



รายงานฉบับสมบูรณ์

Final Report

การจัดการฐานความรู้โดยใช้ Case-Based Reasoning

Case-Based Reasoning for Knowledge Management Implementation



รศ.ดร. เอื้อน

ปิ่นเงิน

นายไพฑูรย์

ศรีนิต

นายพรเทพ

โรจนวสุ

นายสุรพล

โรจนประดิษฐ์

นายอเนก

กอนสาร

RCH

Q

398.8

0446

ห้องปฏิบัติการวิจัย ศาสตร์ข้อมูล

โครงการสำนักวิจัยการสื่อสารและเทคโนโลยีสารสนเทศ
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

กันยายน พ.ศ. 2549

เลขหมู่.....

เลขทะเบียน..... 83641


วัน,เดือน,ปี... 10 ก.ย. 2551

Information Science Laboratory

Research Center for Communications and Information Technology

King Mongkut's Institute of Technology Ladkrabang

September 2006



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

กิตติกรรมประกาศ

โครงการวิจัยนี้ได้รับทุนอุดหนุนจาก โครงการสำนักวิจัยการสื่อสารและเทคโนโลยีสารสนเทศ (Research Center for Communications and Information Technology : ReCCIT) สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง ประจำปีงบประมาณ พ.ศ. 2549 วงเงินงบประมาณ 56,534.00 บาท



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทสรุปย่อ

ห้องปฏิบัติการศาสตร์ข้อมูล กำลังพัฒนาระบบคลังความรู้และระบบสกัดความรู้จากฐานข้อมูลขนาดใหญ่โดยใช้หลักการทางปัญญาประดิษฐ์ โดยมีวัตถุประสงค์เพื่อนำไปประยุกต์กับระบบจัดการความรู้ (Knowledge Management) ระบบการเรียนรู้แบบนิรนอลเน็ตเวิร์คและเทคนิคการสกัดความรู้ด้วยทฤษฎีรัฟเซต (Rough Set) สามารถสกัดเอาความรู้เด่นชัด (Explicit Knowledge) จากฐานข้อมูลและนิรนอลเน็ตเวิร์คจะเรียนรู้จากความรู้ที่สกัดมาได้เพื่อปรับความรู้ให้มีความถูกต้องเพื่อให้สามารถนำไปใช้งานได้จริงและมีประสิทธิภาพสูง



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญ

	หน้า
กิตติกรรมประกาศ.....	I
บทสรุปย่อ.....	II
บทคัดย่อ.....	III
คำย่อและสัญลักษณ์.....	VI
บทที่ 1 บทนำ.....	1
บทที่ 2 ระบบการจัดการฐานความรู้แบบเรียนรู้ได้.....	2
กระบวนการสกัดความรู้ด้วยทฤษฎีกราฟเซต.....	2
โครงสร้างของระบบ.....	5
การสร้าง Case.....	8
การค้นคืน Case.....	11
บทที่ 3 สรุปและข้อเสนอแนะ.....	12
บทที่ 4 เอกสารอ้างอิง.....	13
ภาคผนวก	
ภาคผนวก ก สรุปผลงานภายใต้โครงการ.....	15

บทที่ 1

บทนำ

การจัดการความรู้ (Knowledge Management) หรือ KM คือเครื่องมือสำหรับพัฒนาคนและองค์กรไปสู่การเป็นสังคมแห่งการเรียนรู้ จุดประสงค์ของ KM คือต้องการจัดการองค์ความรู้ต่างๆในองค์กรให้อยู่ในรูปแบบที่สามารถนำกลับมาใช้ใหม่ได้ ความรู้ในองค์กรสามารถแบ่งออกเป็น 2 ประเภท คือ 1) ความรู้เด่นชัด (Explicit Knowledge) เป็นความรู้ที่อยู่ในรูปแบบที่เป็นเอกสารหรือวิชาการ อยู่ในตำรา คู่มือปฏิบัติงาน และ 2) ความรู้ซ่อนเร้น (Tacit Knowledge) เป็นความรู้ที่แฝงอยู่ในตัวคน บุคลากร เป็นประสบการณ์ที่สั่งสมมายาวนาน เป็นภูมิปัญญา โดยที่ความรู้ทั้งสองประเภทนี้มีวิธีการจัดการที่แตกต่างกัน การจัดการความรู้เด่นชัด จะเน้นไปที่การเข้าถึงแหล่งความรู้ ตรวจสอบ และตีความได้ เมื่อนำไปใช้แล้วเกิดความรู้ใหม่ก็นำมาสรุปไว้เพื่อใช้อ้างอิงหรือให้ผู้อื่นเข้าถึงได้ต่อไป ส่วนการจัดการความรู้ซ่อนเร้น นั้นจะเน้นไปที่การถ่ายทอดความรู้ที่อยู่ในตัวผู้ปฏิบัติไปยังผู้ร่วมงานทำให้เกิดการเรียนรู้ร่วมกัน อันนำไปสู่การสร้างความรู้ใหม่ที่แต่ละคนสามารถนำไปใช้ในการปฏิบัติงานได้ต่อไป ในทางปฏิบัติความรู้ทั้งสองประเภทนี้สามารถเปลี่ยนสถานภาพสลับปรับเปลี่ยนไปตลอดเวลา งานวิจัยนำเสนอการจัดเก็บความรู้ทั้งสองประเภทลงในฐานความรู้ และการใช้งานฐานความรู้ โดยใช้ทฤษฎี Case-Based Reasoning (CBR)

ระบบ CBR คือระบบที่นำชิ้นส่วนของความรู้ที่ได้จากความรู้เด่นชัดและความรู้ซ่อนเร้นมาสร้างเป็นฐานความรู้ เพื่อใช้สำหรับเป็นกรณีตัวอย่างในกระบวนการตัดสินใจในปัญหาต่าง ๆ เช่นเหตุการณ์ใดๆ ที่เกิดขึ้นในปัจจุบันที่มีลักษณะคล้ายกับเหตุการณ์ที่เคยเกิดขึ้นในอดีต ดังนั้นเราจึงสามารถใช้วิธีการแก้ปัญหาลักษณะเดียวกันกับวิธีที่แก้ปัญหามาอย่างได้ผลในอดีตได้ ด้วยความสามารถของ CBR ทำให้เราประหยัดเวลาที่ใช้ในการวิเคราะห์ปัญหาและวิเคราะห์หาวิธีแก้ปัญหได้อย่างมาก

ในงานวิจัยนี้แบ่งการทำงานของ CBR ออกเป็นสองส่วนใหญ่ได้คือ ส่วนการจัดกลุ่มสารสนเทศ (Data Clustering) และส่วนการสร้างกรณี (Case Generation) โดยส่วนการจัดกลุ่มสารสนเทศทำหน้าที่จัดกลุ่มข้อมูลในสารสนเทศที่จะนำมาใช้สร้างความรู้ในฐานความรู้โดยใช้ทฤษฎี Rough set และส่วนการสร้างกรณีทำหน้าที่สร้างกรณีตัดสินใจโดยใช้ทฤษฎี Nero-Fuzzy

บทที่ 2

ระบบการจัดการฐานความรู้แบบเรียนรู้ได้

2.1 กระบวนการสกัดความรู้ด้วยทฤษฎีรัพเซต

ทฤษฎีรัพเซตเป็นทฤษฎีที่ครอบคลุมเนื้อหากว้างและมีการนำไปประยุกต์ใช้งานกันในหลายๆ ด้าน ดังนั้นในงานวิจัยนี้จะขอสกัดถึงเฉพาะเนื้อหาที่เกี่ยวข้องกับงานวิจัยที่นำเสนอเท่านั้น ส่วนเนื้อหาทั้งหมดโดยละเอียดสามารถศึกษาเพิ่มเติมได้จาก [1] และ [2]

ระบบสารสนเทศ (Information System)

กำหนดให้ระบบสารสนเทศ แทนด้วยคู่ลำดับ $\lambda = \langle U, A \rangle$ หรืออาจจะมองในรูปฟังก์ชัน $f: U \times A \rightarrow V$ เมื่อ U คือเซตของออบเจกต์เรียกว่ายูนิเวิร์ส A เป็นเซตของแอตทริบิวต์ และ V เป็นเซตของค่าที่เป็นไปได้ของแต่ละแอตทริบิวต์ในแต่ละออบเจกต์ แสดงได้โดย $a: V \rightarrow V_a$ โดยที่ V_a คือ value set ของ a สำหรับทุก $a \in A$

อย่างไรก็ตามในบางครั้งระบบสารสนเทศ อาจจะมีความรู้เดิมที่ใช้ในการจำแนกออบเจกต์ในยูนิเวิร์สอยู่แล้วโดยแทนอยู่ในรูปแอตทริบิวต์ตัดสินใจ ซึ่งถ้าหากเป็นกรณีเช่นนี้เราจะเรียก ระบบสารสนเทศ นั้นว่า เป็น ระบบตัดสินใจ เขียนแทนด้วย $\lambda' = \langle U, A \cup \{d\} \rangle$ โดยที่ $d \notin A$ และเรียก $\{d\}$ ว่าเป็น แอตทริบิวต์ตัดสินใจ ตารางที่ 1 แสดงระบบตัดสินใจ $\lambda' = \langle U, \{Diploma, Experience, French, Reference\} \cup \{Decision\} \rangle$

	<i>Diploma (i)</i>	<i>Experineece (e)</i>	<i>French (f)</i>	<i>Reference (r)</i>	<i>Decision</i>
x_1	MBA	Medium	Yes	Excellent	Accept
x_2	MBA	Low	Yes	Neutral	Reject
x_3	MCE	Low	Yes	Good	Reject
x_4	MSc	High	Yes	Neutral	Accept
x_5	MSc	Medium	Yes	Neutral	Reject
x_6	MSc	High	Yes	Excellent	Reject
x_7	MBA	High	No	Good	Accept
x_8	MCE	Low	No	Excellent	Reject

ตารางที่ 1 ระบบตัดสินใจ Hiring

ระบบตัดสินใจสามารถมีความซ้ำซ้อนได้ 2 ทนทางคือ ออกปเจ็กต์ที่เหมือนกันปรากฏหลายครั้งในตารางเดียวกัน และแอทริบิวต์ที่ไม่มีอำนาจการจำแนกเป็นสมาชิกอยู่ใน A เราสามารถแสดงคุณสมบัติของออกปเจ็กต์ที่มีความซ้ำซ้อน(เหมือนกัน)ด้วยความสัมพันธ์อีควิวเลนซ์(Equivalence Relation)

กำหนดให้ I_B คือ B -indiscernibility สำหรับทุก $B \subseteq A$ โดยที่ $I_B = \{(x, y) \in U : \forall a \in B, a(x) = a(y)\}$ ดังนั้นออกปเจ็กต์ $(x, y) \in I_B$ ใดๆแล้วออกปเจ็กต์ x และ y คือออกปเจ็กต์เหมือนกันหรือไม่สามารถแยกแยะได้ด้วยแอทริบิวต์ B อย่างไรก็ตามความสัมพันธ์ I_B สามารถเขียนแทนได้ด้วย $[x]_B$ โดยที่ทั้งสองสัญลักษณ์มีความหมายเหมือนกัน สำหรับในงานวิจัยนี้จะมอง $[x]_B$ เป็นกลุ่มก้อนของออกปเจ็กต์ภายในขอบเขตความคล้ายเรียกว่า granules ตัวอย่างเช่นในระบบตัดสินใจตารางที่ 1 พิจารณาที่ $B = \{Diploma, Experience\}$ ดังนั้น I_B จะแบ่งยูนิเวิร์สออกเป็น

$$I_B = I_{\{Diploma, Experience\}} = \{\{x_3, x_8\}, \{x_4, x_6\}, \{x_5\}, \{x_1\}, \{x_2\}, \{x_7\}\}$$

หรือกล่าวอีกนัยหนึ่งได้ว่า $\{x_3, x_8\}, \{x_4, x_6\}, \{x_5\}, \{x_1\}, \{x_2\}, \{x_7\}$ เป็น granules ที่สร้างด้วย I_B

จากนิยามของ I_B จะพบว่ามันคือเครื่องมือสำหรับแบ่งยูนิเวิร์สของเป็นชั้นๆโดยที่ออกปเจ็กต์ที่เป็นสมาชิกในแต่ละชั้นจะถือว่าออกปเจ็กต์ที่เหมือนกัน(ค่าเท่ากัน) หรืออาจจะเรียกได้ว่าเป็นออกปเจ็กต์ที่อยู่ในกลุ่มเดียวกัน อย่างไรก็ตามในระบบตัดสินใจ เมื่อพิจารณาแอทริบิวต์ตัดสินใจสำหรับการแบ่งยูนิเวิร์สแล้วไม่สามารถการันตีได้ว่าชั้นที่แบ่งได้จาก I_B นั้นจะมีความเป็นคริสป์ นั่นคือมีออกปเจ็กต์บางตัวที่ไม่สามารถตัดสินใจว่าจะเป็นสมาชิกของชั้นที่อื่นไหน(ลัฟออกปเจ็กต์) ดังนั้นในระบบตัดสินใจจึงต้องนิยามโอเปอเรเตอร์ขึ้นมาอีก 2 โอเปอเรเตอร์คือ B-upper approximation และ B-lower approximation เพื่อใช้ตัดสินใจลัฟออกปเจ็กต์

กำหนดให้ $\mathcal{U} = \langle U, A \rangle$ เป็นระบบสารสนเทศ $B \subseteq A$ และ $X \subseteq U$ เราสามารถประมาณ $[x]_B$ ที่อยู่ใน X โดยอาศัยความรู้ (ข้อมูล) ที่มีอยู่ใน B โดยใช้ B-lower approximation $\underline{B}X = \{x \in U : [x]_B \subseteq X\}$ และ B-upper approximation $\overline{B}X = \{x \in U : [x]_B \cap X \neq \emptyset\}$ ความสัมพันธ์ระหว่าง $X, \underline{B}X, \overline{B}X$ และ $[x]_B$ ดังแสดงในรูปที่ 1 ตัวอย่างจากตารางที่ 1 ถ้ากำหนดให้ $B = \{Diploma, Experience\}$ และ X คือคอนเซ็ปต์ "Reject" จะได้ว่า $X = \{x_2, x_3, x_5, x_6, x_8\}$ $\underline{B}X = \{\{x_2\}, \{x_3, x_8\}, \{x_4, x_6\}, \{x_6\}\}$ และ $\overline{B}X = \{\{x_2\}, \{x_3, x_8\}, \{x_4, x_6\}, \{x_5\}\}$ เป็นต้น

Reducts

การใช้ความสัมพันธ์ $[x]_B$ สามารถลดขนาดของ data set ได้หรือกล่าวอีกนัยหนึ่งคือสามารถลดความซ้ำซ้อนของข้อมูลได้โดยจัดออกปเจ็กต์ที่เหมือนกันรวมเข้าด้วยกันเป็นก้อนเดียว แต่ความซ้ำซ้อนในระบบตัดสินใจนั้นเกิดจาก 2 ทนทางดังที่กล่าวไปแล้วในหัวข้อที่ผ่านมา ดังนั้นการลดความซ้ำซ้อนจึงต้องเอกสารเป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้ 3

กำจัดแอทริบิวต์ที่ไม่มีความสำคัญหรือไม่จำเป็นจนจำแนกออกไปให้ได้ด้วย กระบวนการนี้คือการค้นหา minimal set ของแอทริบิวต์ที่ทำให้ระบบตัดสินใจนั้นมีประสิทธิภาพคงเดิมในขณะที่จำนวนแอทริบิวต์มีจำนวนน้อยที่สุด โดยที่เซตของแอทริบิวต์ดังกล่าวเรียกว่า Reducts

Dependency Rule Generation

กระบวนการสร้างกฎถือเป็นหัวใจหลักของงานวิจัยนี้ โดยเครื่องมือที่ใช้ในการสร้างกฎคือทฤษฎี ลัพเซตเรื่อง d-reducts และ d-discernibility [2] ซึ่งจะอธิบายในหัวข้อนี้โดยสังเขป

กำหนดให้ $\lambda = \langle U, A \rangle$ เป็นระบบตัดสินใจ โดยที่ $A = C \cup d$ เมื่อ C และ d เป็นแอทริบิวต์เงื่อนไข และแอทริบิวต์ตัดสินใจตามลำดับ กำหนดให้ $V_d = \{d_1, d_2, \dots, d_l\}$ เป็นเซตของค่าที่เป็นไปได้ของแอทริบิวต์ตัดสินใจที่แบ่งยูนิเวิร์สออกเป็น l กลุ่ม ดังนั้น $\lambda = \langle U, A \rangle$ จึงสามารถแยกย่อยออกได้เป็น $\lambda_i = \langle U_i, A_i \rangle$ เมื่อ $i = 1, 2, \dots, l$ และ $U = U_1 \cup U_2 \cup \dots \cup U_l$ ในขณะที่ $A_i = C \cup \{d_i\}$

จากนิยามที่กล่าวมาจะได้ $\{u_{i1}, u_{i2}, \dots, u_{ip}\}$ คือเซตของออบเจกต์ใน U_i ที่ปรากฏอยู่ใน λ_i เมื่อ $i = 1, 2, \dots, l$ ดังนั้น d-reducts $B = \{b_1, b_2, \dots, b_p\}$ เรียกว่า B-discernibility matrix เขียนแทนด้วย $Md_i(B)$ และสามารถหาค่าในเมทริกซ์ได้จากสมการที่ 1 ดังนี้

$$c_{ij} = \{a \in B : a(x_i) \neq a(x_j)\}, i=1,2,\dots,n \quad (1)$$

สำหรับทุกๆ $x_j \in \{x_{i1}, x_{i2}, \dots, x_{ip}\}$ สามารถนิยามฟังก์ชัน discernibility ได้คือ

$$f_{d_i}^{x_j} = \bigwedge \{c_{ij} : 1 \leq i, j \leq n, j < i, c_{ij} \neq \emptyset\} \quad (2)$$

ดังนั้น $f_{d_i}^{x_j}$ สามารถเขียนในรูป DNF (Disjunctive Normal Form) โดยที่ในแต่ละพจน์ของ DNF ใช้แทนหนึ่งกฎเรียกว่า r_i และแต่ละกฎที่ได้จะมีค่า dependency factor(df) เป็นตัวชี้วัดค่าความน่าเชื่อถือแสดงในสมการที่ 3

$$df_i = \frac{\text{card}(POS_{B_i}(d_i))}{\text{card}(U_i)} \quad (3)$$

เมื่อ $POS_{B_i}(d_i) = \bigcup_{X \in [x]_{d_i}} \underline{B}_i(X)$ และ $\underline{B}_i(X)$ คือ ขอบเขตล่างของ X เทียบกับ B_i โดยที่ B_i คือแอทริบิวต์เงื่อนไขที่ปรากฏในกฎ r_i ค่าของ r_i จะอยู่ในช่วง $[0,1]$ แสดงค่าความน่าเชื่อถือของกฎ r_i ซึ่งถ้าค่านี้มีค่าเป็น 1 แสดงค่าเชื่อถือได้ร้อยเปอร์เซ็นต์ หรืออาจจะกล่าวได้ว่าความรู้ที่มีอยู่ใน B_i สามารถใช้สรุปข้อมูลใน $[x]_{d_i}$ ได้ครบถ้วนสมบูรณ์

ตัวอย่างเช่น: พิจารณาระบบตัดสินใจ Hiring $\lambda' = \langle U, \{Diploma(i), Experiment(e), French(f), Reference(r)\} \cup \{Decision\} \rangle$ ในตารางที่ 1 $V_{Decision} = \{Accept, Re\ ject\}$ คือเซตของค่าที่เป็นไปได้ของแอทริ

บิวต์ตัดสินใจ Decision ดังนั้นเราสามารถแยกตารางที่ 1 ออกได้เป็น λ'_{Accept} และ λ'_{Reject} ดังแสดงในตาราง 2a และตาราง 2b ตามลำดับ

	<i>i</i>	<i>e</i>	<i>f</i>	<i>r</i>	<i>Decision</i>
x_1	MBA	Medium	Yes	Excellent	Accept
x_4	MSc	High	Yes	Neutral	Accept
x_7	MBA	High	No	Good	Accept

(a)

	<i>i</i>	<i>e</i>	<i>f</i>	<i>r</i>	<i>Decision</i>
x_2	MBA	Low	Yes	Neutral	Reject
x_3	MCE	Low	Yes	Good	Reject
x_5	MSc	Medium	Yes	Neutral	Reject
x_6	MSc	High	Yes	Excellent	Reject
x_8	MCE	Low	No	Excellent	Reject

(b)

ตารางที่ 2 (a) ระบบตัดสินใจ Hiring_Accept" และ (b) ระบบตัดสินใจ Hiring_Reject

จากตารางทั้งสองเราสามารถสร้าง discernibility matrix $M_{Accept}(C)$ และ $M_{Reject}(C)$ ตามสมการ (1) ตารางที่ 2 แสดง $M_{Accept}(C)$ ส่วน $M_{Reject}(C)$ ก็มีกระบวนการสร้างเช่นเดียวกัน จากตารางที่ 2a เราจะได้ฟังก์ชัน discernibility f_{Accept} ดังนี้

$$f_{Accept} = (i \vee e \vee r) \wedge (e \vee f \vee r) \wedge (i \vee f \vee r) \\ = (e \wedge i) \vee (e \wedge f) \vee (i \wedge f) \vee r$$

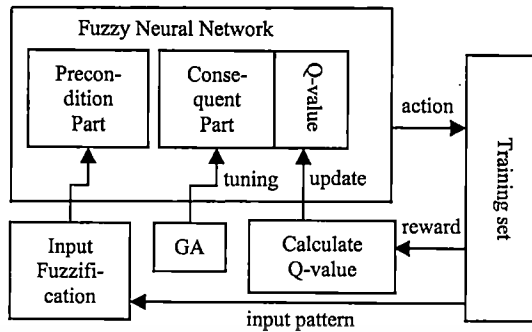
จาก f_{Accept} สามารถนำมาสร้างเป็นกฎเพื่อใช้สรุป $[x]_{d_{Accept}}$ ได้ดังนี้

$$Accept \leftarrow e \wedge i \\ Accept \leftarrow e \wedge f \\ Accept \leftarrow i \wedge f \\ Accept \leftarrow r$$

2.2 โครงสร้างของระบบ

การทำงานของระบบดังแสดงในรูปที่ 3 แบ่งออกเป็นระบบย่อยหลักๆ 5 ส่วน คือ ข้อมูลที่ใช้สอนระบบ (Training set) การจัดการข้อมูลนำเข้า (Input Fuzzification) การจัดการความรู้ (Fuzzy Neural Network) การจัดการค่าคิว (Q-value) และจีนิติกอัลกอริทึม รายละเอียดการทำงานของแต่ละระบบย่อยมีดังต่อไปนี้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้ 5




รูปที่ 3 ระบบการจัดการความรู้โดยใช้หลักการ CBR

1. ข้อมูลที่ใช้สอนระบบ (Training set)

ข้อมูลที่ใช้สอนระบบจะเป็นความรู้เด่นชัดที่เก็บในลักษณะของระบบตัดสินใจ (Decision Systems) อย่างไรก็ตามข้อมูลสำหรับสอนระบบสามารถที่จะเป็นความรู้ซ่อนเร้นได้โดยจะต้องแปลงความรู้ซ่อนเร้นดังกล่าวให้อยู่ในรูปความรู้เด่นชัดเสียก่อนเพราะตามทฤษฎีแล้วความรู้ทั้งสองประเภทสามารถเปลี่ยนกลับไปกลับมาได้

2. การจัดการข้อมูลนำเข้า (Input Fuzzification)

ข้อมูลนำเข้าอยู่ในรูปเวกเตอร์ขนาด n มิติ $X=[x_1, x_2, \dots, x_n]$ โดยที่ x_i เป็นตัวเลข (crisp value) เพื่อให้ระบบสามารถจัดการกับข้อมูลที่คลุมเครือได้จึงแทนข้อมูล n มิติให้เป็น $3n$ มิติในรูปฟังก์ชัน *low medium* และ *high* แทนด้วย $X=[low(x_1), medium(x_1), high(x_1), \dots, low(x_n), medium(x_n), high(x_n)]$ โดยที่ฟังก์ชัน *low medium* และ *high* แทนด้วย PI ฟังก์ชันดังแสดงในรูปที่ 4



รูปที่ 4 PI ฟังก์ชัน

PI ฟังก์ชันมีพารามิเตอร์ c_L, c_M และ c_H แสดงศูนย์กลางของ PI ฟังก์ชัน *low medium* และ *high* ตามลำดับ และพารามิเตอร์ λ_L, λ_M , และ λ_H แสดงรัศมีของ PI ฟังก์ชัน *low medium* และ *high* ตามลำดับ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นิยมนำไปเผยแพร่ในเชิงพาณิชย์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$\begin{aligned}
 c_L(x_j) &= m_{jl} \\
 c_M(x_j) &= m_j \\
 c_H(x_j) &= m_{jh} \\
 \lambda_L(x_j) &= c_M(x_j) - c_L(x_j) \\
 \lambda_H(x_j) &= c_H(x_j) - c_M(x_j) \\
 \lambda_M(x_j) &= 0.5(c_H(x_j) - c_L(x_j))
 \end{aligned}$$

เมื่อ m_j คือค่าเฉลี่ย (mean) ของพีเจอร์ (feature) x_j ค่า m_{jl} คือค่าเฉลี่ยในช่วง $[x_{jmin}, m_j]$ และค่า m_{jh} คือค่าเฉลี่ยในช่วง $(m_j, x_{jmax}]$ โดยที่ค่า x_{jmin} และ x_{jmax} คือค่าต่ำสุดและค่าสูงสุดของพีเจอร์ x_j


3. การจัดการความรู้ (Fuzzy Neural Network)

ระบบย่อยในส่วนของจัดการความรู้จะนำข้อมูลที่ได้จากข้อมูลที่ใช้สอนระบบมาสร้างเป็นโมเดลที่ใช้แทนความรู้ ในงานวิจัยนี้เลือกใช้โมเดลแบบ Fuzzy Neural Network เนื่องจากต้องการให้ส่วนการจัดการความรู้สามารถจัดการกับข้อมูลที่มีความคลุมเครือได้

3.1 โครงสร้างของหน่วยการจัดการความรู้

ลักษณะโครงสร้างหลักจะอาศัยโครงสร้างของนิเวศน์เน็ตเวิร์คโดยที่โทโปโลยี (Topology) จะถูกสร้างด้วยทฤษฎีเซต (Rough Sets) โดยใช้เทคนิคการสร้าง rough set dependency rule ตัวอย่างเช่นในรูปที่ 5 แสดงการสร้างเน็ตเวิร์คโทโปโลยีด้วยทฤษฎีเซตสำหรับสิ่งวิเคราะห์กฎพีชซีเพื่อเก็บลง CBR

Dependency rule: $C_1 \leftarrow (L_1 \wedge L_2) \vee (M_1 \wedge H_2)$ $C_2 \leftarrow M_3$
Fuzzy rule: if $x_1(t)$ is L_1 AND $x_2(t)$ is L_2 then c_1 is k_1
 if $x_1(t)$ is M_1 AND $x_2(t)$ is H_2 then c_1 is k_2
 if $x_1(t)$ is M_3 then c_2 is k_3



รูปที่ 5 การสร้างเน็ตเวิร์คโทโปโลยีด้วยทฤษฎีเซต

รูปที่ 5 แสดงเน็ตเวิร์คโทโปโลยีโดยสามารถนำไปสังเคราะห์เป็นกฎพีชซีได้ คือพิจารณาอินพุทเลเยอร์ (Input layer) และรูลเลเยอร์ (Rule layer) เป็นพีชซีปริคอนดิชัน (Fuzzy precondition part) และพิจารณาเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้ 7

ค่าน้ำหนัก(Synaptic weight)ระหว่างอินพุทเลเยอร์กับเอาต์พุทเลเยอร์ (Output layer) เป็นฟัซซี่คอนซีควอน (Fuzzy consequent part) ดังแสดงในส่วนบนของรูปที่ 5 เป็นต้น

3.2 การเรียนรู้ของหน่วยการจัดการความรู้

จุดประสงค์งานวิจัยนี้คือต้องการหาค่าเซตของค่าน้ำหนักระหว่างอินพุทเลเยอร์กับเอาต์พุทเลเยอร์ เมื่อได้เซตของค่าน้ำหนักที่เหมาะสมแล้วก็นำไปแทนลงในฟัซซี่คอนซีควอนเพื่อเก็บลง CBR ต่อไป งานวิจัยนี้ได้เลือกใช้จีเนติกอัลกอริทึมสำหรับสอนระบบโดยที่สมการค่าความเหมาะสม (Fitness function) จะใช้ค่าคิวจากสมการของกระบวนการเรียนรู้แบบคิว (Q-learning)

3.3 การออกแบบโครโมโซมของจีเนติกอัลกอริทึม

โครโมโซมแต่ละตัวแทนเซตของค่าน้ำหนัก ขนาดของแต่ละโครโมโซมเท่ากับ L ยีนส์สำหรับแทนกฎฟัซซี่ L กฎ โดยที่แต่ละยีนส์แทนค่าคอนซีควอนซิงเกิลตัน (Consequent singleton) ของแต่ละกฎฟัซซี่ แต่ละโครโมโซมจะมีค่าคิว (q-value) เป็นตัวระบุค่าความเหมาะสม เมื่อใดก็ตามที่มีอินพุท (input pattern) เข้ามาในระบบโครโมโซมตัวที่มีค่าคิวมาก ๆ จะมีสิทธิ์ถูกเลือก(มากกว่าตัวอื่น) เพื่อนำเซตของค่าน้ำหนักในโครโมโซมดังกล่าวไปแทนในกฎฟัซซี่ทั้ง L กฎ จากนั้นทดสอบการทำงานของระบบ คำนวณค่าความผิดพลาด และปรับปรุงค่าคิวของโครโมโซมดังกล่าวด้วยสมการการเรียนรู้แบบคิวคือ

$$q_i(t) = q_i(t) + \alpha (r(t) + \gamma (q_{i^*}(t) - q_i(t)))$$

เมื่อ $q_i(t)$ คือโครโมโซมที่ถูกเลือกแบบ e-greedy ในรอบที่ t โดยพิจารณาจากค่าคิวของแต่ละโครโมโซม $q_{i^*}(t)$ คือโครโมโซมที่มีค่าคิวสูงสุดของประชากรทั้งหมด α คือค่าคงที่ระบุอัตราการเรียนรู้ γ คือค่าคงที่ระบุอัตราการลืมน และ $r(t)$ คือค่าประสิทธิผลจากการกระทำครั้งปัจจุบันมีค่าอยู่ในช่วง $[0, 1]$

เมื่อจบในแต่ละรอบของการเรียนรู้ (epoch) จะทำกระบวนการจีเนติกอัลกอริทึม 1 ครั้งเพื่อวิวัฒนาการเซตของค่าน้ำหนักเพื่อให้ค้นหาคำตอบที่ดีที่สุด กระบวนการเรียนรู้จะทำซ้ำจากขั้นตอนแรกจนถึงกระบวนการจีเนติกอัลกอริทึม การทำงานจะวนรอบไปเรื่อยๆจนกว่าจะได้คำตอบที่เหมาะสม

2.3 การสร้าง Case

ในหัวข้อนี้อธิบายวิธีในการสร้างเคส โดยแบ่งการทำงานออกเป็น 2 ขั้นตอนหลักๆดังนี้ 1.) สร้างกฎในรูปแบบฟัซซี่ด้วยทฤษฎีฟัซซี่ และ 2.) เปลี่ยนกฎที่อยู่ในรูปฟัซซี่ไปเป็นเคส

ในกระบวนการแรกก่อนที่เราจะสร้างกฎในรูปแบบฟัซซี่ได้จะต้องเปลี่ยนฟัซซี่เซตให้เป็นคริสป์เซตเสียก่อนด้วย α -cut หรือกล่าวอีกอย่างได้ว่าเป็นการเปลี่ยนฟัซซี่ฟังก์ชันไปเป็นไบนารีฟังก์ชัน ดังแสดงในเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้ 8

รูปที่ 3 ใช้ α -cut = 0.5 บนเวกเตอร์ขนาด 2-มิติเพื่อสร้าง crisp granule ขนาด $3^2 = 9$ เซลล์ อย่างไรก็ตาม เราสามารถสร้าง fuzzy granule โดยตรงได้ [3], [4] รูปที่ 3 แสดงไดอะแกรมของการสร้างเซลล์ ข้อมูลเข้าของกระบวนการทั้งหมดเป็นค่าความเป็นสมาชิกของฟัซซีเซตและเอาต์พุตสุดท้ายของกระบวนการคือเซลล์ที่อยู่ในรูปฟัซซีฟังก์ชันที่ใช้เป็นตัวแทนของแต่ละออปเจกต์ที่เป็นสมาชิกในแต่ละ granule ในขณะที่กระบวนการภายในจะกระทำกับข้อมูลที่เป็นคริสป์เซต ตัวอย่างเช่นในบล็อคดีที่ 2 ของรูปที่ 3 มีข้อมูลเข้าเป็นค่าแบบฟัซซีและให้เอาต์พุตเป็นค่าแบบคริสป์หรือเป็นไบนารีฟังก์ชัน ซึ่งการทำงานโดยละเอียดในแต่ละบล็อกจะอธิบายในหัวข้อต่อไป

การกำหนดค่าขั้นต่ำและการสร้างกฎ

พิจารณาค่าความเป็นสมาชิกของแต่ละออปเจกต์ใน $3n$ ฟัซซีฟังก์ชัน จากนั้นให้เปลี่ยนค่าความเป็นสมาชิกให้อยู่ในรูปไบนารีโดยกำหนดให้แต่ละแอทริบิวต์ของแต่ละฟัซซีเซตที่มีค่าความเป็นสมาชิกมากกว่าหรือเท่ากับค่า $Th (=0.5)$ หรือกล่าวอีกนัยหนึ่งได้ว่าเราเลือกใช้ 0.5-cut ของทุกๆ ฟัซซีเซต Low Medium และ High ให้มีค่าความเป็นสมาชิกเป็น "1" ตัวอย่างเช่น พิจารณาจุด X ในรูปที่ 3 ที่มี $3n$ ฟัซซีเซต อธิบายออปเจกต์ในรูปเวกเตอร์จะได้ $F=[0.4,0.7,0.1,0.2,0.8,0.4]$ เมื่อเปลี่ยนให้อยู่ในรูปไบนารีเวกเตอร์โดยใช้ 0.5-cut จะได้ $F=[0,1,0,0,1,0]$ ทำให้ได้ 3×3 crisp granules ภายใต้ขอบเขตพิจารณา

หลังจากแปลงทุกเวกเตอร์ให้อยู่ในรูปไบนารีแล้วก็จะได้รับระบบตัดสินใจสำหรับใช้ทฤษฎีฟัซซีสร้างเป็นกฎต่างๆ โดยมองพีเจอร์ต่างๆของเวกเตอร์เป็นแอทริบิวต์ของตาราง ตามลำดับ

ลำดับต่อไปจะกล่าวถึงกระบวนการกำจัด noisy pattern เพื่อทำให้การจัดกลุ่มของออปเจกต์ในโดเมนมีความแม่นยำขึ้นหรือกล่าวได้ว่าเพื่อให้ได้ฟัซซีฟังก์ชันที่ใช้อธิบายกลุ่มออปเจกต์ที่ดีที่สุด กำหนดให้ d_k คือกลุ่มของออปเจกต์ที่เป็นคลาสเดียวกันซึ่งแบ่งออกเป็น m กลุ่ม O_1, O_2, \dots, O_m โดยที่ $card(O_k) = n_{ki}$ เมื่อ $\sum_{i=1}^m n_{ki} = n_k$ และให้ $n_{k1} \geq n_{k2} \geq \dots \geq n_{km}$ เมื่อ n_{ki} แทนจำนวนของออปเจกต์ในแต่ละกลุ่ม ดังนั้นถ้าหากเขียนแทนออปเจกต์ทั้งหมดด้วยอาเรย์ 2 มิติขนาด $m \times 3n$ และกำหนดให้ $n'_{k1} > n'_{k2} > \dots > n'_{km}$ แทนค่าจำนวนที่ไม่ซ้ำกันของแต่ละ n_{ki} แล้วเราจะสามารถใช้สมการ (4) กำจัด noisy pattern ได้

$$Tr = \left\lfloor \frac{\sum_{i=1}^m \frac{1}{n'_{ki} - n'_{ki+1}}}{Th} \right\rfloor \quad (4)$$

กลุ่ม O_k โดยที่มีค่าจามีจำนวนออปเจกต์ภายในกลุ่มน้อยกว่าค่า Tr จะถือว่าเป็น noisy pattern และจะถูกกำจัดออกจากโดเมนก่อน จากนั้นนำข้อมูลที่ได้ในตาราง(อาเรย์ 2 มิติ)เข้าสู่กระบวนการสร้างกฎ[1],[5]

การเปลี่ยนจากกฎเป็น Case

หัวข้อนี้อธิบายวิธีการหาค่า rough dependency เพื่อสร้างเคสต่าง โดยกระบวนการเริ่มจากข้อมูลที่เป็นอินพุทของระบบจะถูกกำจัดส่วนที่เป็นขยะ(noisy pattern) ออกไป จากนั้นนำข้อมูลที่ได้เข้าสู่กระบวนการต่อไป โดยเอาที่พหุสัทท้ยของระบบคือเคสต่างๆที่ใช้สำหรับเป็นตัวแทนในการอธิบายปัญหาและวิธีแก้ปัญหของแต่ละคลัสเตอร์ของข้อมูลในขอบเขตพิจารณา ขั้นตอนการทำงานแบ่งออกเป็นขั้นตอนดังนี้

1. พิจารณาส่วน antecedent ของกฎฟuzzy ตัวแปรภาษาแต่ละตัวจะต้องเชื่อมด้วยโลจิก AND
2. ในแต่ละกฎฟuzzy จะมีนิยามด้วยสามฟuzzy เซ็ตคือ Low Medium และ High โดยมีค่า c และ λ เป็นตัวระบุค่าศูนย์ต่อวงกลางและคาร์ตมีของฟuzzy ฟังก์ชันตามลำดับ
3. ในส่วน consequence ของกฎฟuzzy จะมีค่า df นิยามตามสมการ (3) เป็นตัวระบุความน่าเชื่อถือและความสำคัญของแต่ละกฎ

ดังนั้นโครงสร้างของเคสจึงประกอบไปด้วยข้อมูลต่างๆต่อไปนี้

```
Case{  
  Feature i: fuzzseti :center, radius;  
  .....  
  Class k  
  Strength  
}
```

เมื่อ fuzzset_i ระบุฟuzzy เซ็ต Low Medium และ High ของฟuzzy F_i ตามลำดับ

ตัวอย่าง จากรูปที่ 5 ข้อมูล 2 กลุ่มถูกทอนด้วยเวคเตอร์ 2-มิติ ใช้ 0.5-cut แบ่งพื้นที่ออกเป็น $3^2=9$ granules สำหรับใช้อธิบายกลุ่มข้อมูล 2 กลุ่มคือ C₁ และ C₂ จากนั้นใช้สมการ (4) สร้างกฎจะได้

$$C_1 \leftarrow L_1 \wedge H_2, df = 0.4$$

$$C_2 \leftarrow H_1 \wedge L_2, df = 0.5$$

กำหนดให้พารามิเตอร์ต่างๆของฟuzzy เซ็ต Low Medium และ High มีค่าเป็น

$$\text{Feature1: } c_L = 0.1, \lambda_L = 0.5, c_M = 0.5, \lambda_M = 0.7, c_H = 0.7, \lambda_H = 0.4$$

$$\text{Feature2: } c_L = 0.2, \lambda_L = 0.5, c_M = 0.4, \lambda_M = 0.7, c_H = 0.9, \lambda_H = 0.5$$

ดังนั้นจะได้เคสจำนวน 2 เคสดังนี้

```
case 1 {  
  Feature No: 1, fuzzset (L): center=0.1, radius=0.5  
  Feature No: 2, fuzzset (H): center=0.9, radius=0.5 }  
Class = 1  
Strength = 0:5  
}
```

case 2{

Feature No: 1, fuzzset (H): center=0.7, radius=0.4

Feature No: 2, fuzzset (L): center=0.2, radius=0.5

Class = 2

Strength = 0:4

}

2.4 การค้นคืน Case

หลังจากเสร็จสิ้นกระบวนการในหัวข้อที่ 4.2 เราจะได้เคสต่างๆที่อธิบายในรูปฟังก์ชัน π -function ที่มีค่า c และ λ ของแต่ละฟังก์ชันต่างกันแล้วเก็บลงใจฐานความรู้ ในหัวข้อนี้จะอธิบายขั้นตอนการค้นหาเคสที่ใกล้เคียงกับปัญหาที่เราพิจารณาเพื่อใช้ข้อมูลที่อยู่ในเคสดังกล่าวนำมาตอบปัญหา การค้นหาเคสที่ใกล้เคียงกับปัญหาที่เราพิจารณาใช้ฟังก์ชันวัดค่าความคล้ายดังแสดงในสมการ (10)

$$\text{sim}(F, p) = \sqrt{\frac{1}{n_p} \sum_{j=1}^{n_p} (\mu_{\text{fuzzset}}^j(F_j))^2} \quad (10)$$

เมื่อ F คือรูปแบบของปัญหาที่เรากำลังพิจารณา(ยังไม่รู้กลุ่มของปัญหา)แทนอยู่ในรูปเวกเตอร์ n -มิติ และ p คือเคสที่อยู่ในฐานความรู้ ในขณะที่ $\mu_{\text{fuzzset}}^j(F_j)$ คือค่าความเป็นสมาชิกของฟัเจอร์ F_j ในฟังก์ชันที่ติดตามระบุนอยู่ในเคส p ซึ่งถ้าหากค่า $\mu^i = 1$ สำหรับทุกๆ F_j จะทำให้ค่า $\text{sim}(F,p)=1$ หรือมีค่าสูงสุด และถ้าหาก $\mu^i = 0$ สำหรับทุกๆ F_j จะทำให้ค่า $\text{sim}(F,p)=0$ หรือหมายความว่าปัญหา F ไม่มี ความคล้ายกับเคส p เลย แม้แต่น้อย

ดังนั้นเคสใดๆที่มีให้ค่า $\text{sim}(F,p)$ สูงที่สุดแล้วเราจะถือว่าปัญหาดังแสดงตาม F จะนิยามให้อยู่กลุ่มเดียวกันกับปัญหาที่ระบุอยู่ในเคส p ด้วยค่าความน่าเชื่อถือดังระบุด้วยค่า Case Strength ในเคส p ด้วยเช่นเดียวกัน

บทที่ 3

สรุปและข้อเสนอแนะ

งานวิจัยนี้ได้นำเสนอการสกัดความรู้จากฐานข้อมูลขนาดใหญ่เพื่อเก็บความรู้ดังกล่าวลงระบบ CBR ในรูปแบบกฎพีชซี ด้วยความสามารถด้านการจัดการข้อมูลที่มีความคลุมเครือและความสามารถด้านการเรียนรู้ของนิรอลเน็ตเวิร์คทำให้ระบบจัดการความรู้ที่ได้จะงานวิจัยนี้มีประสิทธิภาพสูง ในกระบวนการเรียนรู้ของนิรอลเน็ตเวิร์คได้รับการสนับสนุนโดยจีนี้ติกอัลกอริทึมและการเรียนรู้แบบควิ(Q-learning) ด้วยความสามารถของการเรียนรู้แบบควิทำให้ระบบสามารถพัฒนาตัวเองให้เป็นระบบที่สามารถเรียนรู้ได้โดยไม่ต้องมีผู้สอน และ/หรือ เป็นระบบกึ่งอาศัยผู้สอนได้

ด้วยการประยุกต์เทคนิคทางด้านปัญหาประดิษฐ์เข้ามาใช้ในงานการจัดการความรู้ทำให้ความรู้อื่นๆสามารถเรียนรู้ได้ด้วยคอมพิวเตอร์โดยทำงานแบบอัตโนมัติทำให้มีประโยชน์ต่อองค์กรเป็นอย่างมาก ในการจัดการองค์ความรู้ เก็บองค์ความรู้ และการนำองค์ความรู้มาใช้ทั้งปัจจุบันและอนาคต อย่างไรก็ตามระบบที่นำเสนอในงานวิจัยนี้ใช้โครงสร้างแบบนิวโรพีชซีและใช้กระบวนการเรียนรู้โดยอาศัยการสนับสนุนจากจีนี้ติกอัลกอริทึมจึงมีข้อดีที่ความเร็วในกระบวนการเรียนรู้ ดังนั้นเพื่อเพิ่มประสิทธิภาพให้กับระบบ การปรับปรุงกลไกในการเรียนรู้ของระบบจะต้องถูกปรับปรุงให้ดีขึ้นซึ่งทางผู้วิจัยจะดำเนินการต่อไปในอนาคต

บทที่ 5
เอกสารอ้างอิง

- [1] Z. Pawlak, Rough Sets, Theoretical Aspects of Reasoning about Data. Dordrecht: Kluwer Academic, 1991.
- [2] L. Polkowski, A. Skowron, and J. Komorowski, "Approximate Case-Based Reasoning: A Rough Mereological Approach," Proc.Fourth German Workshop Case-Based Reasoning, System Deveolpment, and Evaluation, pp. 144-151, 1996.
- [3] T.Y. Lin, L.A. Zadehand J. Kacprzyk, eds. "Granular Computing: Fuzzy Logic and Rough Sets,"Computing with Words in Information/ Intelligent Systems, pp. 183-200, Physica-Verlag, Heidelberg, 1999.
- [4] L.A. Zadeh, J. Man-Machine Studies. "Fuzzy-Algorithmic Approach to the Definition of Complex or Imprecise Concepts," vol. 8, pp. 249-291, 1976.
- [5] T.Y. Lin and R. Chen, "Finding Reducts in Very Large Databases," Proc. Joint Conf. Information Science Research, pp. 350-352, 1997

ภาคผนวก

ภาคผนวก ก สรุปผลงานภายใต้โครงการฯ

- [1] Phaitoon Srinil, Pornthep Rojanavas, Kreangsak Tamee, and Ouen Pinngern, "Case Representation using Rough-Neuro-Fuzzy with GA-Learning," *Electrical Engineering/Electronics, Computer Telecommunications and Information Technology (ECTI) Conference*, Thailand, 2006.

