

## บทที่ 1

### บทนำ

ความรู้เป็นทรัพยากรที่มีความสำคัญสำหรับบุคลากรและองค์กรเป็นอย่างมาก ดังนั้นได้มีการนำความรู้มาใช้เพื่อให้เกิดประโยชน์สำหรับบุคคลและองค์กร เช่น การนำความรู้นั้นๆ มาใช้ในเรื่องของการสร้างความได้เปรียบทางด้านการแข่งขันเมื่อมองระดับขององค์กร หรือนำความรู้มาใช้ในการตัดสินใจแก้ปัญหาต่างๆ หรือเพื่อเพิ่มพูนความรู้สำหรับแต่ละบุคคล [1, 2] เนื่องจากในปัจจุบันข้อมูลที่เก็บอยู่ในฐานข้อมูลนั้นมีเพิ่มขึ้นมาก ทำให้การนำข้อมูลในฐานข้อมูลมาใช้ประโยชน์นั้นเป็นไปได้ยากมากยิ่งขึ้น ดังนั้นจึงต้องมีการนำข้อมูลเหล่านั้นมาทำการสกัดหาความรู้ ซึ่งความรู้นั้นอยู่ในรูปของกฎ เพื่อทำให้เข้าใจข้อมูลเหล่านั้นได้ง่ายขึ้นและสามารถนำไปใช้ประโยชน์ได้ต่อไป

การทำเหมืองข้อมูล (Data Mining) เป็นแนวทางหนึ่งที่นำมาช่วยในการค้นหาความรู้จากฐานข้อมูลที่มีจำนวนข้อมูลมาก เพื่อให้ได้มาซึ่งความรู้ที่เป็นประโยชน์นั้น จึงได้มีการนำตัวอย่างเทคนิคการทำเหมืองข้อมูลมาใช้ ไม่ว่าจะเป็น เทคนิคการจัดกลุ่มข้อมูล (Clustering Technique) ที่มีการเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning) และเทคนิคการสกัดความรู้ เป็นต้น การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Clustering) เป็นการเรียนรู้เพื่อแบ่งกลุ่มข้อมูลเอง เป็นการจัดกลุ่มข้อมูลที่มีลักษณะเหมือนกันให้อยู่ในกลุ่มเดียวกัน โดยไม่จำเป็นต้องมีตัวอย่างข้อมูลในการสอน ตัวอย่างเทคนิคการเรียนรู้แบบไม่มีผู้สอน ได้แก่ แผนที่การจัดกลุ่มเอง (Self-Organizing Map : SOM) และการแบ่งกลุ่ม K กลุ่มด้วยค่าเฉลี่ย (K-Means) [3] สำหรับแผนที่การจัดกลุ่มเองนั้นได้มีการนำมาประยุกต์ใช้ในงานวิจัยทางด้านการทำเหมืองข้อมูลอย่างแพร่หลายในด้านต่างๆ เช่น นำวิธีการแผนที่การจัดกลุ่มเองมาใช้ในการแก้ปัญหาเกี่ยวกับการจัดกลุ่มข้อมูล นำมาประยุกต์ใช้ร่วมกับ Case-Based Reasoning เพื่อทำนายยอดขายหนังสือใหม่ และทำนายการจัดการอัตราของพันธบัตร [4, 5] และนำวิธีการแผนที่การจัดกลุ่มเองมาวิเคราะห์ข้อมูลทางด้านการตลาด [6] เป็นต้น

การสกัดความรู้เป็นเทคนิคหนึ่งของการทำเหมืองข้อมูล ซึ่งเป็นแนวทางที่นำมาช่วยในการค้นหาความรู้จากฐานข้อมูลที่มีข้อมูลจำนวนมาก เพื่อให้ได้มาซึ่งความรู้ที่เป็นประโยชน์ และสามารถเข้าใจลักษณะของข้อมูลได้ง่าย โดยเฉพาะอย่างยิ่งข้อมูลที่มีลักษณะเป็นตัวเลข ความรู้ที่สกัดได้ในนั้นอยู่ในรูปของกฎ “ถ้า-แล้ว” (“If-Then” Rules) ซึ่งมี 2 แบบคือ กฎทั่วไป (Crisp Rules) ซึ่งแทนด้วยค่าจำนวนจริง [7] และกฎภาษาธรรมชาติ (Linguistic Rules) ซึ่งแทนด้วยภาษาธรรมชาติ เช่น เล็ก กลาง และ ใหญ่ เป็นต้น [8] ลักษณะกฎทั้งสองแบบนั้นมีองค์ประกอบ 2 ส่วน โดยที่ส่วนแรกที่อยู่หลัง “ถ้า” หรือ “If” จะหมายถึงเหตุ และส่วนที่สองที่อยู่หลัง “แล้ว” หรือ “Then” หมายถึงผลลัพธ์ที่ตามมา รายละเอียดของแต่ละแบบมีดังนี้

## 1. กฎทั่วไป (Crisp Rules/Coventional Rules) มีรูปแบบดังสมการ (1.1)

$$\text{If } x_1 \text{ op } t_1 \text{ and/or ... and/or } x_i \text{ op } t_j \text{ then } c_k \quad (1.1)$$

โดยที่  $x_i$  คือ ตัวแปรข้อมูลเข้าตัวที่  $i$   
 $t_j$  คือ ค่าของตัวแปรข้อมูลเข้าที่เป็นจำนวนจริงที่  $j$   
 $\text{op}$  คือ ตัวดำเนินการ  $=, <, >, <=, >=$  หรือ  $\neq$   
 $c_k$  คือ กลุ่มข้อมูล (Class) ที่  $k$

ตัวอย่างกฎทั่วไปจากฐานข้อมูลโรคมะเร็งเต้านม (Wisconsin Breast Cancer Database) เช่น If  $x_2 = 1$  or  $2$  then benign (ไม่เป็นโรคมะเร็งเต้านม) [7] เป็นต้น

## 2. กฎภาษาธรรมชาติ (Linguistic Rules) มีรูปแบบดังสมการ (1.2)

$$\text{If } x_1 \text{ is } l_1 \text{ and/or ... and/or } x_i \text{ is } l_j \text{ then } c_k \quad (1.2)$$

โดยที่  $x_i$  คือ ตัวแปรข้อมูลเข้าตัวที่  $i$   
 $l_j$  คือ ค่าของตัวแปรข้อมูลเข้าที่  $j$  มีลักษณะเป็นรูปแบบภาษาธรรมชาติ (Linguistic Terms)  
 เช่น เล็ก กลาง และใหญ่ เป็นต้น  
 $c_k$  คือ กลุ่มข้อมูล (Class) ที่  $k$

ตัวอย่างกฏภาษาธรรมชาติจากฐานข้อมูลดอกไม้ไอริช (Iris Flower Database) เช่น If  $x_3$  is small and  $x_4$  is small then Setosa [8] เป็นต้น

วิทยานิพนธ์นี้ได้นำเสนอแบบจำลองการสกัดความรู้โดยใช้แผนที่การจัดกลุ่มเอง ซึ่งแผนที่การจัดกลุ่มเอง ใช้จัดกลุ่มข้อมูลที่มีลักษณะเหมือนกันให้อยู่ในกลุ่มเดียวกันโดยไม่มีตัวอย่างในการสอน ทำการลดมิติของข้อมูลเข้าให้มีจำนวนมิติเป็น 1 มิติ หรือ 2 มิติ [9, 10] มีประโยชน์ คือทำให้สามารถเข้าใจลักษณะภาพรวมของข้อมูลได้ง่าย ซึ่งความรู้ที่สกัดได้จากแผนที่การจัดกลุ่มเอง อยู่ในรูปของกฎ “ถ้า-แล้ว” ที่ผู้ใช้สามารถเข้าใจได้ง่าย และใช้ฐานข้อมูลที่เป็นมาตรฐานจาก University of California at Irvine มาเป็นข้อมูลทดสอบ

## 1.1 การตรวจเอกสาร

เทคนิคที่ใช้ในการสกัดกู้ คือ โครงข่ายประสาทเทียม (Neural Networks) ต้นไม้การตัดสินใจ (Decision Trees) ฟชชีเซต (Fuzzy Set) และทฤษฎีราฟเซต (Rough Set Theory) ดังรายละเอียดดังต่อไปนี้

### 1.1.1 โครงข่ายประสาทเทียม (Neural Networks)

โครงข่ายประสาทเทียมถูกสร้างขึ้นเพื่อเลียนแบบการทำงานของสมองมนุษย์ หลักการทำงานประกอบด้วยหน่วยประมวลผลอยู่หลาย ๆ หน่วยทำงานเชื่อมต่อกัน แต่ละหน่วยสามารถปรับค่าพารามิเตอร์ประจำหน่วยได้จากการเรียนรู้ โครงข่ายประสาทเทียมที่ผ่านการฝึกฝนจะสามารถนำไปใช้แก้ปัญหาจริงได้ [11] ข้อดีของโครงข่ายประสาทเทียม คือ สามารถทำนายได้ค่าความถูกต้องสูง เหมาะกับข้อมูลที่มีลักษณะเป็นตัวเลข

โครงข่ายประสาทเทียมที่นำมาใช้ในการสกัดกู้ แบ่งตามสถาปัตยกรรม มี 3 แบบคือ แผนที่การจัดกลุ่มเอง (Self-Organizing Map: SOM) โครงข่ายประสาทเทียมแบบย้อนกลับ (Recurrent Neural Networks) และโครงข่ายประสาทเทียมแบบเพอร์เซฟตรอนหลายชั้น (Multilayer Perceptron Neural Networks: MLP) มีรายละเอียดดังต่อไปนี้

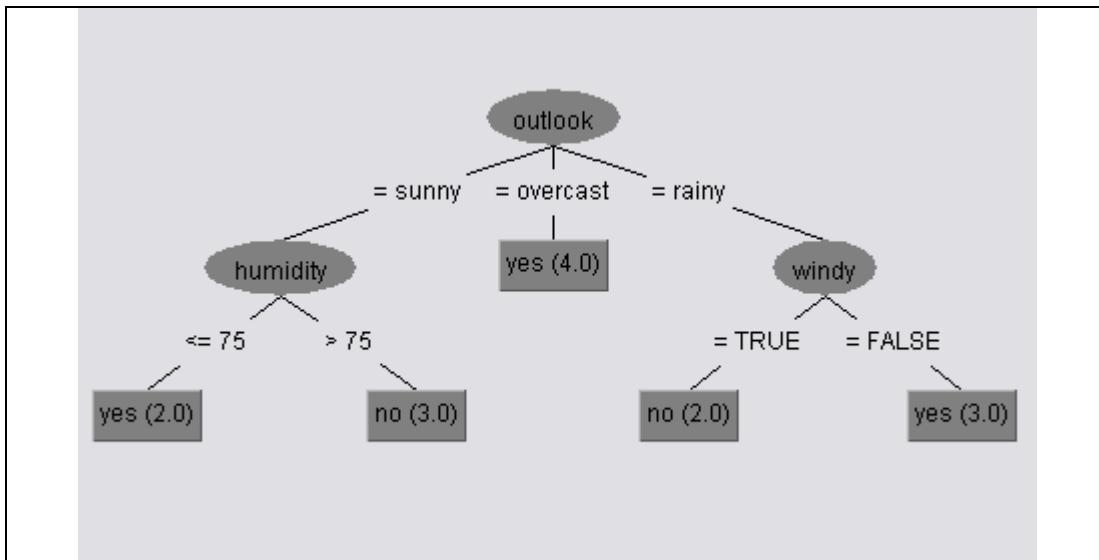
1. แผนที่การจัดกลุ่มเอง (Self-Organizing Map: SOM) เป็นวิธีการหนึ่งของโครงข่ายประสาทเทียมที่มีการเรียนรู้แบบไม่มีผู้สอนซึ่งใช้กันอย่างแพร่หลาย นำมาใช้ในเรื่องของการจัดกลุ่มข้อมูลที่มีลักษณะเหมือนกันให้อยู่ในกลุ่มเดียวกัน ซึ่งประโยชน์ของแผนที่การจัดกลุ่มเองนั้น จะทำการลดมิติของข้อมูลเข้าให้มีจำนวนมิติเป็น 1 มิติ หรือ 2 มิติ และสามารถเข้าใจลักษณะข้อมูลได้ในภาพรวม [10, 12] สำหรับการสกัดความรู้โดยใช้แผนที่การจัดกลุ่มเองเพียงอย่างเดียว ได้มีการนำ U-matrix และ Component plane ที่เป็นเครื่องมือของแผนที่การจัดกลุ่มเอง และขั้นตอนวิธี sig\* มาทำการวิเคราะห์หาขอบเขตของประเภทข้อมูลรวมทั้งใช้เพื่ออธิบายความสัมพันธ์ของข้อมูลให้อยู่ในรูปของกฎ “ถ้า-แล้ว” ของแต่ละข้อมูลเข้า [12, 13] สำหรับกฎที่สกัดได้จากแผนที่การจัดกลุ่มเองนั้นอยู่ในรูปของกฎทั่วไป (Crisp Rules) นอกเหนือไปนี้ได้นำแผนที่การจัดกลุ่มเองมาประยุกต์ใช้ร่วมกับวิธีการอื่น ๆ เพื่อเพิ่มประสิทธิภาพและความถูกต้องในการสกัดความรู้ เช่น การสกัดความรู้โดยใช้แผนที่การจัดกลุ่มเองร่วมกับกฎฟชชี [14] ซึ่งกฎที่ได้นำอยู่ในรูปของกฎภาษาธรรมชาติ (Linguistic Rules) การหากฎความสัมพันธ์โดยใช้แผนที่การจัดกลุ่มเองร่วมกับทฤษฎีราฟเซต [15] การนำแผนที่การจัดกลุ่มเองมาทำการจัดกลุ่มข้อมูล และใช้ทฤษฎีราฟเซตเพื่อทำการสกัดความรู้ให้อยู่ในรูปของกฎ “ถ้า-แล้ว” เพื่อสกัดความรู้ที่เป็นประโยชน์จากฐานข้อมูล [16]

2. โครงข่ายประสาทเทียมแบบย้อนกลับ (Recurrent Neural Networks) เป็นโครงประสาทเทียมที่มีการเรียนรู้แบบมีผู้สอน โดยสัญญาณจากข้อมูลออก (Output) สามารถกลับไปเป็นข้อมูลเข้า (Input) ได้ [17] ข้อเสียของโครงข่ายประสาทเทียมแบบย้อนกลับ คือใช้เวลาในการประมวลผลนาน เมื่อเทียบกับโครงข่ายประสาทเทียมแบบเพอร์เซฟตロンหลายชั้น [7]

3. โครงข่ายประสาทเทียมแบบเพอร์เซฟตرونหลายชั้น (Multilayer Perceptron Neural Networks: MLP) เป็นโครงประสาทเทียมที่มีการเรียนรู้แบบมีผู้สอน นิยมใช้ในการแบ่งกลุ่มข้อมูล ในการสกัดกู้จากโครงข่ายประสาทเทียมแบบเพอร์เซฟตرونหลายชั้น มีทั้งได้กู้ทั่วไป (Crisp Rules/Conventional Rules) และกู้ภาษาธรรมชาติ (Linguistic Rules) [7]

#### 1.1.2 ต้นไม้การตัดสินใจ (Decision Trees)

ต้นไม้การตัดสินใจเป็นการเรียนรู้เพื่อใช้แบ่งกลุ่มข้อมูลโดยใช้คุณสมบัติของข้อมูลในการจัดแบ่งกลุ่ม สำหรับการสร้างต้นไม้การตัดสินใจนั้นจะเป็นสร้างจากบนลงล่าง โดยเริ่มจากการเลือกตัวแปรข้อมูลเข้า (Input Attributes) ที่มีคุณสมบัติที่สามารถแบ่งกลุ่มได้ดีที่สุดมาสร้างเป็นโหนดราก หลังจากนั้น เมื่อข้อมูลผ่านการแบ่งแยกที่โหนดรากตามค่าตัวแปรข้อมูลเข้าของโหนดรากแล้ว หากตัวแปรข้อมูลเข้าที่ดีที่สุดของข้อมูลที่ผ่านการแบ่งแยกนั้นมาสร้างเป็นโหนดลูกของโหนดรากต่อไป และจะวนสร้างโหนดลูกและต้นไม้ย่อยของแต่ละกิ่งไปเรื่อยๆ จนกว่าข้อมูลที่ผ่านการแบ่งแยกนั้นจะจัดอยู่ในกลุ่มเดียวกัน หรือจำนวนข้อมูลที่ผ่านการแบ่งแยกในกิ่งหนึ่งๆ มีค่าน้อยกว่าค่าที่กำหนดไว้ [18, 19] ตัวอย่างอัลกอริทึมต้นไม้การตัดสินใจ ได้แก่ อัลกอริทึม CART ใช้ค่าสัมประสิทธิ์จีนี (Gini) เพื่อกำหนดคุณสมบัติในการแบ่งข้อมูล อัลกอริทึม ID3 และ C4.5 จะใช้ค่าค่าค่ามาตรฐานเกน (Gain Criteria) เพื่อกำหนดคุณสมบัติในการแบ่งข้อมูล ตัวอย่างต้นไม้การตัดสินใจของฐานข้อมูลอาภาคนิพัทธ์ J48 ซึ่งเป็นวิธีการที่พัฒนามาจาก C4.5 [20] แสดงดังภาพประกอบ 1.1



ภาพประกอบ 1.1 ตัวอย่างต้นไม้การตัดสินใจของฐานข้อมูลอากาศ

### 1.1.3 ฟชชีเซต (Fuzzy Set)

ฟชชีเซตเป็นแนวทางในการแสดงถึงลักษณะความคลุมเครือ หรือความไม่ชัดเจนของข้อมูล [21] ฟชชีเซตเป็นเซตที่แสดงถึงความสัมพันธ์ของสมาชิกภายในกลุ่ม โดยความสัมพันธ์นี้จะถูกแสดงในลักษณะของระดับความเป็นสมาชิกที่มีค่าอยู่ในช่วง  $[0, 1]$  เทคนิคฟชชีเซตนำมาใช้ในการแปลงข้อมูลเดิมที่มีลักษณะเป็นตัวเลขจำนวนจริงให้มีลักษณะเป็นรูปแบบภาษาธรรมชาติ (Linguistic Terms) หรือเรียกว่าเทอมเซต (Term Set) เช่น เล็ก กลาง และใหญ่ ซึ่งมีพังก์ชันความเป็นสมาชิกที่ใช้ในการประมาณค่าระดับความเป็นสมาชิกของแต่ละเทอมเซต [22] สำหรับการสกัดความรู้โดยใช้ฟชชีเซตนั้นได้นำวิธีการอื่นๆ มาประยุกต์ใช้ร่วมกันด้วย เช่น นำหลักการฟชชีเซตสร้างฟังก์ชันความเป็นสมาชิกเพื่อใช้ประมาณค่าระดับความเป็นสมาชิกของแต่ละเทอมเซต หลังจากนั้นใช้หลักการرافเซตเพื่อทำการสกัดกฎ ซึ่งกฎที่ได้อัญญາในรูปแบบของกฎภาษาธรรมชาติ [23] นอกจากนี้ได้มีการนำฟชชีเซตมาประยุกต์ใช้ร่วมกับเทคนิคโครงข่ายประสาทเทียมสำหรับการสกัดกฎความรู้ทำให้ได้กฎที่มีค่าความถูกต้องสูง เช่น อัลกอริทึม Adaptive-Network-based Fuzzy Inference System (ANFIS) ซึ่งเป็นอัลกอริทึมที่ใช้โครงข่ายประสาทเทียม 5 ชั้น ใช้การเรียนรู้แบบแพร่ย้อนกลับ (Backpropagation) เพื่อเรียนรู้เหตุ (Antecedent) จากพังก์ชันความเป็นสมาชิก (Membership Function) และใช้ค่าเฉลี่ยกำลังสองน้อยที่สุด (Least Mean Square) เพื่อกำหนดค่าสัมประสิทธิ์ในส่วนผลลัพธ์ของกฎที่ได้ [24]

### 1.1.4 ราฟเซต (Rough Set)

ราฟเซตเป็นทฤษฎีที่ใช้ในการจัดการเกี่ยวกับเรื่องความคลุมเครือและความไม่แน่นอนของข้อมูล หลักการของราฟเซตนั้นใช้วิธีการประมาณค่าจากข้อมูลที่มีอยู่ในลิ่งที่เราสนใจ โดยความสัมพันธ์ของข้อมูลกลุ่มแรกเป็นการประมาณค่าขอบเขตล่าง (Lower

Approximation) และความสัมพันธ์ของข้อมูลกลุ่มที่สองเป็นการประมาณค่าขอบเขตบน (Upper Approximation) [25] สำหรับการสกัดกฎความรู้ได้มีการประยุกต์ทฤษฎีราฟเซตร่วมกับวิธีการอื่น ๆ เช่น นำทฤษฎีราฟเซตมาประยุกต์ใช้ร่วมกับวิธีการคำนวนแบบเมทริกซ์เพื่อใช้ในการสกัดกฎความรู้ [26]

## 1.2 วัตถุประสงค์ของโครงการ

- 1.2.1 เพื่อสร้างแบบจำลองในการสกัดความรู้โดยใช้แผนที่การจัดกลุ่มเอง
- 1.2.2 พัฒนาโปรแกรมจากแบบจำลองสำหรับการสกัดความรู้โดยใช้แผนที่การจัดกลุ่มเอง

## 1.3 ขอบเขตของการดำเนินงาน

- 1.3.1 พัฒนาอัลกอริทึมและสร้างแบบจำลองในการสกัดความรู้โดยใช้แผนที่การจัดกลุ่มเอง
- 1.3.2 พัฒนาโปรแกรมเพื่อสกัดความรู้โดยใช้แผนที่การจัดกลุ่มเอง
- 1.3.3 ข้อมูลที่นำมาสกัดความรู้เป็นข้อมูลที่ได้มาจากข้อมูลทางด้านการแพทย์ คือ กลุ่มฐานข้อมูลที่เป็นมาตรฐานเป็นที่ยอมรับในระดับสากล ซึ่งทำการดาวน์โหลดมาจาก University of California at Irvine (UCI) [27]

## 1.4 ขั้นตอนและระยะเวลาการดำเนินงาน

### 1.4.1 ขั้นตอนการดำเนินงาน

1. ศึกษางานวิจัยและเอกสารที่เกี่ยวข้อง
2. ศึกษาเทคนิคการสกัดความรู้โดยใช้แผนที่การจัดกลุ่มเอง และเทคนิคอื่น ๆ ที่ใช้ในงานวิจัย
3. ศึกษาเครื่องมือและซอฟต์แวร์สำหรับทำงานวิจัย
4. วิเคราะห์และออกแบบโปรแกรมการสกัดความรู้โดยใช้แผนที่การจัดกลุ่มเอง
5. พัฒนาโปรแกรมการสกัดความรู้โดยใช้แผนที่การจัดกลุ่มเอง
6. ทดสอบและติดตั้งโปรแกรมการสกัดความรู้โดยใช้แผนที่การจัดกลุ่มเอง
7. จัดทำเอกสารประกอบโปรแกรมการสกัดความรู้โดยใช้แผนที่การจัดกลุ่มเอง
8. เขียนผลงานวิจัยและนำเสนอผลงานวิจัย
9. จัดทำเอกสารวิทยานิพนธ์

#### 1.4.2 ระยะเวลาดำเนินการ

ตุลาคม 2548 – มีนาคม 2550

#### 1.4.3 แผนการดำเนินการวิจัย

### ตารางที่ 1.1 แสดงระยะเวลาดำเนินการวิจัย

## 1.5 สถานที่และเครื่องมือที่ใช้

### 1.5.1 สถานที่

ห้องวิจัยปัญญาประดิษฐ์ CS207 ภาควิชาวิทยาการคอมพิวเตอร์ ตึกวิทยาการ-คอมพิวเตอร์ คณะวิทยาศาสตร์ มหาวิทยาลัยสงขลานครินทร์ วิทยาเขตหาดใหญ่

### 1.5.2 เครื่องมือที่ใช้

#### ฮาร์ดแวร์

เครื่องไมโครคอมพิวเตอร์หน่วยความจำ 256 เมกะไบต์ ฮาร์ดดิสก์ 40 กิกะไบต์หน่วยประมวลผลกลางรุ่นเพนเทียมอาร์ฟอร์ 3.00 กิกะเฮิร์ต จำนวน 1 เครื่อง

#### ซอฟต์แวร์

1. Microsoft Windows XP เป็นระบบปฏิบัติการ
2. MATLAB 7.0 สำหรับพัฒนาโปรแกรมจากแบบจำลอง และทดสอบแบบจำลอง
3. Java (TM) 2 SDK, Standard Edition สำหรับประมวลผลโปรแกรม Weka
4. Weka สำหรับเปรียบเทียบผลการทดลอง
5. Microsoft Excel 2000 สำหรับเตรียมข้อมูล

## 1.6 ประโยชน์ที่คาดว่าจะได้รับ

- 1.6.1 ได้แบบจำลองในการสกัดความรู้โดยใช้แผนที่การจัดกลุ่มเอง
- 1.6.2 ได้โปรแกรมเพื่อสกัดความรู้โดยใช้แผนที่การจัดกลุ่มเอง