่สุด มีมากกว่า 1 ข้อ และกฎเหล่านั้น มีค่าความเชื่อมั่นเท่ากันด้วย จะทำการเลือกกฎให้กับข้อมูลนั้นๆ แบบสุ่ม

3.4.1 การกำหนดค่าให้กับข้อมูลไม่ทราบค่า

ในการทำงานจริง เป็นไปได้ที่ชุดข้อมูลที่นำมาใช้งานอาจจะมีข้อมูลบางส่วนขาดหายไป หรือไม่ทราบค่า (missing value data) ดังนั้น ก่อนจะนำชุดข้อมูลดังกล่าวมาสร้างเป็นข้อมูลเพื่อให้เน็ตเวิร์กเรียนรู้ จะต้องมีการกำหนดค่าให้กับข้อมูลไม่ทราบค่าเหล่านั้นเสียก่อน โดยงานวิจัยนี้จะใช้วิธีการเช่นเดียวกันกับที่ใช้ในวิธีการเรียนรู้ของเครื่องแบบ C4.5 กล่าวคือ แทนค่าข้อมูลไม่ทราบค่าด้วยค่าความน่าจะเป็นที่ข้อมูลตัวนั้นจะสอดคล้องกับโนดของเน็ตเวิร์ก ซึ่งมีค่าเท่ากับจำนวนข้อมูลที่สอดคล้องกับโนดนั้นๆ ของเน็ตเวิร์กหารด้วยจำนวนข้อมูลที่ทราบค่าทั้งหมด

ยกตัวอย่างเช่น ข้อมูลที่ใช้ในการเรียนรู้ คือ “ฝนตก มีอุณหภูมิปานกลาง มีความชื้นสูง และไม่เล่นเทนนิส” โดยไม่ทราบค่าของคุณลักษณะ *กระแสดม* จากตารางที่ 3.2 ข้อมูลที่เหลืออีก 13 ตัว ซึ่งทราบค่าของคุณลักษณะ *กระแสดม* แบ่งออกเป็น *ลมแรง* จำนวน 5 ตัว และ *ลมปกติ* จำนวน 8 ตัว ดังนั้นเมื่อนำข้อมูลข้างต้นมาสร้างเป็นข้อมูลให้กับเน็ตเวิร์ก จะมีค่าของอินพุตโนดและเอาต์พุตโนดเป็น “0 0 1 1 0 5/13 8/13” และ “0 1” ตามลำดับ

3.5 การเรียนรู้เพื่อปรับค่าน้ำหนักของเน็ตเวิร์ก

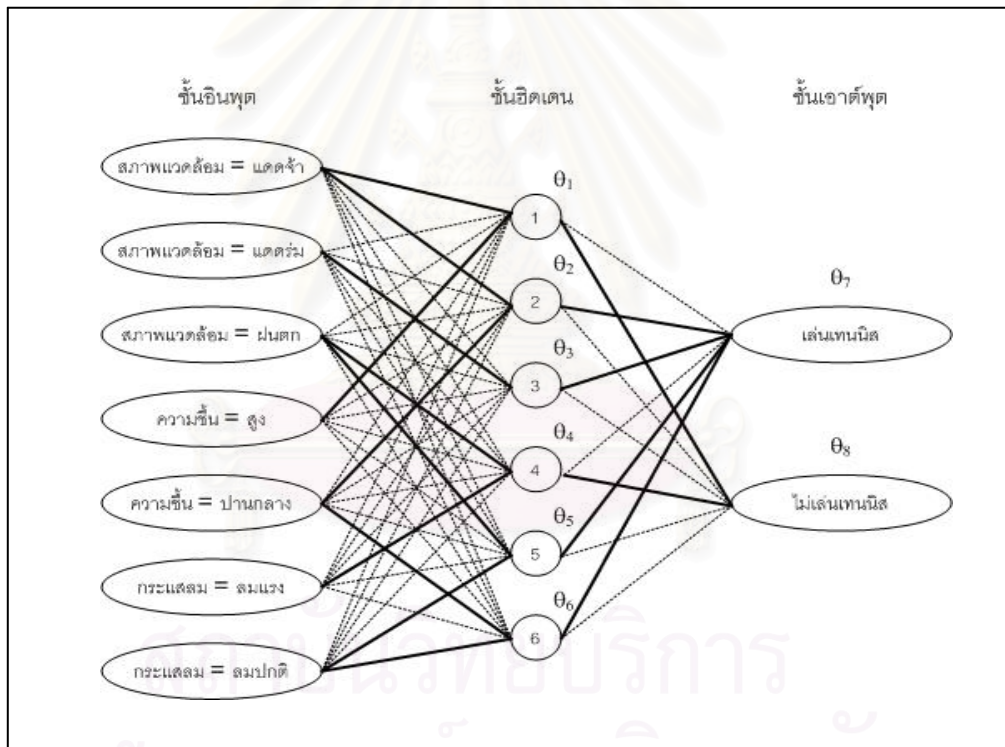
ดังกล่าวข้างต้นว่า แบ็กพรอพาเกชันนิรอรอลเน็ตเวิร์กที่นำเสนอในงานวิจัยนี้ ได้มีการกำหนดโครงสร้างขึ้นจากความรู้ก่อนหน้าซึ่งอยู่ในรูปแบบกฎความสัมพันธ์ของประเภท โดยในโครงสร้างของนิรอรอลเน็ตเวิร์กที่มีการเชื่อมต่อบางส่วน ค่าคุณลักษณะ (attribute value) แต่ละตัวจะมีการเชื่อมโยงไปยังกฎความสัมพันธ์ของประเภทที่มีความสัมพันธ์กัน เพื่อแสดงว่าค่าคุณลักษณะตัวนั้นมีความสำคัญต่อการเลือกกฎนั้นๆ ไปใช้จำแนกประเภทข้อมูล ส่วนค่าคุณลักษณะตัวอื่นที่ไม่เกี่ยวข้อง โครงสร้างในลักษณะนี้ก็จะไม่มีการกำหนดการเชื่อมโยง ส่งผลให้ค่าคุณลักษณะนั้นๆ จะไม่ถูกนำมาร่วมพิจารณาในการเรียนรู้ของนิรอรอลเน็ตเวิร์ก ดังนั้น การเรียนรู้เพื่อปรับค่าน้ำหนักให้กับโครงสร้างของนิรอรอลเน็ตเวิร์กแบบเชื่อมต่อบางส่วน ทั้งที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภทและใช้เพื่อจำแนกประเภทข้อมูล จึงมีการกำหนดค่าน้ำหนักเริ่มต้นแบบสุ่มให้มีค่าน้อยๆ เนื่องจากโครงสร้างก่อนการเรียนรู้ได้มีการกำหนดความสำคัญให้กับแต่ละโนดในเน็ตเวิร์กในขั้นตอนก่อนหน้าแล้ว จากนั้นจึงจะทำการปรับค่าน้ำหนักตามขั้นตอนวิธีแบ็กพรอพาเกชันดังแสดงในหัวข้อที่ 2.1.2.2

ส่วนโครงสร้างของนิรอรอลเน็ตเวิร์กที่มีการเชื่อมต่ออย่างสมบูรณ์ ค่าคุณลักษณะทุกตัวที่ปรากฏในกฎความสัมพันธ์ของประเภทจะมีการเชื่อมโยงไปยังกฎทุกข้อ ทำให้ไม่สามารถระบุได้ว่าค่าคุณลักษณะตัวใดบ้างที่มีความสำคัญต่อการเลือกกฎแต่ละข้อไปใช้จำแนกประเภทข้อมูล ดังนั้น ก่อนที่จะทำการเรียนรู้เพื่อปรับค่าน้ำหนักให้กับโครงสร้างของนิรอรอลเน็ตเวิร์กแบบเชื่อมต่ออย่างสมบูรณ์ ทั้งที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภทและใช้เพื่อจำแนกประเภทข้อมูล จึงต้องมีการกำหนดความสำคัญให้กับแต่ละโนดในเน็ตเวิร์กด้วยค่าน้ำหนักเริ่มต้นที่แตกต่างกัน ก่อน โดยงานวิจัยนี้ได้นำแนวคิดของ KBANN (Knowledge-Based Artificial Neural Networks) [3, 20, 21] มาประยุกต์ใช้ รายละเอียดสามารถแสดงได้ดังต่อไปนี้

1. การกำหนดค่าน้ำหนักของเส้นเชื่อมระหว่างโนดในชั้นอินพุตและชั้นฮิดเดนให้กับโครงสร้างที่มีการเชื่อมต่ออย่างสมบูรณ์ทั้ง 2 กรณี จะมีลักษณะเช่นเดียวกันกับการกำหนดค่าน้ำหนักของกฎแบบและ (conjunctive rule) กล่าวคือ อินพุตโนดทุกโนดที่เป็นเงื่อนไขของกฎความสัมพันธ์ของประเภท (antecedent) แต่ละข้อจะต้องมีค่าความจริงเป็น “จริง” จึงจะสามารถทำให้กฎข้อนั้นมีค่าความจริงเป็น “จริง” ได้ ดังนั้นค่าน้ำหนักเริ่มต้นของอินพุตโนดทุกโนดที่มีการเชื่อมต่อกับฮิดเดนโนดเพื่อแสดงกฎข้อหนึ่งๆ จะมีค่าน้ำหนักเท่ากับ w และมีค่าเอนเอียง (bias) θ สำหรับฮิดเดนโนดนั้นๆ เท่ากับ $(P-0.5)w$ เมื่อ P คือ จำนวนอินพุตโนดที่สัมพันธ์กับกฎข้อนั้น ส่วนอินพุตโนดอื่นๆ ที่ไม่มีความสัมพันธ์กับกฎ จะมีการกำหนดค่าน้ำหนักเริ่มต้นแบบสุ่มให้มีค่าประมาณ “0”
2. การกำหนดค่าน้ำหนักของเส้นเชื่อมระหว่างโนดในชั้นฮิดเดนและชั้นเอาต์พุตให้กับโครงสร้างที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภท ซึ่งมีการเชื่อมต่ออย่างสมบูรณ์ จะมีลักษณะเช่นเดียวกันกับการกำหนดค่าน้ำหนักของกฎแบบและ กล่าวคือ ฮิดเดนโนดแต่ละโนด ซึ่งเปรียบเสมือนกฎความสัมพันธ์ของประเภทแต่ละข้อ จะต้องมีความจริงเป็น “จริง” จึงจะสามารถทำให้เอาต์พุตโนดที่แสดงผลลัพธ์เป็นกฎความสัมพันธ์ของประเภทข้อนั้นๆ มีค่าความจริงเป็น “จริง” ได้ ดังนั้นค่าน้ำหนักเริ่มต้นของฮิดเดนโนดแต่ละโนดที่มีการเชื่อมต่อกับเอาต์พุตโนดที่สัมพันธ์กัน จะมีค่าน้ำหนักเท่ากับ w และมีค่าเอนเอียง θ สำหรับเอาต์พุตโนดนั้นๆ เท่ากับ $(P-0.5)w$ เมื่อ P คือ จำนวนฮิดเดนโนดที่สัมพันธ์กัน ซึ่งในกรณีนี้ θ ของเอาต์พุตโนดทุกโนดจะมีค่าเท่ากับ $0.5w$ เนื่องจากการเชื่อมต่อระหว่างฮิดเดนโนดและเอาต์พุตโนดของโครงสร้างที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภท จะมีความสัมพันธ์แบบ 1:1 เท่านั้น ส่วนฮิดเดนโนดอื่นๆ ที่ไม่เกี่ยวข้อง จะมีการกำหนดค่าน้ำหนักเริ่มต้นแบบสุ่มให้มีค่าประมาณ “0”
3. การกำหนดค่าน้ำหนักของเส้นเชื่อมระหว่างโนดในชั้นฮิดเดนและชั้นเอาต์พุตให้กับโครงสร้างที่ใช้เพื่อจำแนกประเภทข้อมูล ซึ่งมีการเชื่อมต่ออย่างสมบูรณ์ จะมีลักษณะเช่นเดียวกันกับการกำหนดค่าน้ำหนักของกฎแบบหรือ (disjunctive rule) กล่าวคือ เมื่อฮิดเดนโนดที่แสดงกฎความสัมพันธ์ของประเภทที่มีฉลากประเภทเป็น y โนดใดโนดหนึ่งมีค่าความจริงเป็น “จริง” นิวรอลเน็ตเวิร์กก็จะสามารถแสดงผลลัพธ์เป็นฉลากประเภท y ได้ ดังนั้นค่าน้ำหนักเริ่มต้นของฮิดเดนโนดทุกโนดที่มี

การเชื่อมต่อกับเอาต์พุตโนดที่แสดงฉลากประเภทของกฎข้อนั้น จะมีค่าน้ำหนักเท่ากับ w และมีค่าเอนเอียง θ สำหรับเอาต์พุตโนดนั้นๆ เท่ากับ $w/2$ ส่วนการเชื่อมต่อระหว่างฮิดเดนโนดอื่นๆ กับเอาต์พุตโนดที่แสดงฉลากประเภทที่ไม่สอดคล้องกับกฎข้อนั้น จะมีการกำหนดค่าน้ำหนักเริ่มต้นแบบสุ่มให้มีค่าประมาณ "0"

จากรูปที่ 3.6 และกฎความสัมพันธ์ของประเภทของตัวอย่างการเรียนรู้แนวคิดการตัดสินใจเล่นเทนนิสทั้ง 6 ข้อดังกล่าวข้างต้น สามารถคำนวณค่าน้ำหนักเริ่มต้นให้กับโครงสร้างของแบ็กพรอพาทเกชันนิวรอลเน็ตเวิร์กแบบเชื่อมต่ออย่างสมบูรณ์ที่ใช้เพื่อจำแนกประเภทข้อมูลได้ดังรูปที่ 3.8 โดยเส้นทึบแสดงค่าน้ำหนักเท่ากับ w เส้นประแสดงค่าน้ำหนักประมาณ "0" และ θ_1 ถึง θ_8 มีค่าเท่ากับ $1.5w$, $1.5w$, $0.5w$, $1.5w$, $1.5w$, $1.5w$, $w/2$ และ $w/2$ ตามลำดับ



รูปที่ 3.8 ค่าน้ำหนักเริ่มต้นที่กำหนดให้กับโครงสร้างของแบ็กพรอพาทเกชันนิวรอลเน็ตเวิร์กแบบเชื่อมต่ออย่างสมบูรณ์ที่ใช้ในตัวอย่างการเรียนรู้แนวคิดการตัดสินใจเล่นเทนนิส

หลังจากทำการกำหนดค่าน้ำหนักเริ่มต้นให้กับโครงสร้างของนิวรอลเน็ตเวิร์กที่มีการเชื่อมต่ออย่างสมบูรณ์ทั้งที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภทและใช้เพื่อจำแนกประเภทข้อมูลโดยตรงแล้ว จะทำการปรับค่าน้ำหนักของเน็ตเวิร์กด้วยขั้นตอนวิธีแบ็กพรอพาทเกชันเช่นเดียวกันกับโครงสร้างของนิวรอลเน็ตเวิร์กที่มีการเชื่อมต่อแบบบางส่วน

บทที่ 4

การทดลองและผลการทดลอง

บทนี้จะกล่าวถึงรายละเอียดของการทดลองและผลการทดลองที่ได้จากการประยุกต์ใช้แบ็กพรอพาเกชันนิเวรอลเน็ตเวิร์กเพื่อจำแนกประเภทจากกฎความสัมพันธ์ของประเภท โดยทำการเปรียบเทียบผลลัพธ์ความแม่นยำของการจำแนกประเภทข้อมูลที่ได้จากวิธีการนี้ กับวิธีการเรียนรู้ของเครื่องแบบ C4.5 ขั้นตอนวิธี CBA เดิม และ CPAR

เนื้อหาในบทนี้จะแบ่งออกเป็น 3 ส่วนด้วยกัน โดยเนื้อหาในส่วนแรกจะกล่าวถึงชุดข้อมูลที่ใช้ในการทดลอง ส่วนต่อมากล่าวถึงรายละเอียดของวิธีการทดลอง และเนื้อหาในส่วนสุดท้ายจะกล่าวถึงผลการทดลอง

4.1 ชุดข้อมูลที่ใช้ในการทดลอง

ในการทดลองเพื่อเปรียบเทียบความแม่นยำของวิธีการที่นำเสนอในงานวิจัยนี้ กับวิธีการจำแนกประเภทข้อมูลอื่นๆ ดังกล่าวข้างต้น จะนำชุดข้อมูลจาก UCI Repository of Machine Learning Databases [11] จำนวน 12 ชุดมาใช้ในการทดสอบ โดยมีเกณฑ์การเลือกชุดข้อมูลตามลำดับต่อไปนี้

1. เป็นชุดข้อมูลซึ่งงานวิจัย [5] และ [10] เลือกมาใช้ในการทดสอบขั้นตอนวิธี CBA เดิม และ CPAR ตามลำดับ
2. เป็นชุดข้อมูลซึ่งสามารถทำการค้นหาความสัมพันธ์ของประเภทได้สมบูรณ์หรือค่อนข้างสมบูรณ์ เมื่อจำกัดจำนวนของกฎคู่แข่ง (candidate rule) ในระหว่างขั้นตอนการค้นหาที่ 80,000 ข้อ เนื่องจากงานวิจัย [5] กล่าวไว้ว่า เนื่องด้วยข้อจำกัดเรื่องหน่วยความจำของเครื่องคอมพิวเตอร์ที่ใช้ทดลอง บางชุดข้อมูลจะไม่สามารถทำการค้นหาความสัมพันธ์ของประเภทได้สมบูรณ์ จึงจำเป็นต้องมีการจำกัดจำนวนของกฎคู่แข่งที่ถูกสร้างขึ้น และจากการทดลองของงานวิจัย [5] ยังแสดงให้เห็นว่าจำนวนของกฎคู่แข่งที่เกินกว่า 80,000 ข้อ ไม่มีผลต่อผลลัพธ์ความแม่นยำของการจำแนกประเภทข้อมูลเท่าไรนัก ดังนั้น งานวิจัยนี้จึงมีการกำหนดเงื่อนไขของการเลือกชุดข้อมูลในลักษณะดังกล่าวข้างต้น
3. เป็นชุดข้อมูลซึ่งเซตของกฎความสัมพันธ์ของประเภทที่ได้จากขั้นตอนวิธี CBA แบบไม่มีการตัดเล็ม แตกต่างจากเซตของกฎที่ได้จากวิธีการเรียนรู้ของเครื่องแบบ C4.5

รายละเอียดของแต่ละชุดข้อมูลที่ใช้ในการทดลอง สามารถแสดงได้ดังตารางที่ 4.1

ตารางที่ 4.1 รายละเอียดของชุดข้อมูลที่ใช้ในการทดลอง

ชุดข้อมูล	จำนวนข้อมูล	จำนวนประเภทข้อมูล	จำนวนคุณลักษณะ			ข้อมูลไม่ทราบค่า
			ข้อมูลต่อเนื่อง	ข้อมูลไม่ต่อเนื่อง	ทั้งหมด	
Breast-w	699	2	0	10	10	มี
Cleve	303	2	6	7	13	มี
Diabetes	768	2	8	0	8	ไม่มี
Glass	214	7	9	1	10	ไม่มี
Heart	270	2	13	0	13	ไม่มี
Hepatitis	155	2	6	13	19	มี
Iris	150	3	4	0	4	ไม่มี
Lymph	148	4	0	18	18	ไม่มี
Pima	768	2	8	0	8	ไม่มี
Tic-Tac-Toe	958	2	0	9	9	ไม่มี
Wine	178	3	13	0	13	ไม่มี
Zoo	101	7	0	17	17	ไม่มี

4.2 วิธีการทดลอง

การทดลองเริ่มจากการนำชุดข้อมูลที่มีข้อมูลต่อเนื่องมาแปลงเป็นข้อมูลไม่ต่อเนื่องด้วยเครื่องมือ DM2 CBA ซึ่งนำหลักการของ Entropy method ที่นำเสนอในงานวิจัย [22] มาใช้ จากนั้นนำชุดข้อมูลที่ได้มาทำการค้นหากฎความสัมพันธ์ของประเภทด้วยเครื่องมือ DM2 CBA โดยกฎที่ไม่มีการตัดเต็มทั้งหมดจะถูกนำไปใช้ในการกำหนดโครงสร้างให้กับแบ็กพรอพาทาเกชันนิวรอลเน็ตเวิร์ก ส่วนชุดข้อมูลที่ผ่านการแปลงแล้ว จะถูกนำมาแบ่งออกเป็นชุดข้อมูลสอนและชุดข้อมูลทดสอบด้วยวิธี 6-fold cross validation [3] เพื่อนำไปใช้ในการเรียนรู้ของนิวรอลเน็ตเวิร์กต่อไป

หลังจากทำการสร้างโครงสร้างของแบ็กพรอพาทาเกชันนิวรอลเน็ตเวิร์กจากกฎความสัมพันธ์ของประเภท ด้วยเครื่องมือ Qnet for Windows V2K แล้ว ชุดข้อมูลสอนจะถูกนำมาใช้สอนนิวรอลเน็ตเวิร์ก เพื่อทำการปรับค่าน้ำหนักของเส้นเชื่อมในเน็ตเวิร์กให้มีค่าผิดพลาดการสอนน้อยที่สุด ในการทดลอง กำหนดให้เน็ตเวิร์กมีค่าอัตราการเรียนรู้เป็น 0.0001 และค่าโมเมนตัม

(momentum) เป็น 0.80 โดยกระบวนการเรียนรู้จะหยุดเมื่อค่าความผิดพลาดมีค่าน้อยกว่า 0.05 หรือจำนวนรอบการสอนครบ 10,000 รอบ จากนั้นนำนิรอลเน็ตเวิร์กที่ได้มาทดสอบกับชุดข้อมูลทดสอบ โดยโนดในชั้นเอาต์พุตที่มีค่าน้ำหนักมากที่สุดจะถูกเลือกเพื่อนำไปใช้ในการจำแนกประเภทข้อมูล

การประเมินประสิทธิภาพของวิธีการที่นำเสนอในงานวิจัยนี้ จะทำการเปรียบเทียบผลลัพธ์ความแม่นยำของการจำแนกประเภทข้อมูลที่ได้ กับวิธีการเรียนรู้ของเครื่องแบบ C4.5 เนื่องจากเป็นวิธีการจำแนกประเภทข้อมูลที่สร้างกฎประพจน์ที่มนุษย์สามารถทำความเข้าใจได้เหมือนกัน แต่เซตของกฎที่ได้จากวิธีการทั้งสองอาจมีความแตกต่างกันดังกล่าวในหัวข้อที่ 3.2.1 ซึ่งส่งผลให้ความถูกต้องในการจำแนกประเภทข้อมูลมีความแตกต่างกัน งานวิจัยนี้ยังทำการเปรียบเทียบผลลัพธ์ที่ได้กับขั้นตอนวิธี CBA เดิม และ CPAR เนื่องจากงานวิจัย [10] แสดงให้เห็นว่าขั้นตอนวิธี CPAR เป็นขั้นตอนวิธีทางด้านการจำแนกประเภทเชิงความสัมพันธ์ที่ให้ค่าเฉลี่ยของผลลัพธ์ความถูกต้องจากการจำแนกประเภทข้อมูลที่ดีที่สุด

4.3 ผลการทดลอง

การทดสอบตัวจำแนกประเภทข้อมูลที่ได้จากงานวิจัยนี้ว่าสามารถจำแนกประเภทข้อมูลได้ถูกต้องหรือไม่นั้น ในกรณีของนิรอลเน็ตเวิร์กที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภทจะพิจารณาจากเงื่อนไขและฉลากประเภทของกฎที่เป็นผลลัพธ์จากการเรียนรู้ของนิรอลเน็ตเวิร์ก ว่าสอดคล้องกันกับค่าคุณลักษณะและฉลากประเภทของข้อมูลทดสอบหรือไม่ ถ้ามีความสอดคล้องกัน แสดงว่าเน็ตเวิร์กนั้นๆ สามารถจำแนกประเภทได้ถูกต้อง ส่วนนิรอลเน็ตเวิร์กในอีกกรณีหนึ่งซึ่งใช้เพื่อจำแนกประเภทข้อมูลโดยตรง การจะแสดงว่าตัวจำแนกประเภทข้อมูลสามารถจำแนกประเภทได้ถูกต้องนั้น ฉลากประเภทที่เป็นผลลัพธ์จากการเรียนรู้ของนิรอลเน็ตเวิร์กจะต้องสอดคล้องกันกับฉลากประเภทของข้อมูลทดสอบ

ผลลัพธ์ความแม่นยำของการนำนิรอลเน็ตเวิร์กมาประยุกต์ใช้กับการจำแนกประเภทข้อมูลใน 2 ลักษณะ คือ เพื่อคัดเลือกกฎที่จะนำไปใช้ในการจำแนกประเภทข้อมูล และเพื่อใช้ในการจำแนกประเภทข้อมูล โดยใช้โครงสร้างของนิรอลเน็ตเวิร์กแบบเชื่อมต่อบางส่วนและแบบเชื่อมต่อย่างสมบูรณ์ เปรียบเทียบกับวิธีการเรียนรู้ของเครื่องแบบ C4.5 ขั้นตอนวิธี CBA เดิม และ CPAR สามารถแสดงได้ดังตารางที่ 4.2 โดยตัวหนาแสดงค่าความแม่นยำสูงสุดในแต่ละชุดข้อมูล และแถวสุดท้ายของตารางแสดงค่าเฉลี่ยของผลลัพธ์ที่ได้จากทั้ง 12 ชุดข้อมูล

ตารางที่ 4.2 ผลลัพธ์ความแม่นยำของการจำแนกประเภทข้อมูลที่ได้จากการประยุกต์ใช้แบ็กพรอพาเกชันนิรอลเน็ตเวิร์กเพื่อจำแนกประเภท จากกฎความสัมพันธ์ของประเภท เปรียบเทียบกับวิธีการเรียนรู้ของเครื่องแบบ C4.5 ขั้นตอนวิธี CBA เดิม และ CPAR

ชุดข้อมูล	C4.5	CBA เดิม	CPAR	แบ็กพรอพาเกชันนิรอลเน็ตเวิร์กที่ใช้เพื่อคัดเลือก กฎความสัมพันธ์ของประเภท		แบ็กพรอพาเกชันนิรอลเน็ตเวิร์กที่ใช้เพื่อจำแนก ประเภทข้อมูล	
				แบบเชื่อมต่อบางส่วน	แบบเชื่อมต่ออย่างสมบูรณ์	แบบเชื่อมต่อบางส่วน	แบบเชื่อมต่ออย่างสมบูรณ์
Breast-w	97.42	96.13	99.14	99.43	99.57	99.57	99.57
Cleve	81.42	81.77	93.71	95.36	96.69	97.68	97.68
Diabetes	77.32	76.38	79.27	80.05	81.10	80.31	81.49
Glass	66.34	76.47	79.34	83.10	83.10	84.51	84.51
Heart	81.41	82.53	90.71	94.42	94.80	95.17	95.17
Hepatitis	82.48	82.93	94.81	98.70	98.70	100.00	100.00
Iris	94.00	94.58	95.97	95.97	96.64	95.97	96.64
Lymph	73.70	77.93	100.00	98.65	98.65	99.32	100.00
Pima	79.80	75.88	79.27	81.36	81.36	81.10	81.23
Tic-Tac-Toe	99.59	98.87	100.00	100.00	100.00	100.00	100.00
Wine	93.30	98.88	100.00	100.00	100.00	100.00	100.00
Zoo	96.02	98.88	100.00	97.03	99.01	99.01	100.00
ค่าเฉลี่ย	85.23	86.77	92.69	93.67	94.14	94.39	94.69

ตารางที่ 4.3 การเปรียบเทียบผลลัพธ์ความแม่นยำด้วยค่าระดับความเชื่อมั่น ระหว่างนิรอลเน็ตเวิร์กที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภท ซึ่งเชื่อมต่อแบบบางส่วน กับนิรอลเน็ตเวิร์กที่นำเสนอในงานวิจัยนี้แบบอื่นๆ วิธีการเรียนรู้ของเครื่องแบบ C4.5 ขั้นตอนวิธี CBA เดิม และ CPAR

ชุดข้อมูล	ค่าระดับความเชื่อมั่นของนิรอลเน็ตเวิร์กที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภทซึ่งเชื่อมต่อแบบบางส่วน เปรียบเทียบกับ					
	C4.5	CBA เดิม	CPAR	นิรอลเน็ตเวิร์กที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภทซึ่งเชื่อมต่อแบบสมบูรณ์	นิรอลเน็ตเวิร์กที่ใช้เพื่อจำแนกประเภทข้อมูลซึ่งเชื่อมต่อแบบบางส่วน	นิรอลเน็ตเวิร์กที่ใช้เพื่อจำแนกประเภทข้อมูลซึ่งเชื่อมต่อแบบสมบูรณ์
Breast-w	+ 99	+ 99	+ 90	=	=	=
Cleve	+ 99	+ 99	+ 90	=	=	=
Diabetes	+ 85	+ 90	=	=	=	=
Glass	+ 99	+ 99	+ 90	=	=	=
Heart	+ 99	+ 99	+ 95	=	=	=
Hepatitis	+ 99	+ 99	+ 90	=	=	=
Iris	=	=	=	=	=	=
Lymph	+ 99	+ 99	=	=	=	=
Pima	=	+ 99	+ 90	=	=	=
Tic-Tac-Toe	+ 98	+ 99	=	=	=	=
Wine	+ 99	=	=	=	=	=
Zoo	=	=	=	=	=	=
ชนะ-แพ้-เสมอ	9-0-3	9-0-3	6-0-6	0-0-12	0-0-12	0-0-12

ตารางที่ 4.4 การเปรียบเทียบผลลัพธ์ความแม่นยำด้วยค่าระดับความเชื่อมั่น ระหว่างนิรอลเน็ตเวิร์กที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภท
ซึ่งเชื่อมต่อแบบสมบูรณ์ กับนิรอลเน็ตเวิร์กที่นำเสนอในงานวิจัยนี้แบบอื่นๆ วิธีการเรียนรู้ของเครื่องแบบ C4.5 ขั้นตอนวิธี CBA เดิม และ CPAR

ชุดข้อมูล	ค่าระดับความเชื่อมั่นของนิรอลเน็ตเวิร์กที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภทซึ่งเชื่อมต่อแบบสมบูรณ์ เปรียบเทียบกับ					
	C4.5	CBA เดิม	CPAR	นิรอลเน็ตเวิร์กที่ใช้เพื่อคัดเลือก กฎความสัมพันธ์ของประเภท ซึ่งเชื่อมต่อแบบบางส่วน	นิรอลเน็ตเวิร์ก ที่ใช้เพื่อจำแนกประเภทข้อมูล ซึ่งเชื่อมต่อแบบบางส่วน	นิรอลเน็ตเวิร์ก ที่ใช้เพื่อจำแนกประเภทข้อมูล ซึ่งเชื่อมต่อแบบสมบูรณ์
Breast-w	+ 99	+ 99	+ 85	=	=	=
Cleve	+ 99	+ 99	+ 90	=	=	=
Diabetes	+ 90	+ 99	+ 95	+ 85	=	=
Glass	+ 99	+ 99	+ 85	=	=	=
Heart	+ 99	+ 99	+ 95	=	=	=
Hepatitis	+ 99	+ 99	+ 90	=	=	=
Iris	=	+ 85	=	=	=	=
Lymph	+ 99	+ 99	=	=	=	=
Pima	=	+ 99	+ 95	=	=	=
Tic-Tac-Toe	+ 98	+ 99	=	=	=	=
Wine	+ 99	=	=	=	=	=
Zoo	+ 95	=	=	+ 90	=	=
ชนะ-แพ้-เสมอ	10-0-2	10-0-2	7-0-5	2-0-10	0-0-12	0-0-12

ตารางที่ 4.5 การเปรียบเทียบผลลัพธ์ความแม่นยำด้วยค่าระดับความเชื่อมั่น ระหว่างนิรอลเน็ตเวิร์กที่ใช้เพื่อจำแนกประเภทข้อมูล ซึ่งเชื่อมต่อแบบบางส่วน กับนิรอลเน็ตเวิร์กที่นำเสนอในงานวิจัยนี้แบบอื่นๆ วิธีการเรียนรู้ของเครื่องแบบ C4.5 ขั้นตอนวิธี CBA เดิม และ CPAR

ชุดข้อมูล	ค่าระดับความเชื่อมั่นของนิรอลเน็ตเวิร์กที่ใช้เพื่อจำแนกประเภทข้อมูลซึ่งเชื่อมต่อแบบบางส่วน เปรียบเทียบกับ					
	C4.5	CBA เดิม	CPAR	นิรอลเน็ตเวิร์กที่ใช้เพื่อคัดเลือก กฎความสัมพันธ์ของประเภท ซึ่งเชื่อมต่อแบบบางส่วน	นิรอลเน็ตเวิร์กที่ใช้เพื่อคัดเลือก กฎความสัมพันธ์ของประเภท ซึ่งเชื่อมต่อแบบสมบูรณ์	นิรอลเน็ตเวิร์ก ที่ใช้เพื่อจำแนกประเภทข้อมูล ซึ่งเชื่อมต่อแบบสมบูรณ์
Breast-w	+ 99	+ 99	+ 95	=	=	=
Cleve	+ 99	+ 99	+ 90	+ 85	=	=
Diabetes	+ 85	+ 97	=	=	=	=
Glass	+ 99	+ 99	+ 95	=	+ 95	=
Heart	+ 99	+ 99	+ 99	=	=	=
Hepatitis	+ 99	+ 99	+ 90	+ 90	+ 90	=
Iris	=	=	=	=	=	=
Lymph	+ 99	+ 99	=	=	=	=
Pima	=	+ 99	+ 95	=	=	=
Tic-Tac-Toe	+ 98	+ 99	=	=	=	=
Wine	+ 99	=	=	=	=	=
Zoo	+ 95	=	=	+ 90	=	=
ชนะ-แพ้-เสมอ	10-0-2	9-0-3	6-0-6	3-0-9	2-0-10	0-0-12

ตารางที่ 4.6 การเปรียบเทียบผลลัพธ์ความแม่นยำด้วยค่าระดับความเชื่อมั่น ระหว่างนิเวศเน็ตเวิร์กที่ใช้เพื่อจำแนกประเภทข้อมูล ซึ่งเชื่อมต่อบนแบบสมบูร์น กับนิเวศเน็ตเวิร์กที่นำเสนอในงานวิจัยนี้แบบอื่นๆ วิธีการเรียนรู้ของเครื่องแบบ C4.5 ขั้นตอนวิธี CBA เดิม และ CPAR

ชุดข้อมูล	ค่าระดับความเชื่อมั่นของนิเวศเน็ตเวิร์กที่ใช้เพื่อจำแนกประเภทข้อมูลซึ่งเชื่อมต่อบนแบบสมบูร์น เปรียบเทียบกับ					
	C4.5	CBA เดิม	CPAR	นิเวศเน็ตเวิร์กที่ใช้เพื่อคัดเลือก กฎความสัมพันธ์ของประเภท ซึ่งเชื่อมต่อบนแบบบางส่วน	นิเวศเน็ตเวิร์กที่ใช้เพื่อคัดเลือก กฎความสัมพันธ์ของประเภท ซึ่งเชื่อมต่อบนแบบสมบูร์น	นิเวศเน็ตเวิร์ก ที่ใช้เพื่อจำแนกประเภทข้อมูล ซึ่งเชื่อมต่อบนแบบบางส่วน
Breast-w	+ 99	+ 99	+ 85	=	=	=
Cleve	+ 99	+ 99	+ 90	+ 85	+ 95	=
Diabetes	+ 85	+ 99	+ 95	=	=	=
Glass	+ 99	+ 99	+ 95	=	+ 95	=
Heart	+ 99	+ 99	+ 99	+ 90	=	=
Hepatitis	+ 99	+ 99	+ 90	+ 90	+ 90	=
Iris	=	+ 85	=	=	=	=
Lymph	+ 99	+ 99	=	=	=	=
Pima	=	+ 98	+ 98	=	=	=
Tic-Tac-Toe	+ 98	+ 99	=	=	=	=
Wine	+ 99	=	=	=	=	=
Zoo	+ 98	+ 90	=	+ 95	=	=
ชนะ-แพ้-เสมอ	10-0-2	11-0-1	7-0-5	4-0-8	3-0-9	0-0-12

ในการเปรียบเทียบวิธีการที่น่าเสนอในงานวิจัยนี้กับวิธีการจำแนกประเภทข้อมูลอื่นๆ ว่าวิธีการใดมีประสิทธิภาพที่ดีกว่า งานวิจัยนี้จะทำการเปรียบเทียบโดยดูจากค่าระดับความเชื่อมั่น เพื่อแสดงว่าวิธีการหนึ่งดีกว่าอีกวิธีการหนึ่งด้วยค่าความเชื่อมั่นเท่าไรอย่างมีนัยสำคัญทางสถิติ โดยค่าระดับความเชื่อมั่นมักแสดงเป็นค่าร้อยละ การเปรียบเทียบผลลัพธ์ความแม่นยำด้วยค่าระดับความเชื่อมั่นระหว่างแบ็กพรอพาเกชันนิเวรอลเน็ตเวิร์กที่น่าเสนอในงานวิจัยนี้ทั้ง 4 กรณี กับวิธีการจำแนกประเภทข้อมูลอื่นๆ สามารถแสดงได้ดังตารางที่ 4.3, 4.4, 4.5 และ 4.6 ตามลำดับ

จากตารางที่ 4.3, 4.4, 4.5 และ 4.6 การแสดงค่าระดับความเชื่อมั่นของการนำนิเวรอลเน็ตเวิร์กมาประยุกต์ใช้กับการจำแนกประเภทเชิงความสัมพันธ์ เปรียบเทียบกับวิธีการเรียนรู้ของเครื่องแบบ C4.5 ขั้นตอนวิธี CBA เดิม และ CPAR สามารถแบ่งออกได้เป็น 2 กรณี คือ

- + N% แสดงกรณีที่ผลลัพธ์ความแม่นยำของการจำแนกประเภทข้อมูลด้วยวิธีการที่น่าเสนอ มีค่ามากกว่าวิธีการจำแนกประเภทข้อมูลอื่นๆ ที่นำมาใช้เปรียบเทียบอย่างมีนัยสำคัญทางสถิติ ด้วยค่าระดับความเชื่อมั่นมากกว่าหรือเท่ากับ N%
- = แสดงกรณีที่ผลลัพธ์ความแม่นยำของการจำแนกประเภทข้อมูลด้วยวิธีการที่น่าเสนอ กับวิธีการจำแนกประเภทข้อมูลอื่นๆ ที่นำมาใช้เปรียบเทียบ ไม่มีความแตกต่างกันอย่างมีนัยสำคัญทางสถิติ โดยในงานวิจัยนี้จะเปรียบเทียบว่าค่าระดับความเชื่อมั่นที่น้อยกว่า 85% ถือว่าไม่มีนัยสำคัญทางสถิติ

จากค่าเฉลี่ยดังแสดงในแถวสุดท้ายของตารางที่ 4.2 จะเห็นว่าค่าเฉลี่ยของความแม่นยำของการจำแนกประเภทข้อมูลด้วยแบ็กพรอพาเกชันนิเวรอลเน็ตเวิร์กที่น่าเสนอในงานวิจัยนี้ทั้ง 4 กรณี มีค่ามากกว่าค่าเฉลี่ยของความแม่นยำที่ได้จากวิธีการเรียนรู้ของเครื่องแบบ C4.5 ขั้นตอนวิธี CBA เดิม และ CPAR โดยนิเวรอลเน็ตเวิร์กที่ใช้เพื่อจำแนกประเภทข้อมูล ซึ่งใช้การเชื่อมต่อของโครงสร้างแบบสมบรูณ์ระหว่างชั้นอินพุตและชั้นฮิดเดน มีค่าเฉลี่ยของผลลัพธ์ความถูกต้องจากการจำแนกประเภทข้อมูลมากที่สุด

และจากการเปรียบเทียบผลลัพธ์ความแม่นยำของการจำแนกประเภทข้อมูลด้วยค่าระดับความเชื่อมั่นดังแสดงข้างต้น จะได้ว่า

1. นวัตกรรมเน็ตเวิร์กที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภท ซึ่งมีการเชื่อมต่อแบบบางส่วน มีค่าผลลัพธ์ความแม่นยำมากกว่าวิธีการเรียนรู้ของเครื่องแบบ C4.5 ขั้นตอนวิธี CBA เดิม และ CPAR เป็นจำนวน 9, 9 และ 6 ชุดข้อมูล ตามลำดับ และเมื่อเปรียบเทียบกับนวัตกรรมเน็ตเวิร์กแบบอื่นๆ อีก 3 แบบที่นำเสนอในงานวิจัยนี้ แสดงให้เห็นว่าทั้งหมดจะมีค่าผลลัพธ์ที่ใกล้เคียงกัน
2. นวัตกรรมเน็ตเวิร์กที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภท ซึ่งมีการเชื่อมต่อแบบสมบูรณ์ มีค่าผลลัพธ์ความแม่นยำมากกว่าวิธีการเรียนรู้ของเครื่องแบบ C4.5 ขั้นตอนวิธี CBA เดิม และ CPAR เป็นจำนวน 10, 10 และ 7 ชุดข้อมูล ตามลำดับ และเมื่อเปรียบเทียบกับนวัตกรรมเน็ตเวิร์กแบบอื่นๆ จะมีค่าผลลัพธ์มากกว่านวัตกรรมเน็ตเวิร์กที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภท ซึ่งมีการเชื่อมต่อแบบบางส่วน เป็นจำนวน 2 ชุดข้อมูล และมีค่าผลลัพธ์ที่ใกล้เคียงกันเมื่อเปรียบเทียบกับนวัตกรรมเน็ตเวิร์กอีก 2 แบบที่เหลือ
3. นวัตกรรมเน็ตเวิร์กที่ใช้เพื่อจำแนกประเภทข้อมูล ซึ่งมีการเชื่อมต่อแบบบางส่วน มีค่าผลลัพธ์ความแม่นยำมากกว่าวิธีการเรียนรู้ของเครื่องแบบ C4.5 ขั้นตอนวิธี CBA เดิม และ CPAR เป็นจำนวน 10, 9 และ 6 ชุดข้อมูล ตามลำดับ และเมื่อเปรียบเทียบกับนวัตกรรมเน็ตเวิร์กแบบอื่นๆ จะมีค่าผลลัพธ์มากกว่านวัตกรรมเน็ตเวิร์กที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภท ซึ่งมีการเชื่อมต่อแบบบางส่วน และการเชื่อมต่อแบบสมบูรณ์ เป็นจำนวน 3 และ 2 ชุดข้อมูล ตามลำดับ ส่วนนวัตกรรมเน็ตเวิร์กที่ใช้เพื่อจำแนกประเภทข้อมูล ซึ่งมีการเชื่อมต่อแบบสมบูรณ์ จะมีค่าผลลัพธ์ที่ใกล้เคียงกัน
4. นวัตกรรมเน็ตเวิร์กที่ใช้เพื่อจำแนกประเภทข้อมูล ซึ่งมีการเชื่อมต่อแบบสมบูรณ์ มีค่าผลลัพธ์ความแม่นยำมากกว่าวิธีการเรียนรู้ของเครื่องแบบ C4.5 ขั้นตอนวิธี CBA เดิม และ CPAR เป็นจำนวน 10, 11 และ 7 ชุดข้อมูล ตามลำดับ และเมื่อเปรียบเทียบกับนวัตกรรมเน็ตเวิร์กแบบอื่นๆ จะมีค่าผลลัพธ์มากกว่านวัตกรรมเน็ตเวิร์กที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภท ซึ่งมีการเชื่อมต่อแบบบางส่วน และการเชื่อมต่อแบบสมบูรณ์ เป็นจำนวน 4 และ 3 ชุดข้อมูล ตามลำดับ ส่วนนวัตกรรมเน็ตเวิร์กที่ใช้เพื่อจำแนกประเภทข้อมูล ซึ่งมีการเชื่อมต่อแบบบางส่วน จะมีค่าผลลัพธ์ที่ใกล้เคียงกัน

ส่วนชุดข้อมูลอื่นๆ ที่ไม่ได้กล่าวถึง ผลลัพธ์ความแม่นยำของการจำแนกประเภทข้อมูล ด้วยวิธีการที่นำเสนอทั้ง 4 กรณี และวิธีการจำแนกประเภทข้อมูลอื่นๆ ที่นำมาใช้เปรียบเทียบ จะมีผลลัพธ์ที่ใกล้เคียงกันอย่างมีนัยสำคัญทางสถิติ และจากทั้ง 12 ชุดข้อมูล ไม่มีข้อมูลชุดใดเลย ที่ผลลัพธ์ของวิธีการที่นำเสนอทั้ง 4 กรณีนี้ มีค่าต่ำกว่า

ดังกล่าวข้างต้นว่าผลลัพธ์ความแม่นยำของการจำแนกประเภทข้อมูลที่ได้จากนิรवलเน็ตเวิร์กที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภท พิจารณาจากความสอดคล้องของกฎที่เป็นผลลัพธ์จากการเรียนรู้ของนิรवलเน็ตเวิร์กกับข้อมูลทดสอบ กล่าวคือ เงื่อนไขของกฎทุกตัวและฉลากประเภทของกฎนั้นๆ จะต้องตรงกันกับค่าคุณลักษณะและฉลากประเภทในข้อมูลทดสอบ จึงจะถือว่าสามารถจำแนกประเภทได้ถูกต้อง ดังนั้น ผู้วิจัยจึงได้ทำการศึกษาเปรียบเทียบว่าในกรณีที่ไม่มีกฎที่ตรงพอดี นิรवलเน็ตเวิร์กที่นำเสนอนี้จะสามารถคัดเลือกกฎที่มีความเหมาะสมที่สุดไปใช้จำแนกประเภทข้อมูลได้หรือไม่ โดยผลลัพธ์ความแม่นยำของการจำแนกประเภทข้อมูลสามารถแสดงได้ดังตารางที่ 4.7

จากผลลัพธ์ความแม่นยำดังแสดงในสมมติที่ 4 และ 7 ของตารางที่ 4.7 จะเห็นว่าการใช้กฎที่ตรงพอดีร่วมกับกฎที่มีความเหมาะสมที่สุดจากการปรับค่าน้ำหนักของนิรवलเน็ตเวิร์กในการจำแนกประเภทข้อมูล ทำให้ผลลัพธ์ความแม่นยำมีค่าเพิ่มขึ้นเล็กน้อย เมื่อเปรียบเทียบกับกรณีที่ใช้กฎที่ตรงพอดีเพียงอย่างเดียว และจากการเปรียบเทียบกฎที่มีความเหมาะสมที่สุดที่เป็นผลลัพธ์จากการเรียนรู้ของนิรवलเน็ตเวิร์กกับข้อมูลทดสอบ พบว่ากฎนั้นๆ มีเงื่อนไขบางส่วนของกฎสอดคล้องกันกับค่าคุณลักษณะในข้อมูลทดสอบ ซึ่งแสดงให้เห็นว่าในกรณีที่ไม่มีกฎที่ตรงพอดี นิรवलเน็ตเวิร์กจะเลือกกฎที่มีนัยทั่วไปมากกว่า (more general) มาใช้ในการจำแนกประเภทข้อมูลนั่นเอง

สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

ตารางที่ 4.7 ผลลัพธ์ความแม่นยำในการจำแนกประเภทข้อมูลของนิรอลเน็ตเวิร์กที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภท
ที่ได้จากการใช้กฎที่ตรงพอดีร่วมกับกฎที่มีความเหมาะสมที่สุด เปรียบเทียบกับการใช้กฎที่ตรงพอดีเพียงอย่างเดียว

ชุดข้อมูล	นิรอลเน็ตเวิร์กที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภท แบบเชื่อมต่อบางส่วน			นิรอลเน็ตเวิร์กที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภท แบบเชื่อมต่อสมบูรณ์		
	กฎที่ตรงพอดี	จำนวนข้อมูลที่จำแนกประเภท ได้ถูกต้องเพิ่มขึ้น	กฎที่ตรงพอดี + กฎที่เหมาะสมที่สุด	กฎที่ตรงพอดี	จำนวนข้อมูลที่จำแนกประเภท ได้ถูกต้องเพิ่มขึ้น	กฎที่ตรงพอดี + กฎที่เหมาะสมที่สุด
Breast-w	99.43	1	99.57	99.57	-	99.57
Cleve	95.36	2	96.03	96.69	2	97.35
Diabetes	80.05	-	80.05	81.10	-	81.10
Glass	83.10	-	83.10	83.10	-	83.10
Heart	94.42	1	94.80	94.80	-	94.80
Hepatitis	98.70	-	98.70	98.70	-	98.70
Iris	95.97	-	95.97	96.64	-	96.64
Lymph	98.65	-	98.65	98.65	-	98.65
Pima	81.36	-	81.36	81.36	-	81.36
Tic-Tac-Toe	100.00	-	100.00	100.00	-	100.00
Wine	100.00	-	100.00	100.00	-	100.00
Zoo	97.03	1	98.02	99.01	-	99.01
ค่าเฉลี่ย	93.67	-----	93.85	94.14	-----	94.19

จากการเปรียบเทียบการนำแบ็กพรอพากะชันนิวรอลเน็ตเวิร์กมาประยุกต์ใช้กับการจำแนกประเภทเชิงความสัมพันธ์ใน 2 ลักษณะ คือ เพื่อคัดเลือกกฎความสัมพันธ์ของประเภทที่จะนำไปใช้ จำแนกประเภทข้อมูล และเพื่อใช้จำแนกประเภทข้อมูลโดยตรง จะเห็นว่านิวรอลเน็ตเวิร์กที่ใช้ในการจำแนกประเภทข้อมูลโดยตรง ซึ่งให้ผลลัพธ์เป็นฉลากประเภทตามธรรมชาติของการเรียนรู้ของนิวรอลเน็ตเวิร์ก ยังคงมีประสิทธิภาพในการจำแนกประเภทข้อมูลมากกว่านิวรอลเน็ตเวิร์กที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภท อย่างไรก็ตาม ถึงแม้ว่านิวรอลเน็ตเวิร์กที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภทจะมีค่าผลลัพธ์ที่ต่ำกว่าเล็กน้อย แต่การนำนิวรอลเน็ตเวิร์กมาใช้ในลักษณะนี้ก็ยังมีข้อดีที่นิวรอลเน็ตเวิร์กที่ใช้ในการจำแนกประเภทข้อมูลไม่สามารถกระทำได้ คือ สามารถระบุกฎหรือนัยทั่วไปของกฎที่ใช้จำแนกประเภทข้อมูลได้โดยตรง กล่าวอีกนัยหนึ่งคือ ทำให้สามารถบอกถึงค่าของคุณลักษณะที่มีผลต่อการจำแนกประเภทข้อมูลได้

และจากการเปรียบเทียบผลลัพธ์ความแม่นยำของการจำแนกประเภทข้อมูลระหว่างโครงสร้างของนิวรอลเน็ตเวิร์กที่มีการเชื่อมต่อแบบบางส่วน กับโครงสร้างของนิวรอลเน็ตเวิร์กที่มีการเชื่อมต่ออย่างสมบูรณ์ จะเห็นว่ากรณีที่โครงสร้างที่มีการเชื่อมต่ออย่างสมบูรณ์มีประสิทธิภาพในการจำแนกประเภทข้อมูลมากกว่าโครงสร้างที่มีการเชื่อมต่อแบบบางส่วน อาจจะเป็นเนื่องจากวิธีการกำหนดค่าน้ำหนักเริ่มต้นให้กับเน็ตเวิร์กที่แตกต่างกัน กล่าวคือ โครงสร้างที่มีการเชื่อมต่อแบบบางส่วน มีการกำหนดค่าน้ำหนักเริ่มต้นแบบสุ่มให้มีค่าน้อยๆ ทำให้ค่าน้ำหนักที่ได้อาจจะไม่ได้อยู่ในท้องถิ่นที่ดีเท่าไรนัก จึงทำให้ผลลัพธ์จากการเรียนรู้ของนิวรอลเน็ตเวิร์กในลักษณะนี้มีค่าที่ต่ำกว่าเล็กน้อย ส่วนโครงสร้างที่มีการเชื่อมต่ออย่างสมบูรณ์ มีการนำแนวคิดของ KBANN มาประยุกต์ใช้กับการกำหนดค่าน้ำหนักเริ่มต้น ทำให้ค่าน้ำหนักก่อนการเรียนรู้ของนิวรอลเน็ตเวิร์กอาจจะอยู่ในท้องถิ่นที่ดีกว่า ดังนั้น เมื่อกำหนดให้ค่าพารามิเตอร์ต่างๆ ในการเรียนรู้ของเน็ตเวิร์กมีค่าเท่ากัน โครงสร้างที่มีการกำหนดค่าน้ำหนักเริ่มต้นในลักษณะนี้จึงสามารถทำการเรียนรู้เพื่อนำไปสู่ค่าที่ดีที่สุดเฉพาะที่ (local optimum) ที่ดีกว่าได้ ซึ่งส่งผลให้การจำแนกประเภทข้อมูลด้วยวิธีการนี้ มีค่าความถูกต้องที่มากกว่าด้วย

ปัจจัยอีกประการหนึ่งซึ่งอาจจะส่งผลให้โครงสร้างของนิวรอลเน็ตเวิร์กที่มีการเชื่อมต่ออย่างสมบูรณ์ให้ผลลัพธ์ของการจำแนกประเภทข้อมูลที่ดีกว่า คือ เนื่องจากโครงสร้างในลักษณะนี้ไม่ได้ทำการตัดค่าคุณลักษณะที่ไม่มีความสัมพันธ์กับกฎความสัมพันธ์ของประเภทแต่ละข้อออกไปโดยสมบูรณ์ กล่าวคือ ค่าคุณลักษณะทุกตัวยังคงมีการกำหนดการเชื่อมโยงไปยังกฎทุกข้อ เพียงแต่มีการกำหนดค่าน้ำหนักเริ่มต้นที่แตกต่างกันตามความสำคัญของค่าคุณลักษณะแต่ละตัว

เท่านั้น ดังนั้น ในการเรียนรู้ของนิรอลเน็ตเวิร์กที่มีการเชื่อมต่ออย่างสมบูรณ์ จะมีการปรับค่าน้ำหนักให้กับค่าคุณลักษณะทุกตัว จึงมีความเป็นไปได้ที่การเรียนรู้จะทำให้เกิดความสัมพันธ์ใหม่ระหว่างค่าคุณลักษณะต่างๆ ในเน็ตเวิร์กได้ ส่งผลให้ตัวจำแนกประเภทข้อมูลที่ได้จากโครงสร้างของนิรอลเน็ตเวิร์กในลักษณะนี้ ให้ผลลัพธ์ของการจำแนกประเภทข้อมูลที่มากกว่าโครงสร้างของนิรอลเน็ตเวิร์กที่มีการเชื่อมต่อแบบบางส่วน

นอกจากนี้ ผู้วิจัยได้มีการทดลองเพิ่มเติมเพื่อเปรียบเทียบแบ็กพรอพาทาเกชันนิรอลเน็ตเวิร์กที่นำเสนอในงานวิจัยนี้ ซึ่งกำหนดโครงสร้างจากความรู้ก่อนหน้าในรูปแบบกฎที่ค้นพบในขั้นตอนการค้นหากฎความสัมพันธ์ของประเภท กับแบ็กพรอพาทาเกชันนิรอลเน็ตเวิร์กที่ใช้ในการจำแนกประเภทข้อมูลโดยทั่วไป ซึ่งมีการกำหนดโครงสร้างจากชุดข้อมูลที่นำมาใช้ในการเรียนรู้ โดยรายละเอียดของการทดลองสามารถศึกษาได้จากภาคผนวก ข



สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

บทที่ 5

สรุปผลการวิจัยและข้อเสนอแนะ

5.1 สรุปผลการวิจัย

เนื่องจากขั้นตอนวิธีที่เป็นต้นแบบของการจำแนกประเภทเชิงความสัมพันธ์ที่เรียกว่า CBA มีข้อจำกัดในการสร้างตัวจำแนกประเภทข้อมูล กล่าวคือ การเรียงอันดับกฎความสัมพันธ์ของประเภทตามการทำก่อนด้วยค่าความเชื่อมั่นและค่าสนับสนุนของกฎแต่ละข้อ ก่อนจะนำกฎเหล่านั้นไปใช้จำแนกประเภทข้อมูล มักจะส่งผลให้ผลลัพธ์ความแม่นยำของการจำแนกประเภทข้อมูลด้วยขั้นตอนวิธี CBA ต่ำกว่าขั้นตอนวิธีประเภทเดียวกันที่เกิดขึ้นในภายหลัง ดังนั้น งานวิจัยนี้จึงมุ่งเน้นที่จะปรับปรุงขั้นตอนวิธี CBA ให้มีความแม่นยำสูงขึ้น โดยนำนิรอลเน็ตเวิร์กที่มีความสามารถในการจำแนกประเภทข้อมูลสูง และทนทานต่อข้อมูลรบกวนมาประยุกต์ใช้กับการจำแนกประเภทเชิงความสัมพันธ์ ข้อดีของวิธีการที่นำเสนอ คือ การนำความรู้ในรูปแบบกฎความสัมพันธ์ของประเภทที่ค้นพบก่อนหน้านี้ในขั้นตอนการค้นหากฎความสัมพันธ์ของประเภท มาช่วยกำหนดโครงสร้างของนิรอลเน็ตเวิร์กที่จะใช้ทำการเรียนรู้ เพื่อสร้างตัวจำแนกประเภทข้อมูลจากกฎความสัมพันธ์ของประเภทที่มีความแม่นยำมากยิ่งขึ้น

การประยุกต์ใช้แบ็กพรอพาทาเกชันนิรอลเน็ตเวิร์กเข้ากับการจำแนกประเภทเชิงความสัมพันธ์ที่นำเสนอในงานวิจัยนี้ สามารถแบ่งการทำงานได้เป็น 4 ส่วน คือ 1) การค้นหากฎความสัมพันธ์ของประเภท 2) การสร้างโครงสร้างของแบ็กพรอพาทาเกชันนิรอลเน็ตเวิร์กจากกฎความสัมพันธ์ของประเภท 3) การสร้างข้อมูลที่ใช้ในการเรียนรู้ และ 4) การเรียนรู้เพื่อปรับค่าน้ำหนักของเน็ตเวิร์ก โดยในส่วนของการค้นหากฎความสัมพันธ์ของประเภท งานวิจัยนี้ได้ปรับใช้ขั้นตอนวิธี CBA เพื่อค้นหากฎความสัมพันธ์ของประเภท โดยไม่มีการตัดเล็มกฎที่ค้นพบ เนื่องจากนิรอลเน็ตเวิร์กสามารถทำการเรียนรู้ได้อย่างมีประสิทธิภาพ แม้ว่าชุดข้อมูลสอนจะมีข้อมูลรบกวน อีกทั้งวิธีการตัดเล็มกฎของขั้นตอนวิธี CBA อาจจะทำให้กฎที่น่าสนใจถูกทำการตัดเล็มออกไปได้ เมื่อเสร็จสิ้นขั้นตอนการค้นหากฎความสัมพันธ์ของประเภทแล้ว ก็จะนำกฎที่ค้นพบมากำหนดโครงสร้างให้กับแบ็กพรอพาทาเกชันนิรอลเน็ตเวิร์ก ซึ่งงานวิจัยนี้ได้ทำการศึกษาเปรียบเทียบการนำนิรอลเน็ตเวิร์กมาประยุกต์ใช้กับการจำแนกประเภทข้อมูลใน 2 ลักษณะ คือ เพื่อคัดเลือกกฎความสัมพันธ์ของประเภท และเพื่อใช้จำแนกประเภทข้อมูล โดยใช้การเชื่อมต่อของโครงสร้าง 2 แบบ คือ แบบเชื่อมต่อบางส่วน และแบบเชื่อมต่ออย่างสมบูรณ์ โดยการเรียนรู้ของนิรอลเน็ตเวิร์กที่ใช้เพื่อจำแนกประเภทข้อมูลในกรณีหลัง จะให้ผลลัพธ์เป็นผลากประเภทตามธรรมชาติของการเรียนรู้ของนิรอลเน็ตเวิร์ก โดยไม่สามารถระบุกฎที่ใช้จำแนกประเภทข้อมูล

ได้โดยตรง ซึ่งแตกต่างจากวิธีการเรียนรู้ของเครื่องแบบต้นไม้ตัดสินใจ การจำแนกประเภทเชิงความสัมพันธ์ และนิรवलเน็ตเวิร์กที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภทในกรณีแรก ซึ่งให้ผลลัพธ์เป็นเซตของกฎประพจน์ที่มนุษย์สามารถทำความเข้าใจได้ ทำให้สามารถระบุกฎที่ใช้จำแนกประเภทข้อมูลได้โดยตรง

เมื่อทำการกำหนดโครงสร้างให้กับนิรवलเน็ตเวิร์กแล้ว ต่อมาจะนำชุดข้อมูลสอนและชุดข้อมูลทดสอบที่แบ่งไว้ มาแปลงให้อยู่ในรูปแบบที่นิรवलเน็ตเวิร์กสามารถใช้งานได้ โดยการสร้างข้อมูลที่ใช้ในการเรียนรู้ของนิรवलเน็ตเวิร์ก จะพิจารณาจากการทดสอบค่าความจริงระหว่างข้อมูลที่ใช้เรียนรู้กับอินพุตและเอาต์พุตของเน็ตเวิร์ก โดยจะแทนด้วยค่า “1” เมื่อมีความจริงเป็น “จริง” และแทนด้วยค่า “0” เมื่อมีความจริงเป็น “เท็จ” และในขั้นตอนสุดท้าย คือการเรียนรู้เพื่อปรับค่าน้ำหนักของเน็ตเวิร์ก นิรवलเน็ตเวิร์กที่ใช้การเชื่อมต่อของโครงสร้างแบบบางส่วน จะใช้การกำหนดค่าน้ำหนักเริ่มต้นแบบสุ่ม เนื่องจากโครงสร้างของนิรवलเน็ตเวิร์กในลักษณะนี้ ได้มีการกำหนดความสำคัญให้กับแต่ละโนดในเน็ตเวิร์กด้วยการกำหนดเส้นเชื่อมในขั้นตอนก่อนหน้าแล้ว จากนั้นก็จะทำการปรับค่าน้ำหนักตามขั้นตอนวิธีแบ็กพรอพาเกชัน ส่วนนิรवलเน็ตเวิร์กที่ใช้การเชื่อมต่อของโครงสร้างแบบสมบูรณ์ จะมีการกำหนดค่าน้ำหนักเริ่มต้นตามกฎที่ค้นพบในขั้นตอนการค้นหากฎความสัมพันธ์ของประเภท ซึ่งนำแนวคิดของ KBANN มาประยุกต์ใช้ จากนั้นจึงจะทำการปรับค่าน้ำหนักของเน็ตเวิร์กด้วยขั้นตอนวิธีแบ็กพรอพาเกชัน เช่นเดียวกันกับนิรवलเน็ตเวิร์กที่ใช้การเชื่อมต่อของโครงสร้างแบบบางส่วน และเมื่อเสร็จสิ้นกระบวนการเรียนรู้แล้ว จะนำนิรवलเน็ตเวิร์กที่ได้มาทดสอบกับชุดข้อมูลทดสอบ เพื่อประเมินประสิทธิภาพของวิธีการที่นำเสนอ

จากผลการทดลองกับชุดข้อมูลจำนวน 12 ชุด และการเปรียบเทียบผลลัพธ์ความแม่นยำของการจำแนกประเภทข้อมูลด้วยค่าระดับความเชื่อมั่น แสดงให้เห็นว่าแบ็กพรอพาเกชันนิรवलเน็ตเวิร์กที่กำหนดโครงสร้างจากกฎความสัมพันธ์ของประเภทที่นำเสนอในงานวิจัยนี้ทั้ง 4 กรณี มีประสิทธิภาพในการจำแนกประเภทข้อมูลมากกว่าวิธีการเรียนรู้ของเครื่องแบบ C4.5 ขั้นตอนวิธี CBA เดิม และ CPAR อย่างมีนัยสำคัญทางสถิติ โดยนิรवलเน็ตเวิร์กที่ใช้เพื่อจำแนกประเภทข้อมูล ซึ่งใช้การเชื่อมต่อของโครงสร้างแบบสมบูรณ์ระหว่างชั้นอินพุตและชั้นฮิดเดน เป็นวิธีการที่มีประสิทธิภาพในการจำแนกประเภทข้อมูลมากที่สุด

งานวิจัยนี้แสดงให้เห็นว่าการนำแบ็กพรอพพาเกชันนิวรอลเน็ตเวิร์กมาประยุกต์ใช้กับการจำแนกประเภทเชิงความสัมพันธ์ สามารถสร้างตัวจำแนกประเภทข้อมูลจากกฎความสัมพันธ์ของประเภทที่มีความแม่นยำมากกว่าตัวจำแนกประเภทข้อมูลที่สร้างจากขั้นตอนวิธี CBA เดิมได้ โดยการนำสองเทคนิคที่สำคัญของการทำเหมืองข้อมูล คือ การจำแนกประเภทข้อมูล และการค้นหากฎความสัมพันธ์ มารวมเข้าด้วยกัน

5.2 ข้อเสนอแนะ

1. จากผลการทดลองในงานวิจัยนี้ แสดงให้เห็นว่าความรู้ก่อนหน้าซึ่งอยู่ในรูปแบบกฎความสัมพันธ์ของประเภท มีผลต่อความแม่นยำของตัวจำแนกประเภทข้อมูลที่สร้างขึ้น ดังนั้น การปรับปรุงการสร้างกฎที่เป็นไปได้ในขั้นตอนการค้นหากฎความสัมพันธ์ของประเภทให้มีประสิทธิภาพมากยิ่งขึ้น น่าจะทำให้ได้ตัวจำแนกประเภทข้อมูลจากกฎความสัมพันธ์ของประเภทที่ดีขึ้นได้
2. การสร้างข้อมูลที่ใช้ในการเรียนรู้ให้กับแบ็กพรอพพาเกชันนิวรอลเน็ตเวิร์กที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภท โดยพิจารณาจากความสอดคล้องของฉลากประเภท จำนวนค่าของคุณลักษณะที่กฎแต่ละข้อสอดคล้องกับข้อมูล และค่าความเชื่อมั่นของกฎข้อนั้นๆ อาจทำให้เกิดการโอเวอร์ฟิต (overfitting) กับชุดข้อมูลสอนได้ ถ้าหากมีวิธีการที่มีความยืดหยุ่นมากกว่านี้ อาจจะทำให้ผลลัพธ์ความแม่นยำของการจำแนกประเภทข้อมูลมีค่ามากยิ่งขึ้นได้
3. นอกจาก KBANN แล้ว ยังมีขั้นตอนวิธีที่น่าสนใจอีกมากมาย ที่น่าจะสามารถนำมาประยุกต์ใช้กับการกำหนดค่าน้ำหนักเริ่มต้นให้กับโครงสร้างของนิวรอลเน็ตเวิร์กแบบที่มีการเชื่อมต่ออย่างสมบูรณ์ได้เช่นกัน ยกตัวอย่างเช่น ขั้นตอนวิธีที่นำเสนอในงานวิจัย [23, 24]

รายการอ้างอิง

1. Quinlan, J. R. C4.5: Programs for Machine Learning. San Francisco: Morgan Kaufmann Publishers, 1993.
2. Clark, P. and Niblett, T. The CN2 induction algorithm. Machine Learning. 3 (1989): 261–283.
3. Mitchell, T. M. Machine Learning. New York: The McGraw-Hill, 1997.
4. Lim, T. S., Loh, W. Y. and Shih, Y. S. A comparison of prediction accuracy, complexity, and training time of thirty-three old and new classification algorithms. Machine Learning. 40 (2000): 203-228.
5. Liu, B., Hsu, W. and Ma, Y. Integrating Classification and Association Rule Mining. The 4th International Conference on Knowledge Discovery and Data Mining, 1998: 80-86.
6. Han, J. and Kamber, M. Data Mining Concepts and Techniques. San Francisco: Morgan Kaufmann Publishers, 2000.
7. Agrawal, R., Imielinski, T. and Swami, A. Mining Association Rules between Sets of Items in Large Databases. ACM SIGMOD International Conference on Management of Data, 1993: 207-216.
8. Agrawal, R. and Srikant, R. Fast Algorithms for Mining Association Rules. The 20th International Conference on Very Large Databases, 1994: 487-499.
9. Li, W., Han, J. and Pei, J. CMAR: Accurate and Efficient Classification Based on Multiple Class-Association Rules. IEEE International Conference on Data Mining, 2001: 369-376.
10. Yin, X. and Han, J. CPAR: Classification based on Predictive Association Rules. SIAM International Conference on Data Mining, 2003.
11. Merz, C. J., Murphy, P. M. and Aha, D. W. UCI repository of machine learning databases. Department of Information and Computer Science, University of California, Irvine, CA [Online]. 1997. Available from: <http://www.ics.uci.edu/~mlearn/MLRepository.html>

12. กฤษณะ ไวยมัย และ ถีระวัฒน์ พงษ์ศิริปรีดา. การใช้เทคนิค Association Rule Discovery เพื่อการจัดสรรกฎหมายในการพิจารณาคดีความ. NECTEC Technical Journal. 3 (2001).
13. ณัฐวรรณ รัตนากกุล และ กฤษณะ ไวยมัยงานวิจัย. ระบบจำแนกประเภทโครงสร้างของโปรตีนโดยใช้เทคนิคด้าไมนึ่ง. การประชุมวิชาการ มก. ครั้งที่ 40, 2545.
14. Bishop, C. M. Neural Networks for Pattern Recognition. Oxford University Press, 1995.
15. Dietterich, T. G. Proper Statistical Tests for Comparing Supervised Classification Learning Algorithms. Technical Report. Department of Computer Science, Oregon State University, Corvallis, OR, 1996.
16. กัลยา วานิชย์บัญชา. การวิเคราะห์สถิติ : สถิติเพื่อการตัดสินใจ. กรุงเทพมหานคร: ภาควิชาสถิติ คณะพาณิชยศาสตร์และการบัญชี จุฬาลงกรณ์มหาวิทยาลัย, 2539.
17. Han, J., Pei, J. and Yin, Y. Mining Frequent Patterns without Candidate Generation. ACM SIGMOD International Conference on Management of Data, 2000.
18. Lavrac, N. and Dzeroski, S. Inductive Logic Programming Techniques and Applications. New York: Ellis Horwood, 1994.
19. Kijirikul, B., Sinthupinyo, S. and Chongkasemwongse, K. Approximate Match of Rules Using Backpropagation Neural Networks. Machine Learning. 44 (2001): 273-299.
20. Towell, G. G. and Shavlik, J. W. Knowledge-Based Artificial Neural Networks. Artificial Intelligence. 70 (1994): 119-165.
21. Towell, G. G. Symbolic Knowledge and Neural Networks: Insertion, Refinement, and Extraction. Ph.D. Thesis. University of Wisconsin, Madison, WI, 1992.
22. Fayyad, U. M. and Irani, K. B. Multi-Interval Discretization of Continuous-Valued Attributes for Classification Learning. The 13th International Joint Conference on Artificial Intelligence, 1993: 1022-1027.

23. Chen, C. L. and Nutter, R. S. Improving the Training Speed of Three-layer Feedforward Neural Nets by Optimal Estimation of the Initial Weights. IEEE International Joint Conference on Neural Networks, 1991: 2063-2068.
24. Li, G., Alnuweiri, H. and Wu, Y. Acceleration of Back Propagations through Initial Weight Pre-Training with Delta Rule. IEEE International Conference on Neural Networks, 1993: 580-585.



สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย



ภาคผนวก

สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

ตารางที่ ก.2 การค้นหากฎความสัมพันธ์ของประเภทตามขั้นตอนวิธี CBA

1 st pass	F_1	$\langle \{(A, e)\}, 4 \rangle, \langle \{(C, y)\}, 3 \rangle,$ $\langle \{(A, g)\}, 5 \rangle, \langle \{(C, n)\}, 3 \rangle,$ $\langle \{(B, p)\}, 3 \rangle, \langle \{(C, y)\}, 2 \rangle,$ $\langle \{(B, q)\}, 5 \rangle, \langle \{(C, y)\}, 3 \rangle,$ $\langle \{(B, q)\}, 5 \rangle, \langle \{(C, n)\}, 2 \rangle,$ $\langle \{(B, w)\}, 2 \rangle, \langle \{(C, n)\}, 2 \rangle$
2 nd pass	C_2	$\langle \{(A, e), (B, p)\}, (C, y) \rangle,$ $\langle \{(A, g), (B, p)\}, (C, y) \rangle,$ $\langle \{(A, g), (B, q)\}, (C, n) \rangle,$ $\langle \{(A, e), (B, q)\}, (C, y) \rangle,$ $\langle \{(A, g), (B, q)\}, (C, y) \rangle,$ $\langle \{(A, g), (B, w)\}, (C, n) \rangle$
	F_2	$\langle \{(A, e), (B, p)\}, 3 \rangle, \langle \{(C, y)\}, 2 \rangle,$ $\langle \{(A, g), (B, q)\}, 3 \rangle, \langle \{(C, y)\}, 2 \rangle,$ $\langle \{(A, g), (B, w)\}, 2 \rangle, \langle \{(C, n)\}, 2 \rangle$
CAR_1		$(A, e) \rightarrow (C, y), \quad (A, g) \rightarrow (C, n), \quad (B, p) \rightarrow (C, y),$ $(B, q) \rightarrow (C, y), \quad (B, w) \rightarrow (C, n)$
CAR_2		$\{(A, e), (B, p)\} \rightarrow (C, y), \quad \{(A, g), (B, q)\} \rightarrow (C, y),$ $\{(A, g), (B, w)\} \rightarrow (C, n)$
$CARs$		$CAR_1 \cup CAR_2$
$prCAR_1$		$(A, e) \rightarrow (C, y), \quad (A, g) \rightarrow (C, n), \quad (B, p) \rightarrow (C, y),$ $(B, q) \rightarrow (C, y), \quad (B, w) \rightarrow (C, n)$
$prCAR_2$		$\{(A, g), (B, q)\} \rightarrow (C, y)$
$prCARs$		$prCAR_1 \cup prCAR_2$

จากตารางที่ ก.2 กฎความสัมพันธ์ของประเภทที่ผ่านการตัดเล็มแล้วมีดังต่อไปนี้

(A, e)	\rightarrow	(C, y)	ค่าสนับสนุน = 3/10	ค่าความเชื่อมั่น = 3/4
(A, g)	\rightarrow	(C, n)	ค่าสนับสนุน = 3/10	ค่าความเชื่อมั่น = 3/5
(B, p)	\rightarrow	(C, y)	ค่าสนับสนุน = 2/10	ค่าความเชื่อมั่น = 2/3
(B, q)	\rightarrow	(C, y)	ค่าสนับสนุน = 3/10	ค่าความเชื่อมั่น = 3/5
(B, w)	\rightarrow	(C, n)	ค่าสนับสนุน = 2/10	ค่าความเชื่อมั่น = 2/2
$(A, g), (B, q)$	\rightarrow	(C, y)	ค่าสนับสนุน = 2/10	ค่าความเชื่อมั่น = 2/3

ภาคผนวก ข
ผลการทดลองการจำแนกประเภทข้อมูลด้วยแบ็กพรอพาเกชัน
นิรอลเน็ตเวิร์กที่กำหนดโครงสร้างจากชุดข้อมูล

สำหรับการประเมินประสิทธิภาพของวิธีการที่นำเสนอ ผู้วิจัยได้มีการทดลองเพิ่มเติมเพื่อเปรียบเทียบผลลัพธ์ความแม่นยำของการจำแนกประเภทข้อมูลด้วยแบ็กพรอพาเกชันนิรอลเน็ตเวิร์กที่กำหนดโครงสร้างจากความรู้ก่อนหน้าในรูปแบบกฎความสัมพันธ์ของประเภทที่นำเสนอในงานวิจัยนี้ กับแบ็กพรอพาเกชันนิรอลเน็ตเวิร์กที่ใช้ในการจำแนกประเภทข้อมูลโดยทั่วไป ซึ่งมีการกำหนดโครงสร้างจากชุดข้อมูลที่นำมาใช้ในการเรียนรู้

ในการทดลอง กำหนดให้นิรอลเน็ตเวิร์กที่นำมาใช้เปรียบเทียบใช้การเชื่อมต่อของโครงสร้างแบบสมบูรณ์ ระหว่างชั้นอินพุตกับชั้นฮิดเดนและระหว่างชั้นฮิดเดนกับชั้นเอาต์พุต โดยมีจำนวนอินพุตในดเท่ากับจำนวนคุณลักษณะของชุดข้อมูล จำนวนฮิดเดนในดเท่ากับจำนวนอินพุตในด หรือใกล้เคียงกับจำนวนอินพุตในด (จากการทดลอง) กล่าวคือ ให้ฮิดเดนในดแต่ละในดแทนคุณลักษณะแต่ละตัวของชุดข้อมูล และจำนวนเอาต์พุตในดเท่ากับจำนวนประเภทของข้อมูลที่ต้องการให้เน็ตเวิร์กทำการเรียนรู้ หลังจากทำการกำหนดโครงสร้างให้กับนิรอลเน็ตเวิร์กที่นำมาใช้เปรียบเทียบแล้ว ก็จะทำเน็ตเวิร์กนั้นๆ มาทำการปรับค่าน้ำหนักด้วยขั้นตอนวิธีแบ็กพรอพาเกชัน โดยกำหนดให้ค่าพารามิเตอร์ต่างๆ มีค่าเท่ากับค่าที่ใช้ในการเรียนรู้ของนิรอลเน็ตเวิร์กที่นำเสนอในงานวิจัยนี้

ผลลัพธ์ความแม่นยำของการจำแนกประเภทข้อมูลด้วยแบ็กพรอพาเกชันนิรอลเน็ตเวิร์กที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภทและใช้เพื่อจำแนกประเภทข้อมูลโดยตรง ซึ่งกำหนดโครงสร้างจากกฎความสัมพันธ์ของประเภท ที่นำเสนอในงานวิจัยนี้ เปรียบเทียบกับแบ็กพรอพาเกชันนิรอลเน็ตเวิร์กที่กำหนดโครงสร้างจากชุดข้อมูล สามารถแสดงได้ดังตารางที่ ข.1 โดยตัวหนาแสดงค่าความแม่นยำสูงสุดในแต่ละชุดข้อมูล และแถวสุดท้ายของตารางแสดงค่าเฉลี่ยของผลลัพธ์ที่ได้จากทั้ง 12 ชุดข้อมูล จากนั้น เมื่อนำค่าผลลัพธ์ความแม่นยำที่ได้จากการทดลองมาคำนวณค่าระดับความเชื่อมั่นเพื่อเปรียบเทียบประสิทธิภาพของแต่ละขั้นตอนวิธี จะได้ผลลัพธ์ดังแสดงในตารางที่ ข.2

จากค่าเฉลี่ยดังแสดงในแถวสุดท้ายของตารางที่ ข.1 จะเห็นว่าค่าเฉลี่ยของความแม่นยำของการจำแนกประเภทข้อมูลด้วยแบ็กพรอพาเกชันนิรอลเน็ตเวิร์กที่นำเสนอในงานวิจัยนี้ ทั้ง 4 กรณี มีค่ามากกว่าค่าเฉลี่ยของความแม่นยำที่ได้จากแบ็กพรอพาเกชันนิรอลเน็ตเวิร์กที่ใช้

ในการจำแนกประเภทข้อมูลโดยทั่วไป และเมื่อทำการเปรียบเทียบผลลัพธ์ความแม่นยำของการจำแนกประเภทข้อมูลด้วยค่าระดับความเชื่อมั่นดังแสดงในตารางที่ ข.2 จะได้ว่า

1. นีวรอลเน็ตเวิร์กที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภท ทั้งแบบเชื่อมต่อบางส่วนและเชื่อมต่อสมบูรณ์ มีค่าผลลัพธ์ความแม่นยำมากกว่านีวรอลเน็ตเวิร์กที่กำหนดโครงสร้างจากชุดข้อมูลที่นำมาใช้เปรียบเทียบ เป็นจำนวน 4 ชุดข้อมูล มีค่าผลลัพธ์ที่ใกล้เคียงกันเป็นจำนวน 8 ชุดข้อมูล และไม่มีชุดข้อมูลที่ด้อยกว่า
2. นีวรอลเน็ตเวิร์กที่ใช้เพื่อจำแนกประเภทข้อมูลแบบเชื่อมต่อบางส่วน มีค่าผลลัพธ์ความแม่นยำมากกว่านีวรอลเน็ตเวิร์กที่นำมาใช้เปรียบเทียบ เป็นจำนวน 5 ชุดข้อมูล มีค่าผลลัพธ์ที่ใกล้เคียงกันเป็นจำนวน 7 ชุดข้อมูล และไม่มีชุดข้อมูลที่ด้อยกว่า
3. นีวรอลเน็ตเวิร์กที่ใช้เพื่อจำแนกประเภทข้อมูลแบบเชื่อมต่อสมบูรณ์ มีค่าผลลัพธ์ความแม่นยำมากกว่านีวรอลเน็ตเวิร์กที่นำมาใช้เปรียบเทียบ เป็นจำนวน 6 ชุดข้อมูล มีค่าผลลัพธ์ที่ใกล้เคียงกันเป็นจำนวน 6 ชุดข้อมูล และไม่มีชุดข้อมูลที่ด้อยกว่า

จากผลการทดลองข้างต้น แสดงให้เห็นว่าการนำความรู้ในรูปแบบกฎความสัมพันธ์ของประเภทที่ค้นพบก่อนหน้านี้ในขั้นตอนการค้นหากฎความสัมพันธ์ของประเภท มาช่วยกำหนดโครงสร้างให้กับแบ็กพรอพาเกชันนีวรอลเน็ตเวิร์ก สามารถทำให้นีวรอลเน็ตเวิร์กมีประสิทธิภาพในการจำแนกประเภทข้อมูลที่สูงขึ้นได้

ตารางที่ ข.1 ผลลัพธ์ความแม่นยำของการจำแนกประเภทข้อมูลที่ได้จากแบ็กพรอพาทาเกชันนิวรอลเน็ตเวิร์กที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภท
และใช้เพื่อจำแนกประเภทข้อมูล ซึ่งกำหนดโครงสร้างจากกฎความสัมพันธ์ของประเภท
เปรียบเทียบกับแบ็กพรอพาทาเกชันนิวรอลเน็ตเวิร์กที่กำหนดโครงสร้างจากชุดข้อมูล

ชุดข้อมูล	แบ็กพรอพาทาเกชันนิวรอลเน็ตเวิร์ก ที่กำหนดโครงสร้างจากชุดข้อมูล	แบ็กพรอพาทาเกชันนิวรอลเน็ตเวิร์กที่ใช้เพื่อคัดเลือก กฎความสัมพันธ์ของประเภท		แบ็กพรอพาทาเกชันนิวรอลเน็ตเวิร์กที่ใช้เพื่อจำแนก ประเภทข้อมูล	
		แบบเชื่อมต่อบางส่วน	แบบเชื่อมต่ออย่างสมบูรณ์	แบบเชื่อมต่อบางส่วน	แบบเชื่อมต่ออย่างสมบูรณ์
Breast-w	99.57	99.43	99.57	99.57	99.57
Cleve	93.05	95.36	96.69	97.68	97.68
Diabetes	80.70	80.05	81.10	80.31	81.49
Glass	80.28	83.10	83.10	84.51	84.51
Heart	91.82	94.42	94.80	95.17	95.17
Hepatitis	97.40	98.70	98.70	100.00	100.00
Iris	96.64	95.97	96.64	95.97	96.64
Lymph	97.30	98.65	98.65	99.32	100.00
Pima	81.23	81.36	81.36	81.10	81.23
Tic-Tac-Toe	100.00	100.00	100.00	100.00	100.00
Wine	98.87	100.00	100.00	100.00	100.00
Zoo	93.07	97.03	99.01	99.01	100.00
ค่าเฉลี่ย	92.49	93.67	94.14	94.39	94.69

ตารางที่ ข.2 การเปรียบเทียบผลลัพธ์ความแม่นยำด้วยค่าระดับความเชื่อมั่น ระหว่างแบ็กพรอพาทาเกชันนิวรอลเน็ตเวิร์กที่ใช้เพื่อคัดเลือก
 กฎความสัมพันธ์ของประเภทและใช้เพื่อจำแนกประเภทข้อมูล ซึ่งกำหนดโครงสร้างจากกฎความสัมพันธ์ของประเภท
 เปรียบเทียบกับแบ็กพรอพาทาเกชันนิวรอลเน็ตเวิร์กที่กำหนดโครงสร้างจากชุดข้อมูล

ชุดข้อมูล	นิวรอลเน็ตเวิร์กที่ใช้เพื่อคัดเลือกกฎความสัมพันธ์ของประเภท		นิวรอลเน็ตเวิร์กที่ใช้เพื่อจำแนกประเภทข้อมูล	
	แบบเชื่อมต่อบางส่วน เปรียบเทียบกับนิวรอลเน็ตเวิร์ก ที่กำหนดโครงสร้างจากชุดข้อมูล	แบบเชื่อมต่อสมบูรณ์ เปรียบเทียบกับนิวรอลเน็ตเวิร์ก ที่กำหนดโครงสร้างจากชุดข้อมูล	แบบเชื่อมต่อบางส่วน เปรียบเทียบกับนิวรอลเน็ตเวิร์ก ที่กำหนดโครงสร้างจากชุดข้อมูล	แบบเชื่อมต่อสมบูรณ์ เปรียบเทียบกับนิวรอลเน็ตเวิร์ก ที่กำหนดโครงสร้างจากชุดข้อมูล
Breast-w	=	=	=	=
Cleve	+ 85	+ 85	+ 90	+ 90
Diabetes	=	=	=	+ 85
Glass	+ 90	+ 85	+ 90	+ 90
Heart	+ 85	+ 85	+ 95	+ 90
Hepatitis	=	=	=	=
Iris	=	=	=	=
Lymph	=	=	+ 85	+ 90
Pima	=	=	=	=
Tic-Tac-Toe	=	=	=	=
Wine	=	=	=	=
Zoo	+ 90	+ 99	+ 99	+ 99
ชนะ-แพ้-เสมอ	4-0-8	4-0-8	5-0-7	6-0-6

ภาคผนวก ค
รายละเอียดของชุดข้อมูลที่ใช้ในการทดลอง

การทดสอบวิธีการที่นำเสนอในงานวิจัยนี้ จะนำชุดข้อมูลจาก UCI Repository of Machine Learning Databases จำนวน 12 ชุดมาใช้ในการทดสอบ โดยรายละเอียดของแต่ละชุดข้อมูล สามารถแสดงได้ดังต่อไปนี้

ชุดข้อมูล

Breast-w

จำนวนประเภทข้อมูล

2 ประเภท ประกอบด้วย benign และ malignant

จำนวนคุณลักษณะ

10 ตัว ประกอบด้วย

คุณลักษณะ	ค่าที่เป็นไปได้	คุณลักษณะ	ค่าที่เป็นไปได้
Sample code number	id number	Single Epithelial Cell Size	1 - 10
Clump Thickness	1 - 10	Bare Nuclei	1 - 10
Uniformity of Cell Size	1 - 10	Bland Chromatin	1 - 10
Uniformity of Cell Shape	1 - 10	Normal Nucleoli	1 - 10
Marginal Adhesion	1 - 10	Mitoses	1 - 10

ชุดข้อมูล

Cleve

จำนวนประเภทข้อมูล

2 ประเภท ประกอบด้วย buff และ sick

จำนวนคุณลักษณะ

13 ตัว ประกอบด้วย

คุณลักษณะ	ค่าที่เป็นไปได้	คุณลักษณะ	ค่าที่เป็นไปได้
Age	continuous	Max heart rate	continuous
Sex	male, fem	Exercise induced angina	true, fal
Chest pain type	angina, abnang, notang, asympt	Oldpeak	continuous
Trestbps	continuous	Slope	up, flat, down
Cholesterol	continuous	Number of vessels colored	continuous
Fasting blood sugar < 120	true, fal	Thal	norm, fix, rev
Resting ecg	norm, abn, hyp		

ชุดข้อมูล

Diabetes

จำนวนประเภทข้อมูล

2 ประเภท ประกอบด้วย tested positive for diabetes และ tested negative for diabetes

จำนวนคุณลักษณะ

8 ตัว ประกอบด้วย

คุณลักษณะ	ค่าที่เป็นไปได้	คุณลักษณะ	ค่าที่เป็นไปได้
Number of times pregnant	continuous	2-Hour serum insulin	continuous
Plasma glucose concentration a 2 hours in an oral glucose tolerance test	continuous	Body mass index	continuous
Diastolic blood pressure	continuous	Diabetes pedigree function	continuous
Triceps skin fold thickness	continuous	Age	continuous

ชุดข้อมูล

Glass

จำนวนประเภทข้อมูล

7 ประเภท ประกอบด้วย building_windows_float_processed, building_windows_non_float_processed, vehicle_windows_float_processed, vehicle_windows_non_float_processed, containers, tableware และ headlamps

จำนวนคุณลักษณะ

10 ตัว ประกอบด้วย

คุณลักษณะ	ค่าที่เป็นไปได้	คุณลักษณะ	ค่าที่เป็นไปได้
Id number	1 - 214	Silicon	continuous
Refractive Index	continuous	Potassium	continuous
Sodium	continuous	Calcium	continuous
Magnesium	continuous	Barium	continuous
Aluminum	continuous	Iron	continuous

ชุดข้อมูล

Heart

จำนวนประเภทข้อมูล

2 ประเภท ประกอบด้วย absence of heart disease และ presence of heart disease

จำนวนคุณลักษณะ

13 ตัว ประกอบด้วย

คุณลักษณะ	ค่าที่เป็นไปได้	คุณลักษณะ	ค่าที่เป็นไปได้
Age	continuous	Maximum heart rate achieved	continuous
Sex	continuous	Exercise induced angina	continuous
Chest pain type	continuous	Oldpeak	continuous
Resting blood pressure	continuous	The slope of the peak exercise ST segment	continuous
Serum cholestoral in mg/dl	continuous	Number of major vessels colored by flourosopy	continuous
Fasting blood sugar > 120 mg/dl	continuous	Thal	continuous
Resting electrocardiographic results	continuous		continuous

ชุดข้อมูล

Iris

จำนวนประเภทข้อมูล

3 ประเภท ประกอบด้วย Iris Setosa, Iris Versicolour และ Iris Virginica

จำนวนคุณลักษณะ

4 ตัว ประกอบด้วย

คุณลักษณะ	ค่าที่เป็นไปได้	คุณลักษณะ	ค่าที่เป็นไปได้
Sepal length	continuous	Petal length	continuous
Sepal width	continuous	Petal width	continuous

ชุดข้อมูล Hepatitis

จำนวนประเภทข้อมูล 2 ประเภท ประกอบด้วย die และ live

จำนวนคุณลักษณะ 19 ตัว ประกอบด้วย

คุณลักษณะ	ค่าที่เป็นไปได้	คุณลักษณะ	ค่าที่เป็นไปได้
Age	continuous	Spiders	no, yes
Sex	male, female	Ascites	no, yes
Steroid	no, yes	Varices	no, yes
Antivirals	no, yes	Bilirubin	continuous
Fatigue	no, yes	Alk Phosphate	continuous
Malaise	no, yes	Sgot	continuous
Anorexia	no, yes	Albumin	continuous
Liver Big	no, yes	Protime	continuous
Liver Firm	no, yes	Histology	no, yes
Spleen Palpable	no, yes		

ชุดข้อมูล Pima

จำนวนประเภทข้อมูล 2 ประเภท ประกอบด้วย tested positive for diabetes และ tested negative for diabetes

จำนวนคุณลักษณะ 8 ตัว ประกอบด้วย

คุณลักษณะ	ค่าที่เป็นไปได้	คุณลักษณะ	ค่าที่เป็นไปได้
Number of times pregnant	continuous	2-Hour serum insulin	continuous
Plasma glucose concentration a 2 hours in an oral glucose tolerance test	continuous	Body mass index	continuous
Diastolic blood pressure	continuous	Diabetes pedigree function	continuous
Triceps skin fold thickness	continuous	Age	continuous

ชุดข้อมูล

Lymph

จำนวนประเภทข้อมูล

4 ประเภท ประกอบด้วย normal find, metastases, malign lymph และ fibrosis

จำนวนคุณลักษณะ

18 ตัว ประกอบด้วย

คุณลักษณะ	ค่าที่เป็นไปได้	คุณลักษณะ	ค่าที่เป็นไปได้
Lymphatics	normal, arched, deformed, displaced	Lym.nodes enlar	1 - 4
Block of affere	no, yes	Changes in lym.	bean, oval, round
Bl. of lymph. c	no, yes	Defect in node	no, lacunar, lac. marginal, lac. central
Bl. of lymph. s	no, yes	Changes in node	no, lacunar, lac. marginal, lac. central
By pass	no, yes	Changes in stru	no, grainy, drop-like, coarse, diluted, reticular, stripped, faint
Extravasates	no, yes	Special forms	no, chalices, vesicles
Regeneration of	no, yes	Dislocation of	no, yes
Early uptake in	no, yes	Exclusion of no	no, yes
Lym.nodes dimin	0 - 3	No. of nodes in	0-9, 10-19, 20-29, 30-39, 40-49, 50-59, 60-69, >=70

ชุดข้อมูล

Tic-Tac-Toe

จำนวนประเภทข้อมูล

2 ประเภท ประกอบด้วย positive และ negative

จำนวนคุณลักษณะ

9 ตัว ประกอบด้วย

คุณลักษณะ	ค่าที่เป็นไปได้	คุณลักษณะ	ค่าที่เป็นไปได้
top-left-square	x, o, b	middle-right-square	x, o, b
top-middle-square	x, o, b	bottom-left-square	x, o, b
top-right-square	x, o, b	bottom-middle-square	x, o, b
middle-left-square	x, o, b	bottom-right-square	x, o, b
middle-middle-square	x, o, b		

ชุดข้อมูล

Wine

จำนวนประเภทข้อมูล

3 ประเภท ประกอบด้วย 1, 2 และ 3

จำนวนคุณลักษณะ

13 ตัว ประกอบด้วย

คุณลักษณะ	ค่าที่เป็นไปได้	คุณลักษณะ	ค่าที่เป็นไปได้
c1	continuous	c8	continuous
c2	continuous	c9	continuous
c3	continuous	c10	continuous
c4	continuous	c11	continuous
c5	continuous	c12	continuous
c6	continuous	c13	continuous
c7	continuous		

ชุดข้อมูล

Zoo

จำนวนประเภทข้อมูล

7 ประเภท ประกอบด้วย 1, 2, 3, 4, 5, 6 และ 7

จำนวนคุณลักษณะ

17 ตัว ประกอบด้วย

คุณลักษณะ	ค่าที่เป็นไปได้	คุณลักษณะ	ค่าที่เป็นไปได้
Animal name	Unique for each instance	Backbone	Boolean
Hair	Boolean	Breathes	Boolean
Feathers	Boolean	Venomous	Boolean
Eggs	Boolean	Fins	Boolean
Milk	Boolean	Legs	0, 2, 4, 5, 6, 8
Airborne	Boolean	Tail	Boolean
Aquatic	Boolean	Domestic	Boolean
Predator	Boolean	Catsize	Boolean
Toothed	Boolean		

ภาคผนวก ง

ตารางแจกแจงค่าที่แบบทางเดียว (one-tail Student's t-Distribution)

ตารางแจกแจงค่าที่แบบทางเดี่ยวนี้ เป็นตารางที่ใช้ในการคำนวณค่าระดับความเชื่อมั่น
ในหัวข้อที่ 2.1.3 โดยในวิทยานิพนธ์ฉบับนี้ ใช้ค่าองศาเสรี (df) เท่ากับ 5 สำหรับการทำ 6-fold
cross validation

df	ระดับความเชื่อมั่นที่ N (%)											
	75	80	85	90	95	97.5	98	99	99.5	99.75	99.9	99.95
1	1.000	1.376	1.963	3.078	6.314	12.71	15.89	31.82	63.66	127.3	318.3	636.6
2	.816	1.061	1.386	1.886	2.920	4.303	4.849	6.965	9.925	14.09	22.33	31.60
3	.765	.978	1.250	1.638	2.353	3.182	3.482	4.541	5.841	7.453	10.21	12.92
4	.741	.941	1.190	1.533	2.132	2.776	2.999	3.747	4.604	5.598	7.173	8.610
5	.727	.920	1.156	1.476	2.015	2.571	2.757	3.365	4.032	4.773	5.893	6.869
6	.718	.906	1.134	1.440	1.943	2.447	2.612	3.143	3.707	4.317	5.208	5.959
7	.711	.896	1.119	1.415	1.895	2.365	2.517	2.998	3.499	4.029	4.785	5.408
8	.706	.889	1.108	1.397	1.860	2.306	2.449	2.896	3.355	3.833	4.501	5.041
9	.703	.883	1.100	1.383	1.833	2.262	2.398	2.821	3.250	3.690	4.297	4.781
10	.700	.879	1.093	1.372	1.812	2.228	2.359	2.764	3.169	3.581	4.144	4.587
11	.697	.876	1.088	1.363	1.796	2.201	2.328	2.718	3.106	3.497	4.025	4.437
12	.695	.873	1.083	1.356	1.782	2.179	2.303	2.681	3.055	3.428	3.930	4.318
13	.694	.870	1.079	1.350	1.771	2.160	2.282	2.650	3.012	3.372	3.852	4.221
14	.692	.868	1.076	1.345	1.761	2.145	2.264	2.624	2.977	3.326	3.787	4.140
15	.691	.866	1.074	1.341	1.753	2.131	2.249	2.602	2.947	3.286	3.733	4.073
16	.690	.865	1.071	1.337	1.746	2.120	2.235	2.583	2.921	3.252	3.686	4.015
17	.689	.863	1.069	1.333	1.740	2.110	2.224	2.567	2.898	3.222	3.646	3.965
18	.688	.862	1.067	1.330	1.734	2.101	2.214	2.552	2.878	3.197	3.611	3.922
19	.688	.861	1.066	1.328	1.729	2.093	2.205	2.539	2.861	3.174	3.579	3.883
20	.687	.860	1.064	1.325	1.725	2.086	2.197	2.528	2.845	3.153	3.552	3.850
21	.686	.859	1.063	1.323	1.721	2.080	2.189	2.518	2.831	3.135	3.527	3.819
22	.686	.858	1.061	1.321	1.717	2.074	2.183	2.508	2.819	3.119	3.505	3.792
23	.685	.858	1.060	1.319	1.714	2.069	2.177	2.500	2.807	3.104	3.485	3.768
24	.685	.857	1.059	1.318	1.711	2.064	2.172	2.492	2.797	3.091	3.467	3.745
25	.684	.856	1.058	1.316	1.708	2.060	2.167	2.485	2.787	3.078	3.450	3.725
26	.684	.856	1.058	1.315	1.706	2.056	2.162	2.479	2.779	3.067	3.435	3.707
27	.684	.855	1.057	1.314	1.703	2.052	2.15	2.473	2.771	3.057	3.421	3.690
28	.683	.855	1.056	1.313	1.701	2.048	2.154	2.467	2.763	3.047	3.408	3.674
29	.683	.854	1.055	1.311	1.699	2.045	2.150	2.462	2.756	3.038	3.396	3.659
30	.683	.854	1.055	1.310	1.697	2.042	2.147	2.457	2.750	3.030	3.385	3.646
40	.681	.851	1.050	1.303	1.684	2.021	2.123	2.423	2.704	2.971	3.307	3.551
60	.679	.848	1.045	1.296	1.671	2.000	2.099	2.390	2.660	2.915	3.232	3.460
80	.678	.846	1.043	1.292	1.664	1.990	2.088	2.374	2.639	2.887	3.195	3.416
100	.677	.845	1.042	1.290	1.660	1.984	2.081	2.364	2.626	2.871	3.174	3.390
inf.	.674	.841	1.036	1.282	1.64	1.960	2.054	2.326	2.576	2.807	3.091	3.291

ประวัติผู้เขียนวิทยานิพนธ์

นางสาวนภาพรรณ ยิ่งชาญกุล เกิดเมื่อวันที่ 16 ธันวาคม พ.ศ. 2524 ที่จังหวัด กรุงเทพมหานคร สำเร็จการศึกษาหลักสูตรวิทยาศาสตรบัณฑิต (วท.บ.) สาขาวิทยาการคอมพิวเตอร์ จากภาควิชาวิทยาการคอมพิวเตอร์ คณะวิทยาศาสตร์ มหาวิทยาลัยเชียงใหม่ ในปีการศึกษา 2545 และเข้าศึกษาต่อในหลักสูตรวิทยาศาสตรมหาบัณฑิต สาขาวิทยาศาสตร์คอมพิวเตอร์ ที่ภาควิชาวิศวกรรมคอมพิวเตอร์ คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย ในปีการศึกษา 2546



สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย