

## บทที่ 2

### ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

เนื้อหาในบทนี้กล่าวถึงทฤษฎีและงานวิจัยที่เกี่ยวข้องในงานวิจัย ทฤษฎีที่เกี่ยวข้อง มีเนื้อหาเกี่ยวกับทฤษฎีที่ใช้ในงานวิจัยประกอบด้วย การเรียนรู้ของเครื่อง การโปรแกรมตรรกะเชิงอุปนัย และแบ็กพรอพอกชันนิวรอลเน็ตเวิร์ก ส่วนงานวิจัยที่เกี่ยวข้องเป็นงานวิจัยด้านการโปรแกรมตรรกะเชิงอุปนัย

#### ทฤษฎีที่เกี่ยวข้อง

ทฤษฎีที่เกี่ยวข้องในงานวิจัยนี้ประกอบด้วย การเรียนรู้ของเครื่อง การโปรแกรมตรรกะเชิงอุปนัย วิธีการแบ็กพรอพอกชันนิวรอลเน็ตเวิร์ก และวิธีการจำแนกตามกลุ่มหลัก

##### 1. การเรียนรู้ของเครื่อง

การศึกษาด้านการเรียนรู้ของเครื่อง [Mitchell, 1997] มีจุดมุ่งหมายเพื่อให้โปรแกรมคอมพิวเตอร์สามารถพัฒนาความสามารถของตัวเองโดยอัตโนมัติจากตัวอย่างที่ผู้สอนป้อนให้ ตัวอย่างเช่น โปรแกรมคอมพิวเตอร์ซึ่งสามารถเรียนรู้เพื่อเล่นหมากรุก สามารถพัฒนาความสามารถในการเล่นซึ่งวัดจากเปอร์เซ็นต์ในการชนะคู่แข่ง โดยใช้ตัวอย่างซึ่งได้จากการเล่นกับตัวเอง หรือการสร้างโปรแกรมที่สามารถรู้จำภาพตัวเขียนอักษรได้ ซึ่งวัดความสามารถในการรู้จำจากเปอร์เซ็นต์ของภาพตัวอักษรที่รู้จำได้ถูกต้อง โดยใช้ตัวอย่างเป็นภาพตัวอักษรซึ่งผู้สอนป้อนให้

มีการนำวิธีการเรียนรู้ของเครื่องไปใช้เป็นส่วนประกอบสำคัญในการสร้างโปรแกรมเพื่อใช้งานทั่วไป รวมทั้งมีการประยุกต์ใช้กับงานด้านต่างๆ เช่น การสร้างโปรแกรมประยุกต์เพื่อประโยชน์ในด้านธุรกิจ การอนุมัติบัตรเครดิต การค้นพบความรู้จากฐานข้อมูล (Knowledge Discovery from Database) การใช้งานทั่วไป เช่น การรู้จำเสียงพูด การรู้จำภาพ ฯลฯ ตัวอย่างของการประยุกต์ใช้ซึ่งนำวิธีการเรียนรู้ของเครื่องไปใช้งานได้อย่างดี ได้แก่ การรู้จำเสียงพูด [Waibel และคณะ, 1989; Lee, 1989] การทำนายอัตราการฟื้นตัวของผู้ป่วยโรคปอดอักเสบ [Cooper และคณะ, 1997] การสืบหากรณีที่เจ้าของบัตรเครดิตชำระเงินไม่ตรงเวลา การบังคับรถโดยอัตโนมัติบนถนนหลวง [Pomerleau, 1989] หรือการสร้างกลยุทธ์ต่างๆ ในการเล่นเกม [Tesauro, 1992; 1995] ฯลฯ ในทางทฤษฎีก็เช่นกัน มีงานวิจัยจำนวนมากได้พัฒนาวิธีการเรียนรู้ของเครื่องให้มีประสิทธิภาพมากยิ่งขึ้น ตัวอย่างของการพัฒนาเหล่านี้ ได้แก่ การหาความสัมพันธ์พื้นฐานของตัวอย่างที่ป้อนให้เพื่อทำการเรียนรู้ การหาจำนวนสมมติฐานที่เหมาะสมควรนำมาพิจารณา การ

คาดหมายความผิดพลาดของสมมติฐานต่างๆ และการสร้างแบบจำลองของการเรียนรู้ของมนุษย์และสัตว์ รวมทั้งการทำความเข้าใจความสัมพันธ์ของการเรียนรู้ของมนุษย์และสัตว์กับขั้นตอนวิธีการเรียนรู้สำหรับเครื่องคอมพิวเตอร์ [Laird และคณะ, 1986; Qin และคณะ, 1992; Chi และ Bassock, 1989]

ตัวอย่างของการนำวิธีการเรียนรู้ของเครื่องไปใช้งานได้อย่างมีประสิทธิภาพ

#### 1.1 การเรียนรู้เพื่อการรู้จำเสียงพูด

มีการใช้วิธีการเรียนรู้ของเครื่องเป็นองค์ประกอบสำคัญ ส่งผลให้ระบบที่รู้จำเสียงพูดมีประสิทธิภาพสูงขึ้น โดยนำวิธีการเรียนรู้ของเครื่องไปใช้ในรูปแบบต่างๆ เช่น ระบบ SPHINX [Lee, 1989] เรียนรู้เพื่อการรู้จำองค์ประกอบพื้นฐานของเสียงพูด (phonemes) และคำศัพท์ (words) จากสัญญาณเสียง รวมถึงการใช้วิธรรณเ็ดเวิร์กและแบบจำลองฮิดเด็นมาร์คอฟ (Hidden Markov Model) [Waibel และคณะ, 1989; Lee, 1989] เพื่อรู้จำเสียงของผู้พูดแต่ละคน

#### 1.2 การเรียนรู้เพื่อบังคับพาหนะโดยอัตโนมัติ

ใช้การเรียนรู้ของเครื่องเพื่อควบคุมรถยนต์ด้วยเครื่องคอมพิวเตอร์ สามารถควบคุมได้อย่างถูกต้องเมื่อขับเคลื่อนอยู่บนถนนหลายแบบ โดยเรียนรู้จากตัวอย่างที่ผู้สอนเป็นผู้ควบคุมรถ ดังตัวอย่างเช่น ระบบ ALVINN [Pomerleau, 1989] สามารถขับเคลื่อนรถยนต์ได้เองด้วยความเร็ว 70 ไมล์ต่อชั่วโมง เป็นระยะทาง 90 ไมล์ บนทางหลวง ร่วมกับรถยนต์คันอื่นซึ่งมีมนุษย์เป็นผู้บังคับ

#### 1.3 การเรียนรู้เพื่อจำแนกโครงสร้างใหม่ทางดาราศาสตร์

มีการนำวิธีการเรียนรู้ของเครื่องไปประยุกต์ใช้เพื่อค้นหาลักษณะพื้นฐานในระบบฐานข้อมูลขนาดใหญ่ เช่น องค์การบริหารการบินและอวกาศแห่งชาติ สหรัฐอเมริกา หรือ NASA ได้ใช้ขั้นตอนวิธีการเรียนรู้ต้นไม้ตัดสินใจ (Decision Tree Learning Algorithm) เรียนรู้เพื่อจำแนกวัตถุที่อยู่บนท้องฟ้าจากภาพที่มีขนาดใหญ่มาก [Fayyad และคณะ, 1995]

#### 1.4 การเรียนรู้เล่นเกมแบ็กแกมมอน (backgammon)

โปรแกรมคอมพิวเตอร์ที่ใช้เล่นเกมซึ่งประสบความสำเร็จมากที่สุด ได้แก่ โปรแกรมเล่นเกมแบ็กแกมมอน ซึ่งใช้วิธีการเรียนรู้ของเครื่องเป็นแนวคิดพื้นฐาน ตัวอย่างโปรแกรมเหล่านี้ ได้แก่ TD-GAMMON [Tesauro 1992; 1995] เป็นโปรแกรมที่มีความสามารถสูงมากในการเล่นแบ็กแกมมอน สามารถหากลยุทธ์ในการเล่นโดยการฝึกเล่นกับตัวเองจนมีความสามารถเทียบเท่ากับมนุษย์ระดับแชมป์โลก

## 2. การโปรแกรมตรรกะเชิงอุปนัย

การโปรแกรมตรรกะเชิงอุปนัยหรือไอแอลพี [Mitchell, 1997] เป็นการนำวิธีการเรียนรู้ของเครื่องมาใช้ร่วมกับวิธีการโปรแกรมเชิงตรรกะ (Logic Programming) แนวคิดหลักของวิธีการนี้ยังคงเป็นไปตามแนวทางของการเรียนรู้ของเครื่อง คือ การพยายามสร้างแนวคิดเพื่ออธิบายตัวอย่างบวกและไม่อธิบายตัวอย่างลบ เพียงแต่นำวิธีการโปรแกรมเชิงตรรกะมาใช้ในการอธิบายตัวอย่าง และกลุ่มความรู้ภูมิหลังที่ป้อนให้แก่ระบบเพื่อทำการเรียนรู้ ระบบจะเรียนรู้เพื่อสร้างแนวความคิดในรูปแบบของโปรแกรมเชิงตรรกะจากตัวอย่างและความรู้ภูมิหลัง ที่ผู้สอนป้อนให้ ซึ่งแนวความคิดที่ได้จากระบบนี้สามารถนำไปใช้เพื่อทำนายตัวอย่างที่ยังไม่เคยพบได้

เนื่องจากการโปรแกรมตรรกะเชิงอุปนัยเป็นวิธีการเรียนรู้แบบหนึ่งของเครื่อง ดังนั้นจุดมุ่งหมายของการโปรแกรมตรรกะเชิงอุปนัย จึงคล้ายกับจุดมุ่งหมายของการเรียนรู้ของเครื่อง นั่นคือ การพัฒนาเครื่องมือและวิธีการเพื่อสร้างสมมติฐานจากการสังเกตหรือจากตัวอย่าง และเพื่อสังเคราะห์ความรู้ใหม่จากประสบการณ์ที่ได้รับ แต่การใช้โปรแกรมเชิงตรรกะเป็นเครื่องมือในการอธิบายสมมติฐานและตัวอย่าง ทำให้การโปรแกรมตรรกะเชิงอุปนัยมีจุดเด่นเหนือวิธีการเรียนรู้ของเครื่องแบบอื่น ดังนี้

1. การใช้โปรแกรมตรรกะเป็นรูปแบบในการอธิบายความรู้ (knowledge) เนื่องจากความรู้ส่วนใหญ่ของมนุษย์สามารถอธิบายได้ในรูปของตรรกะลำดับที่หนึ่ง แต่ในวิธีการเรียนรู้ของเครื่องส่วนใหญ่มักจะอธิบายความรู้เหล่านี้โดยการใช้ตรรกศาสตร์ประพจน์ ทำให้ไม่สามารถอธิบายความรู้ของมนุษย์ได้เท่าที่ควร นอกจากนี้ข้อได้เปรียบสำคัญอีกประการหนึ่งของการใช้โปรแกรมเชิงตรรกะ คือ การใช้โปรแกรมตรรกะเพื่ออธิบายแนวความคิดที่สังเคราะห์ได้จากตัวอย่างสามารถอธิบายแนวความคิดได้ซับซ้อนมากยิ่งขึ้น ซึ่งการอธิบายด้วยตรรกศาสตร์ประพจน์แต่เพียงอย่างเดียว จะไม่สามารถครอบคลุมแนวคิดได้ทั้งหมด
2. สามารถใช้ความรู้ภูมิหลังในกระบวนการเรียนรู้ได้ง่ายกว่าการเรียนรู้ของเครื่องแบบอื่น ที่ไม่ใช้การโปรแกรมเชิงตรรกะ

หลักการสำคัญของการโปรแกรมตรรกะเชิงอุปนัย คือ การสร้างแนวคิด หรือกฎ หรือสมมติฐาน (h) ที่สามารถอธิบายเซตของตัวอย่างบวก (E) ได้ โดยใช้ประกอบกับความรู้ภูมิหลัง (B) ดังความสัมพันธ์

$$B \wedge h \vdash E$$

จุดมุ่งหมายสำคัญของวิธีการโปรแกรมตรรกะเชิงอุปนัยคือ การสร้างสมมติฐานซึ่งเมื่อรวมกับความรู้ภูมิหลังแล้วสามารถชี้ป็นนัยถึง (imply) ตัวอย่างได้ โดยสร้างสมมติฐานจากกลุ่มตัวอย่างและความรู้ภูมิหลังที่ป้อนให้ ทฤษฎีที่เกี่ยวข้องในการสร้างสมมติฐานมีหลายวิธี เช่น วิธีการอนุมานเชิงอุปนัย (Inductive Inference) ไออาร์ (Inverse Resolution, IR) อาร์แอลจีจี (Relative Least General Generalization,

RLGG) ไออี (Inverse Entailment, IE) ฯลฯ ในที่นี้ได้นำเสนอทฤษฎีที่เกี่ยวข้องดังนี้ คือ วิธีการอนุมานเชิงอุปนัย วิธีการไออาร์ และวิธีการอาร์แอลจีจี

## 2.1 วิธีการอนุมานโดยอุปนัย [Mitchell, 1997]

ในการสร้างสมมติฐานขึ้นจากตัวอย่างและความรู้ภูมิหลัง จำเป็นต้องสร้างข้อกำหนดขึ้น ดังนี้ “กำหนดให้  $D$  เป็นเซตของตัวอย่างที่ใช้สอนเพื่อเรียนรู้โดยมีรูปแบบเป็น  $\langle x_i, f(x_i) \rangle$  เมื่อ  $x_i$  คือ ตัวอย่างที่  $i$  และ  $f(x_i)$  เป็นค่าที่ต้องการ (target value) และ  $B$  คือความรู้ภูมิหลัง คำนิยามของการเรียนรู้คือการสร้างสมมติฐาน  $h$  ซึ่งค่า  $f(x_i)$  ของแต่ละตัวอย่าง  $x_i$  แต่ละตัวสามารถซึ่งเป็นนัยถึงได้ด้วยสมมติฐาน  $h$  ลักษณะของ  $x_i$  และความรู้ภูมิหลัง  $B$ ” ดั่งนิพจน์ที่ (1)

$$(\forall \langle x_i, f(x_i) \rangle \in D) (B \wedge h \wedge x_i) \vdash f(x_i) \quad (1)$$

นิพจน์  $X \vdash Y$  หมายความว่า “ $Y$  สามารถซึ่งเป็นนัยถึงได้โดยใช้  $X$ ” ซึ่งในนิพจน์ (1) หมายความว่า สำหรับทุกตัวอย่าง  $x_i$  ค่าของ  $f(x_i)$  สามารถซึ่งเป็นนัยถึงได้โดยใช้ความรู้ภูมิหลัง  $B$  สมมติฐาน  $h$  และตัวอย่าง  $x_i$

ตัวอย่างเช่น ในการสร้างแนวความคิดของความสัมพันธ์ระหว่างคนสองคน  $\langle U, V \rangle$  เมื่อ  $U$  เป็นบุตรของ  $V$  แทนด้วยเพรดิเคต  $child(U, V)$  สมมติให้มีตัวอย่างบวกเพียงตัวอย่างเดียวคือ  $child(sharon, bob)$  โดยมีเพรดิเคตที่ใช้อธิบายตัวอย่างนี้คือ  $male(bob)$ ,  $female(sharon)$  และ  $father(bob, sharon)$  และมีความรู้ภูมิหลังเป็น  $parent(U, V) \leftarrow father(U, V)$  จะสามารถอธิบายโดยใช้นิพจน์ (1) ได้ดังนี้

$$\begin{aligned} x_i : & \quad male(bob), female(sharon), father(bob, sharon) \\ f(x_i) : & \quad child(sharon, bob) \\ B : & \quad parent(U, V) \leftarrow father(U, V) \end{aligned}$$

ในกรณีนี้สามารถสร้างสมมติฐานได้หลายแบบซึ่งสามารถครอบคลุมตัวอย่างได้ ตามคำนิยามในนิพจน์ (1)  $(B \wedge h \wedge x_i) \vdash f(x_i)$  ซึ่งในที่นี้จะยกตัวอย่างสมมติฐาน 2 ข้อ ดังนี้

$$\begin{aligned} h_1 : & \quad child(U, V) \leftarrow father(V, U) \\ h_2 : & \quad child(U, V) \leftarrow parent(V, U) \end{aligned}$$

จะเห็นว่าเพรดิเคตเป้าหมาย  $child(sharon, bob)$  ถูกครอบคลุมด้วยเงื่อนไข  $h_1 \wedge x_i$  โดยไม่ต้องใช้ความรู้ภูมิหลัง  $B$  แต่สำหรับในกรณีของสมมติฐาน  $h_2$  เมื่อนำ  $h_2$  ไปรวมกับ  $x_i$  โดยไม่ใช้ความรู้ภูมิหลัง  $B$  จะพบว่าไม่ครอบคลุมเพรดิเคต  $child(sharon, bob)$  จำเป็นต้องใช้ความรู้ภูมิหลัง  $B$  ประกอบด้วย จึงจะทำให้เป็นไปตามเงื่อนไข  $(B \wedge h \wedge x_i) \vdash f(x_i)$  ตัวอย่างนี้แสดงให้เห็นถึงบทบาทสำคัญของความรู้ภูมิหลังในการ

ขยายเซตของสมมติฐานจากตัวอย่าง ดังเช่นในสมมติฐาน  $h_2$  จะต้องใช้ความรู้ภูมิหลังร่วมด้วยจึงสามารถครอบคลุมตัวอย่างได้

ในการค้นหาสมมติฐานตามความสัมพันธ์  $(\forall \langle x, f(x) \rangle \in D) (B \wedge h \wedge x) \vdash f(x)$  มีลักษณะที่น่าสนใจหลายประการ เช่น

- ความสัมพันธ์นี้สนับสนุนคำนิยามพื้นฐานของการเรียนรู้ คือ การค้นหาแนวคิดทั่วไปซึ่งสามารถใช้อธิบายเซตของตัวอย่างที่ใช้ในการสอนได้
- เมื่อใช้ความรู้ภูมิหลังประกอบ สามารถสร้างสมมติฐานที่ครอบคลุมตัวอย่างได้มากขึ้น
- ความรู้ภูมิหลังสามารถช่วยให้กระบวนการเรียนรู้ค้นหาสมมติฐานได้ง่ายขึ้น

## 2.2 วิธีการโออาร์ [Mitchell, 1997]

กฎรีโซลูชัน (resolution rule) เป็นวิธีการหนึ่งที่ได้รับค่านิยมในการนำมาพิจารณาตรรกะลำดับที่หนึ่ง เพื่อสร้างสมมติฐานจากตัวอย่างบวก ตัวอย่างลบ และความรู้ภูมิหลังได้ มีการนำไปใช้เป็นแนวคิดพื้นฐานในระบบ CIGOL [Muggleton และ Buntine; 1998]

กำหนดให้  $L$  เป็นประพจน์  $P$  และ  $R$  เป็นอนุประโยคที่เกิดจากประพจน์หลายประพจน์มารวมกัน จะได้กฎรีโซลูชัน คือ

$$\frac{\begin{array}{ccc} P & \vee & L \\ \neg L & \vee & R \end{array}}{P \vee R}$$

หมายความว่า สามารถสรุปอนุประโยค  $P \vee R$  ได้จากอนุประโยค  $P \vee L$  และอนุประโยค  $\neg L \vee R$  ซึ่งสามารถนำไปใช้ในการสร้างสมมติฐานที่ครอบคลุมตัวอย่างได้ ดังนี้

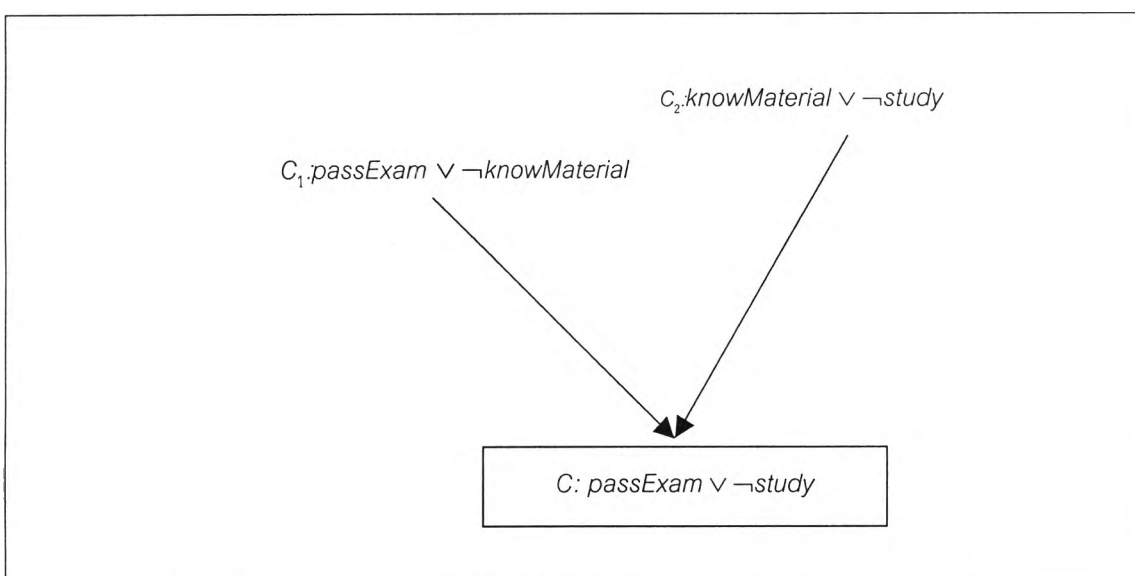
1. กำหนดให้มีอนุประโยค  $C_1$  และ  $C_2$  ให้หาสัญลักษณ์  $L$  จากอนุประโยค  $C_1$  ซึ่งมีสัญลักษณ์  $\neg L$  ปรากฏอยู่ในอนุประโยค  $C_2$
2. สร้างอนุประโยคสรุป  $C$  โดยรวมสัญลักษณ์ทุกตัวจาก  $C_1$  และ  $C_2$  ยกเว้นสัญลักษณ์  $L$  และ  $\neg L$  ดังสมการ

$$C = (C_1 - \{L\}) \cup (C_2 - \{\neg L\})$$

การใช้กฎรีโซลูชันในการสรุปสมมติฐานจากตัวอย่าง โดยการใช้อนุประโยคที่มีอยู่  $C_1$  และ  $C_2$  ให้กำหนดสัญลักษณ์  $L$  ซึ่งเป็นสัญลักษณ์แบบบวก (positive literal) ในอนุประโยคหนึ่ง และเป็นสัญลักษณ์แบบลบ (negative literal) ในอนุประโยคที่เหลือ จะสามารถสร้างอนุประโยคสรุป  $C$  ได้ ดังรูปที่ 2.1 กำหนดให้มีอนุประโยค  $C_1$  และ  $C_2$  ในขั้นแรกต้องกำหนดสัญลักษณ์  $L = \neg \text{knowMaterial}$  ซึ่งปรากฏอยู่ในอนุประโยค

$C_1$  และสัญญาพจน์ที่ตรงข้ามคือ  $\neg(\neg knowMaterial) = knowMaterial$  ซึ่งปรากฏอยู่ในอนุประโยค  $C_2$  ดังนั้นผลสรุปของสองอนุประโยคนี้ คือ การรวมกันของสัญญาพจน์  $C_1 - \{L\} = passExam$  และ  $C_2 - \{\neg L\} = \neg study$

เมื่อสามารถนำกฎรีโซลูชันมาใช้เพื่อหาข้อสรุปจากอนุประโยคได้ ก็เป็นการง่ายที่จะสร้างตัวดำเนินการโออาร์  $(C, C_1)$  ซึ่งสามารถทำการอนุมานโดยอุปนัยได้ โดยการสร้างอนุประโยคเริ่มแรก  $C_2$  จากข้อสรุป  $C$  และอนุประโยคเริ่มแรกอีกประโยคหนึ่งคือ  $C_1$  ตัวอย่างเช่น มีข้อสรุป  $C = A \vee B$  และอนุประโยคเริ่มต้น  $C_1 = B \vee D$  จุดมุ่งหมายคือ การพยายามสร้างอนุประโยค  $C_2$  ซึ่ง  $C_1 \wedge C_2 \vdash C$



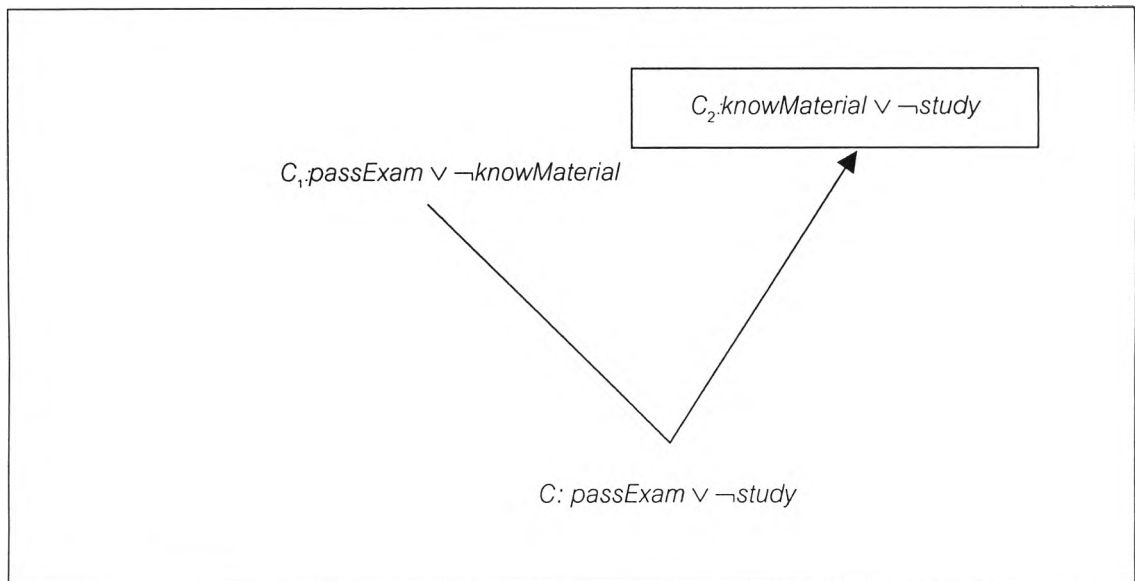
รูปที่ 2.1 ตัวอย่างของการใช้กฎรีโซลูชันในการหาข้อสรุปจากอนุประโยค 2 อนุประโยค

วิธีการ ขั้นแรก จากนิยามของกฎรีโซลูชัน สัญญาพจน์ใดๆ ที่ปรากฏในอนุประโยค  $C$  แต่ไม่ปรากฏในอนุประโยค  $C_1$  จะต้องปรากฏใน  $C_2$  ในตัวอย่างก่อนหน้านั้น ในอนุประโยค  $C_2$  จะต้องมียุทธศาสตร์  $A$  ชั้นที่สอง สัญญาพจน์ที่ปรากฏใน  $C_1$  แต่ไม่ปรากฏใน  $C$  จะต้องเป็นสัญญาพจน์ที่ถูกดึงออกโดยกฎรีโซลูชัน ดังนั้นนิเสธของสัญญาพจน์นี้จะปรากฏใน  $C_2$  จากตัวอย่างเดิม อนุประโยค  $C_2$  จึงต้องมีสัญญาพจน์  $\neg D$  ปรากฏอยู่ด้วย สุดท้ายจะได้สัญญาพจน์  $C_2 = A \vee \neg D$  ซึ่งสามารถสรุปการดำเนินการโออาร์ได้ดังนี้

1. กำหนดอนุประโยค  $C_1$  และ  $C$  ให้หาสัญญาพจน์  $L$  จากอนุประโยค  $C_1$  แต่ไม่ปรากฏอยู่ในอนุประโยค  $C$
2. สร้างอนุประโยค  $C_2$  ดังสมการ

$$C_2 = (C - (C_1 - \{L\})) \cup \{\neg L\}$$

ตัวอย่างในรูป 2.2 แสดงการใช้ตัวดำเนินการโออาร์ ในการสร้างสมมติฐาน  $C_2 = knowMaterial \vee \neg study$  จากอนุประโยค  $C = passExam \vee \neg study$  และอนุประโยค  $C_1 = passExam \vee \neg knowMaterial$



รูปที่ 2.2 ตัวอย่างของการใช้ตัวดำเนินการไอออาร์ในการสร้างสมมติฐานจากอนุประโยค 2 อนุประโยค

### 2.3 การรีโซลูชันลำดับที่หนึ่ง (First-Order Resolution) [Mitchell, 1997]

ก่อนหน้านี้ได้นำเสนอการทำรีโซลูชันเมื่อนำไปใช้กับประพจน์ เพื่อหาอนุประโยคที่สามจากอนุประโยคสองอนุประโยคที่กำหนดให้ เมื่อนำมาประยุกต์ใช้กับตรรกะลำดับที่หนึ่ง เพื่อสร้างการรีโซลูชันลำดับที่หนึ่ง จะใช้พื้นฐานของตัวแทนรวม (unifying substitution)

กำหนดตัวแทน  $\theta = \{X/bob, Y/Z\}$  หมายความว่า ใช้ค่าคงที่ *bob* แทนตัวแปร *X* และใช้ตัวแปร *Z* แทนตัวแปร *Y* และใช้เครื่องหมาย  $W\theta$  แทนผลการแทนโดยตัวแทน  $\theta$  ในนิพจน์ *W* ตัวอย่างเช่น ถ้า *L* เป็นสัจพจน์ *father(X, bill)* และ  $\theta = \{X/bob, Y/Z\}$  จะได้  $W\theta = \text{father}(bob, bill)$

ตัวแทนรวม  $\theta$  สำหรับสัจพจน์สองสัจพจน์  $L_1$  และ  $L_2$  คือ ตัวแทนรวมซึ่งเมื่อนำไปแทนตัวแปรแล้วจะทำให้สัจพจน์  $L_1\theta = L_2\theta$  ตัวอย่างเช่น ถ้า  $L_1 = \text{father}(X, Y)$ ,  $L_2 = \text{father}(bill, Z)$ , และ  $\theta = \{X/bill, Z/Y\}$ , แล้ว  $\theta$  เป็นตัวแทนรวมสำหรับ  $L_1$  และ  $L_2$  เพราะ  $L_1\theta = L_2\theta = \text{father}(bill, Y)$  ซึ่งกฎรีโซลูชันลำดับที่หนึ่งจะสร้างอนุประโยคสรุป *C* ด้วยวิธีการดังนี้

1. หาสัจพจน์  $L_1$  จากอนุประโยค  $C_1$  สัจพจน์  $L_2$  จากอนุประโยค  $C_2$  และตัวแทน  $\theta$  ซึ่งทำให้  $L_1\theta = L_2\theta$
2. สร้างอนุประโยคสรุปโดยรวมทุกสัจพจน์จาก  $C_1\theta = C_2\theta$  ยกเว้นสัจพจน์  $L_1\theta$  และ  $\neg L_2\theta$  ดังสมการ

$$C = (C_1 - \{L_1\})\theta \cup (C_2 - \{L_2\})\theta$$

## 2.4 วิธีการไอราร์ในกรณีลำดับที่หนึ่ง (Inverse Resolution: First-Order Case) [Mitchell, 1997]

จากหัวข้อที่แล้วในการรีโซลูชันลำดับที่หนึ่งจะได้

$$C = (C_1 - \{L_1\})\theta_1 \cup (C_2 - \{L_2\})\theta_2$$

กำหนดให้ในอนุประโยค  $C_2$  ไม่มีสัจพจน์ที่เหมือนกับสัจพจน์ในอนุประโยค  $C_1$  เราสามารถเปลี่ยนสมการข้างต้นเป็น

$$C - (C_1 - \{L_1\})\theta_1 = (C_2 - \{L_2\})\theta_2$$

สุดท้ายเราใช้นิยามของกฎการรีโซลูชัน  $L_2 = \neg L_1\theta_1\theta_2^{-1}$  เราจะสามารถสรุปอนุประโยค  $C_2$  เป็นกฎไอราร์ได้ดังนี้

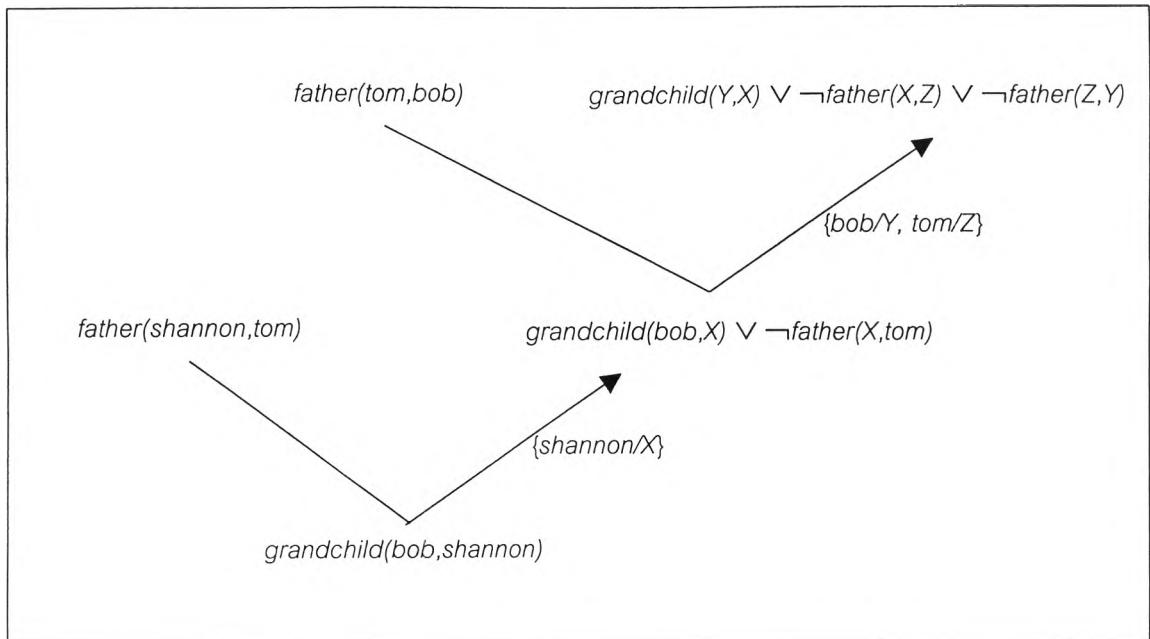
$$C_2 = (C - (C_1 - \{L_1\})\theta_1)\theta_2^{-1} \cup \{\neg L_1\theta_1\theta_2^{-1}\}$$

ตัวอย่างในรูปที่ 2.3 ต้องการเรียนรู้กฎสำหรับเพรดิกเตดเป้าหมาย  $grandchild(Y,X)$  โดยกำหนดข้อมูลที่ใช้ทำการเรียนรู้  $D = grandchild(bob,shannon)$  และข้อมูลซึ่งเป็นความรู้ภูมิหลัง  $B = \{father(shannon,tom), father(tom,bob)\}$  พิจารณาส่วกลางที่สุดของรูปที่ 2.3 ในที่นี้ให้ข้อสรุป  $C$  เป็นตัวอย่างที่ใช้ในการเรียนรู้  $grandchild(bob,shannon)$  และเลือกอนุประโยค  $C_1 = father(shannon,tom)$  จากกลุ่มความรู้ภูมิหลังในการใช้ตัวดำเนินการไอราร์สำหรับสัจพจน์  $L_1$  คือ  $father(shannon,tom)$  เลือกตัวแทนย้อนกลับ  $\theta_1^{-1} = \{\}$  และ  $\theta_2^{-1} = \{shannon/X\}$  ในกรณีนี้เราสามารถสร้างอนุประโยค  $C_2$  เป็นการรวมกันของอนุประโยค  $(C - (C_1 - \{L_1\})\theta_1)\theta_2^{-1} = (C\theta_1)\theta_2^{-1} = grandchild(bob,X)$  และอนุประโยค  $\{\neg L_1\theta_1\theta_2^{-1}\} = \neg father(X,tom)$  ดังนั้นผลลัพธ์ คือ อนุประโยค  $grandchild(bob,X) \vee \neg father(X,tom)$  ซึ่งมีค่าเท่ากับอนุประโยค  $grandchild(bob,X) \leftarrow father(X,tom)$  ด้วยวิธีเดียวกันนี้ เราสามารถสร้างอนุประโยคสุดท้าย  $grandchild(Y,X) \leftarrow father(X,Z) \wedge father(Z,Y)$  ได้

## 2.5 วิธีการอาร์แอลจีจี [Muggleton และ Feng, 1992]

วิธีการอาร์แอลจีจี เป็นอีกวิธีการหนึ่งนอกเหนือจากวิธีการไอราร์ซึ่งมีผู้นำมาใช้ในการสร้างอนุประโยคที่สามารถครอบคลุมตัวอย่างในระบบไอบแอลพี โดยให้แนวคิดของ Plotkin [Plotkin, 1971] สำหรับวิธีการอาร์แอลจีจี คือ การแทนที่การค้นหาด้วยกระบวนการสร้างอนุประโยคซึ่งครอบคลุมเซตของตัวอย่าง





รูปที่ 2.3 ตัวอย่างของการใช้วิธีการโออาร์ในการสร้างกฎสำหรับเพรดิเคตเป้าหมาย  $grandchild(Y,X)$

ก่อนอธิบายถึงวิธีการอาร์แอลจีจี Plotkin ให้คำนิยามของคำว่า  $\theta$ -subsume ว่า อนุประโยค  $C$   $\theta$ -subsume อนุประโยค  $D$  หรือ  $C \leq D$  ก็ต่อเมื่อ ถ้าสามารถหาการแทนที่ (substitution)  $\theta$  ซึ่งทำให้  $C\theta \subseteq D$  จากนั้น Plotkin ได้อธิบายถึงวิธีการแอลจีจี (least general generalisation: lgg) ว่าเป็นการหาขอบเขตล่างซึ่งมีน้อยทั่วไป (general) น้อยที่สุดในแลตทิซ (lattice) ที่ถูกสร้างโดยความสัมพันธ์  $\leq$  เราสามารถหาแอลจีจีของพจน์ (term) 2 พจน์  $p(g(a),a)$  และ  $p(g(b),b)$  ได้เป็น  $p(g(X),X)$  ซึ่งถ้าเราใช้ตัวแทน  $\{X/a\}$  กับพจน์  $p(g(X),X)$  จะได้พจน์  $p(g(a),a)$  และเมื่อใช้ตัวแทน  $\{X/b\}$  จะได้พจน์  $p(g(b),b)$

สำหรับการหาแอลจีจีของอนุประโยค 2 อนุประโยคใดๆ มีวิธีการดังนี้

1. หาแอลจีจีของสัญลักษณ์ในส่วนหัวของอนุประโยคเพื่อเป็นส่วนหัวของอนุประโยคใหม่
2. หาการรวม (combination) ทุกแบบที่เป็นไปได้ของแอลจีจีในส่วนคำอธิบาย (body) ของกฎเพื่อสร้างส่วนคำอธิบายของอนุประโยคใหม่
3. ถ้ามีสัญลักษณ์ใดปรากฏในอนุประโยคเดียวไม่ปรากฏอยู่ในอีกอนุประโยคหนึ่ง ไม่ต้องนำอนุประโยคนั้นไปไว้ในอนุประโยคใหม่

ตัวอย่างเช่น การหาแอลจีจีของอนุประโยค 2 อนุประโยค ต่อไปนี้

$$q(g(a)) \leftarrow p(g(a, b), r(h(b), c), r(b, d)).$$

$$q(x) \leftarrow p(x, y), r(y, z), r(h(y), z), s(g(x), h(y)).$$

แอลจีจีของอนุประโยคทั้งสอง คือ

$$q(x) \leftarrow p(X, Y), r(Z, U), r(V, W), r(h(Y), U), r(Y, W).$$

โดยมีตัวแทนเป็น

$$\{ X/\{g(a), x\}, Y/\{b, y\}, Z/\{h(b), y\}, U/\{c, z\}, V/\{b, h(y)\}, W/\{d, z\} \}$$

เมื่อสามารถหาแอสจี้ของสองอนุประโยคได้แล้ว เราก็สามารถทำอาร์แอสจี้ได้ โดยกำหนดให้  $\mathcal{K}$  เป็นเซตของความรู้ภูมิหลัง  $e_1$  และ  $e_2$  เป็นตัวอย่างบวก ( $e_1, e_2 \in \mathcal{E}$ ) ซึ่ง  $\mathcal{K} \# e_1$  และ  $\mathcal{K} \# e_2$  อนุประโยค  $C$  เป็นแอสจี้ของตัวอย่าง  $e_1$  และ  $e_2$  สัมพันธ์กับ  $\mathcal{K}$  ก็ต่อเมื่อ  $C$  เป็นอนุประโยคที่มีนัยทั่วไปน้อยที่สุดภายในขอบเขตแห่งแลตทิซของ  $\theta$ -subsumption ซึ่ง  $\mathcal{K} \wedge C \vdash e_1 \wedge e_2$  โดยที่อนุประโยค  $C$  ถูกใช้เพียงครั้งเดียวในการหา  $e_1$  และ  $e_2$  วิธีการสร้างอาร์แอสจี้สามารถพิสูจน์ได้ดังนี้

$$\begin{aligned}
& \mathcal{K} \wedge C \vdash e_1, \\
& C \vdash \mathcal{K} \rightarrow e_1, \\
& \vdash C \rightarrow (\mathcal{K} \rightarrow e_1), \\
& \vdash C \rightarrow (\neg \mathcal{K} \vee e_1), \\
& \vdash C \rightarrow ((\neg(a_1 \wedge a_2 \wedge \dots) \vee e_1) \quad (2) \\
& \vdash C \rightarrow ((\neg a_1 \vee \neg a_2 \vee \dots) \vee e_1)
\end{aligned}$$

ในนิพจน์ที่ (2) เป็นการแทน  $\mathcal{K}$  ด้วยกลุ่มความรู้ภูมิหลัง  $a_1 \wedge a_2 \wedge \dots$  ซึ่งสามารถแทนได้หลายรูปแบบด้วยกัน ในขณะที่เดียวกันเราสามารถหา  $e_2$  ได้เช่นเดียวกับ  $e_1$  จะได้

$$\vdash C \rightarrow ((\neg a_1 \vee \neg a_2 \vee \dots) \vee e_2)$$

ถ้ากำหนดให้  $C_1$  และ  $C_2$  เป็น  $((\neg a_1 \vee \neg a_2 \vee \dots) \vee e_1)$  และ  $\vdash C \rightarrow ((\neg a_1 \vee \neg a_2 \vee \dots) \vee e_2)$  ตามลำดับ จะได้

$$\vdash C \rightarrow \text{lgg}(C_1, C_2)$$

ตัวอย่างเช่น หากมีกลุ่มความรู้ภูมิหลังเป็นดังนี้

```

partition(X,[],[],[]).
partition(X,[Head|Tail],[Head|Sublist1],Sublist2) ←
    lte(Head,X),
    partition(X,Tail,Sublist1,Sublist2).
partition(X,[Head|Tail],Sublist1,[Head|Sublist2] ←
    gt(Head,X),
    partition(X,Tail,Sublist1,Sublist2).
append([],List,List).
append([Head|Tail],List,[Head|Rest]) ←
    append(Tail,List,Rest).

```

lte(0,0).

lte(0,1).

...

gt(1,0).

gt(2,0).

gt(2,1).

...

สมมติให้  $e_1 = \text{qsort}([1],[1])$  และ  $e_2 = \text{qsort}([2,4,3,1,0],[0,1,2,3,4])$

$C_1 = \text{qsort}([1],[1]) \leftarrow$

append([], [1], [1]),

append([0,1], [2,3,4], [0,1,2,3,4]), ...

partition(1, [], [], []),

partition(2, [4,3,1,0], [1,0], [4,3]), ...

qsort([], []),

qsort([1,0], [0,1]),

qsort([4,3], [3,4]), ...

$C_2 = \text{qsort}([2,4,3,1,0],[0,1,2,3,4]) \leftarrow$

append([], [1], [1]),

append([0,1], [2,3,4], [0,1,2,3,4]), ...

partition(1, [], [], []),

partition(2, [4,3,1,0], [1,0], [4,3]), ...

qsort([], []),

qsort([1,0], [0,1]),

qsort([4,3], [3,4]), ...

จะได้  $C = \text{lgg}(C_1, C_2)$

$= \text{qsort}([A|B], [C|D]) \leftarrow$

append(E, [A|F], [C|D]),

append([], [1], [1]),

append(G, [H|I], [J|K]),

append([0,1], [2,3,4], [0,1,2,3,4]),

partition(A, B, L, M),



ต้องใช้เพอร์เซปตรอนมาต่อกันให้มีลักษณะเป็นหลายชั้น เพื่อให้สามารถแยกตัวอย่างเหล่านี้ได้ จึงมีการสร้างนิวรอลเน็ตเวิร์กแบบหลายชั้นขึ้น

แบ็กพรอพาเกชันนิวรอลเน็ตเวิร์กแบบหลายชั้น (Multilayer Backpropagation Neural Network) เป็นขั้นตอนวิธีแบบหนึ่งของนิวรอลเน็ตเวิร์ก มีความสามารถในการสร้างดิซิชันเซอร์เฟสแบบไม่เป็นเชิงเส้น (nonlinear decision surface) ตัวอย่างของการนำนิวรอลเน็ตเวิร์กแบบหลายชั้นไปใช้งานได้แก่ การจำแนกเสียงสระ 10 เสียง [Huang และคณะ, 1988] ทั้งหมดอยู่ในรูปแบบของคำศัพท์ "h\_d" (เช่น "hid", "had", "head", "hood", ฯลฯ) มีสัญญาณอินพุตเป็นตัวเลขพารามิเตอร์ 2 ตัว จากการวิเคราะห์สเปกตรัม (spectral analysis) ของเสียง ทำให้สามารถสร้างดิซิชันเซอร์เฟสได้ใน 2 มิติ ซึ่งสามารถแบ่งแยกตัวอย่างได้ดีกว่าดิซิชันเซอร์เฟสแบบเชิงเส้น (linear decision surface)

แบ็กพรอพาเกชันนิวรอลเน็ตเวิร์กต่างจากเพอร์เซปตรอนที่องค์ประกอบย่อยของนิวรอลเน็ตเวิร์ก ซึ่งเป็นองค์ประกอบที่สามารถทำงานกับฟังก์ชันแบบไม่เชิงเส้น (nonlinear function) โดยใช้องค์ประกอบซิกมอยด์ดังรูปที่ 2.4

องค์ประกอบซิกมอยด์จะทำงานโดยหาผลคูณเวกเตอร์ของอินพุตเวกเตอร์กับค่าน้ำหนักของเส้นเชื่อมระหว่างอินพุตนิวรอนกับนิวรอนในชั้นถัดไป จากนั้นนำผลที่ได้ผ่านตัวกรอง (threshold) เอาต์พุตขององค์ประกอบซิกมอยด์จะเป็นฟังก์ชันต่อเนื่อง (Continuous Function) ที่มีค่าเข้าใกล้ 0 หรือ 1 ในขณะที่เอาต์พุตของเพอร์เซปตรอนธรรมดาจะให้ค่าเป็นค่าไม่ต่อเนื่อง ฟังก์ชันซิกมอยด์มีค่านิยามเป็นดังนี้

$$o = \sigma(\bar{w} \cdot \bar{x})$$

โดย

$$\sigma(y) = \frac{1}{1 + e^{-y}}$$

เมื่อ

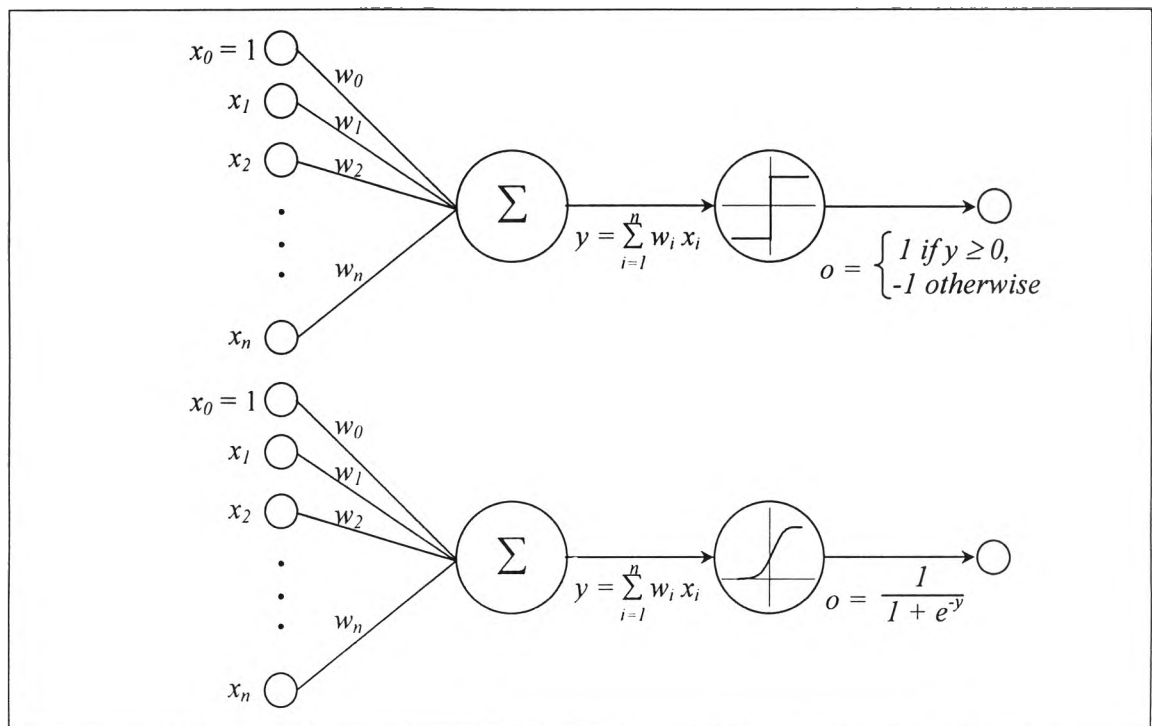
$o$  - เอาต์พุต

$\bar{x}$  - อินพุต

$\bar{w}$  - ค่าน้ำหนักของอินพุตนั้นๆ

$\sigma$  - ฟังก์ชันซิกมอยด์ (sigmoid function) ซึ่งให้ค่าเอาต์พุตระหว่าง 0 และ 1

ขั้นตอนวิธีแบ็กพรอพาเกชันนิวรอลเน็ตเวิร์ก [Mitchell, 1992] ทำการเรียนรู้เพื่อปรับค่าน้ำหนักสำหรับนิวรอลเน็ตเวิร์กแบบหลายชั้น โดยใช้วิธีการเกรเดียนต์เดสเซนต์ (gradient descent) เพื่อลดกำลังสองของค่าผิดพลาด (squared error) ระหว่างเอาต์พุตที่ได้จากเน็ตเวิร์กและค่าเป้าหมายของอินพุตเหล่านี้ให้น้อยที่สุด โดยมีขั้นตอนวิธีสำหรับการปรับค่าน้ำหนักในแบบแบ็กพรอพาเกชันดังนี้



รูปที่ 2.4 องค์ประกอบของไบโพลาร์ (รูปบน) และองค์ประกอบซิกมอยด์ (รูปล่าง)

กำหนดให้ตัวอย่างที่ใช้ในการเรียนรู้แต่ละตัวอย่างอยู่ในรูป  $(\bar{x}, \bar{t})$  เมื่อ  $\bar{x}$  เป็นอินพุตเวกเตอร์ของนิวรอลเน็ตเวิร์ก และ  $\bar{t}$  เป็นเวกเตอร์เป้าหมายของนิวรอลเน็ตเวิร์ก  $\eta$  เป็นค่าอัตราการเรียนรู้ (learning rate)

อินพุตขององค์ประกอบ  $j$  ซึ่งมาจากองค์ประกอบ  $i$  แทนด้วย  $x_{ij}$  และค่าน้ำหนักขององค์ประกอบ  $j$  ซึ่งมาจากองค์ประกอบ  $i$  แทนด้วย  $w_{ij}$

1. สร้างนิวรอลเน็ตเวิร์กตามโครงสร้างที่ต้องการ กำหนดจำนวนนิวรอนของแต่ละชั้น
2. กำหนดค่าน้ำหนักเริ่มต้นแบบสุ่มให้มีค่าน้อยๆ (เช่น ระหว่าง -0.05 ถึง 0.05)
3. ปรับค่าน้ำหนักด้วยขั้นตอนวิธีดังนี้

– สำหรับแต่ละอินพุตเวกเตอร์  $(\bar{x}, \bar{t})$  ในเซตตัวอย่างที่ใช้เรียนรู้

1. ใช้ตัวอย่าง  $x$  เป็นอินพุต คำนวณหาค่า  $o_k$  ของทุกๆ นิวรอนในนิวรอลเน็ตเวิร์ก
2. คำนวณค่าความคลาดเคลื่อน  $\delta_k$  ของทุกนิวรอน  $k$  ในชั้นเอาต์พุต

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

3. คำนวณค่าความคลาดเคลื่อน  $\delta_h$  ของทุกนิวรอน  $h$  ในชั้นซ่อน

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

4. ปรับค่าน้ำหนักของเส้นเชื่อม  $w_{ij}$

$$w_{ij} \leftarrow w_{ij} + \Delta w_{ij}$$

เมื่อ

$$\Delta w_{ij} = \eta \delta_j x_{ij}$$

#### 4. วิธีการจำแนกตามกลุ่มหลัก (Majority Class Method)

ในการทดลองเพื่อเปรียบเทียบขั้นตอนวิธี CN2 ของ Clark และ Niblett (1989) มีการนำวิธีการจำแนกตามกลุ่มหลักมาทดลองเปรียบเทียบกับวิธีการอื่น ในการจำแนกตัวอย่างของวิธีการจำแนกตามกลุ่มหลักนี้ ระบบจะจำแนกตัวอย่างทดสอบให้อยู่ในกลุ่มซึ่งปรากฏมากที่สุดในกลุ่มตัวอย่างที่ใช้เรียนรู้ โดยไม่สนใจค่าคุณลักษณะของตัวอย่างนั้นๆ เลย ผลการทดลองที่ได้พบว่า ด้วยวิธีการง่ายๆ นี้ สามารถจำแนกตัวอย่างในกลุ่มปัญหามะเร็งเต้านม (Breast Cancer) ได้เป็นอย่างดี เมื่อเทียบกับขั้นตอนวิธีอื่นที่นำมาทดลองเปรียบเทียบ

#### งานวิจัยที่เกี่ยวข้อง

งานวิจัยอื่นที่เกี่ยวข้องกับงานวิจัยนี้เป็นงานวิจัยทางด้านการโปรแกรมตรรกะเชิงอุปนัยเป็นหลัก ซึ่งมีการวิจัยเป็น 2 แนวทาง คือ การนำไปประยุกต์ใช้กับงานด้านต่างๆ และการปรับปรุงเพื่อเพิ่มประสิทธิภาพของการโปรแกรมตรรกะเชิงอุปนัย ซึ่งงานวิจัยที่เกี่ยวข้องมีดังนี้

##### 1. Ivan Bratko และ Stephen H. Muggleton (1995)

เอกสารอ้างอิงนี้เป็นบทความที่กล่าวถึงวิธีการโปรแกรมตรรกะเชิงอุปนัยหรือโอแอลพี ข้อได้เปรียบของวิธีการโอแอลพีกับวิธีการเรียนรู้ของเครื่องแบบอื่น แนวคิดพื้นฐานของระบบโอแอลพี ความสำคัญของความรู้ภูมิหลัง และการนำไปประยุกต์ใช้ในงานด้านต่างๆ เช่น การวิเคราะห์ไฟไนต์เอลิเมนต์ (Finite Element) การวิเคราะห์ความสามารถก่อกลายพันธุ์ของโมเลกุล การจำแนกคุณภาพทางด้านชีววิทยาของน้ำในแม่น้ำ การสร้างแบบจำลองของโมเลกุลทางชีวภาพ (Biomolecular modeling) การปรับปรุงคุณภาพของข้อมูลในการออกแบบโปรแกรม ฯลฯ

##### 2. Bojan Dolsak และ Stephen Muggleton (1992)

ผู้วิจัยทั้งสองคนนี้ได้นำวิธีการโอแอลพีไปใช้ในงานด้านไฟไนต์เอลิเมนต์ จุดมุ่งหมายของการทดลองคือ การสร้างกฎเพื่อทำนายจำนวนเอลิเมนต์ที่เหมาะสมของโครงสร้างแต่ละแบบ เนื่องจากโดยปกติแล้วจะต้องมีการแทนโครงสร้างที่ต้องการวิเคราะห์ด้วยองค์ประกอบย่อยๆ ก่อน จากนั้นจึงวิเคราะห์ความเค้น (stress) ของโครงสร้างนั้นๆ Dolsak และ Muggleton ใช้ระบบโอแอลพี GOLEM ในการทดลองครั้งนั้น โดยใช้กลุ่มความรู้ภูมิหลังเป็นลักษณะต่างๆ ของเส้นเชื่อม ประกอบด้วยชนิดของเส้นเชื่อม เช่น important, not\_important, circuit, half\_circuit และ short\_for\_hole ฯลฯ เงื่อนไขขอบเขต (boundary conditions) เช่น free และ one\_side\_fixed ฯลฯ ชนิดของโหลด (load) เช่น not\_loaded, one\_side\_loaded และ cont\_loaded ฯลฯ ในการทดลองประกอบด้วยตัวอย่างบวก 75 ตัวอย่าง ตัวอย่างลบ 618 ตัวอย่าง และกลุ่มความรู้ภูมิหลัง 588 ข้อ จากนั้นทำการทดลอง 2 ครั้ง ในแต่ละครั้งทำการสุ่มเพื่อแบ่งตัวอย่างบวกมาใช้เป็นตัวอย่างที่ใช้ทดสอบ 10% ของตัวอย่างบวกทั้งหมด ผลการทดลองเฉลี่ยของทั้งสองครั้งได้เปอร์เซ็นต์ความถูกต้องเท่ากับ 79%

### 3. Johannes Furnkranz (1994)

นักวิจัยผู้นี้ได้สร้างระบบไอแอลพีชื่อ FOSSIL สามารถใช้กับปัญหาที่มีสัญญาณรบกวนได้ โดยใช้ค่าอีวิริสติกซึ่งวัดจากค่าสหสัมพันธ์ทางสถิติ (statistical correlation) ซึ่งเป็นวิธีการที่แตกต่างจากระบบโดยทั่วไปที่ใช้แนวคิดจากขั้นตอนวิธีการเรียนรู้ต้นไม้ตัดสินใจ (decision tree learning algorithm) มาจัดการกับสัญญาณรบกวนในเซตของตัวอย่างที่ใช้เรียนรู้ ทำการทดลองเปรียบเทียบกับระบบ FOIL [Quilan, 1990] โดยสุ่มเลือกตัวอย่างที่ใช้เรียนรู้ตามระดับสัญญาณรบกวน เปลี่ยนกลุ่มจากตัวอย่างบวกเป็นตัวอย่างลบ หรือเปลี่ยนจากตัวอย่างลบเป็นตัวอย่างบวก กลุ่มตัวอย่างที่ใช้ในการทดลอง คือ กลุ่มตัวอย่างการวิเคราะห์ตำแหน่งของตัวหมากรุกว่ามีการวางผิดตำแหน่งหรือไม่ (King-Rook-King illegal) เมื่อมีตัวหมากเหลืออยู่บนกระดาน 3 ตัว คือ ขุน (king) ฝ่ายขาว ขุนฝ่ายดำ และเรือ (rook) ฝ่ายขาว ผลการทดลองปรากฏว่า ระบบ FOSSIL ให้เปอร์เซ็นต์ความถูกต้องสูงกว่าระบบ FOIL ในระดับสัญญาณรบกวน 6 ระดับจากทั้งหมด 8 ระดับ

### 4. William W. Cohen (1995)

นักวิจัยผู้นี้ได้ทดลองโดยใช้ระบบการเรียนรู้ในลำดับที่หนึ่ง (first order learning system) ชื่อ FOIL ในงานด้านการจำแนกประเภทข้อความ (Text Categorization) เพื่อเปรียบเทียบวิธีการโปรแกรมตรรกะเชิงอุปนัย และวิธีการแบบตรรกศาสตร์ประพจน์ ในการทดลองมีการใช้ความรู้ภูมิหลังเกี่ยวกับตำแหน่งและความสัมพันธ์ของตำแหน่งของคำศัพท์ ผลการทดลองพบว่า ในการจำแนกข้อความจำนวน 51,991 ข้อความ ออกเป็น 10 หมวดหมู่ การเรียนรู้โดยใช้วิธีการโปรแกรมตรรกะเชิงอุปนัยให้ผลถูกต้องกว่าแบบตรรกศาสตร์ประพจน์ 2 หมวดหมู่ และ ทั้งสองแบบให้ผลการทดลองใกล้เคียงกัน 8 หมวดหมู่

### 5. Ashwin Srinivasan, Stephen H. Muggleton, R. D. King และ M. J. E. Stenberg (1996)

คณะนักวิจัยกลุ่มนี้ได้นำระบบไอแอลพี PROGOL มาใช้ในงานวิเคราะห์ความสามารถก่อกลายพันธู์ในโมเลกุลขนาดเล็ก โดยใช้ข้อมูลของอะตอม พันธะ และลักษณะต่างๆ ของโมเลกุลเป็นความรู้ภูมิหลัง เช่น anthracene, phenanthrene, ball3, ring\_size\_6, carbon\_5\_aromatic\_ring และ benzene ฯลฯ มีตัวอย่างบวกจำนวน 125 ตัวอย่าง ตัวอย่างลบ 63 ตัวอย่าง รวมตัวอย่างทั้งหมด 188 ตัวอย่าง ผลการทดลองได้เปอร์เซ็นต์ความถูกต้องเท่ากับ 80% จากตัวอย่างทั้งหมด และเมื่อทำการทดสอบโดยแบ่งตัวอย่างที่ใช้เรียนรู้จำนวน 30% หรือ 56 ตัวอย่าง เป็นกลุ่มตัวอย่างที่ใช้ทดสอบ ให้เปอร์เซ็นต์ความถูกต้องเท่ากับ 71%

### 6. Hendrik Blockeel และ Luc De Raedt (1997)

นักวิจัยทั้งสองนี้ได้พัฒนาระบบ TILDE (Top-down Induction of Logical Decision Tree) โดยใช้วิธีการสร้างต้นไม้ตัดสินใจเพื่อให้สามารถทำงานกับปัญหาที่อยู่ในรูปตรรกะลำดับที่หนึ่ง ปกติแล้ว



ขั้นตอนวิธีที่สนใจมักจะถูกนำไปใช้กับปัญหาที่มีลักษณะเป็นค่าคุณลักษณะ หรืออยู่ในรูปตรรกศาสตร์ ประพจน์มากกว่าปัญหาที่อยู่ในรูปแบบตรรกะลำดับที่หนึ่ง กลุ่มตัวอย่างที่ใช้ทดลองประกอบด้วยกลุ่มตัวอย่าง การวิเคราะห์ความสามารถที่กลายพันธุ์ ทำการทดลองเปรียบเทียบระบบ PROGOL, FOIL และ Indigo [Geibel และคณะ, 1996] ผลการทดลองปรากฏว่า TILDE ให้เปอร์เซ็นต์ความถูกต้องใกล้เคียงกับ PROGOL และ Indigo แต่สูงกว่า FOIL ในการวิเคราะห์ความสามารถที่กลายพันธุ์ การวิเคราะห์ไฟไนต์ เอลิเมนต์ ทำการทดลองเทียบกับ FOIL, Indigo, FFOIL [Quinlan, 1996] และ FORS [Karalic, 1995] TILDE ให้เปอร์เซ็นต์ความถูกต้องต่ำกว่า Indigo และ FFOIL แต่สูงกว่า FOIL และ FORS

#### 7. Mary E. Califf และ Raymond J. Mooney (1997)

นักวิจัยทั้งสองนี้ได้นำวิธีการโปรแกรมตรรกะเชิงอุปนัยมาประยุกต์ใช้กับงานด้านการดึงข้อมูลสำคัญ จากข้อความภาษาธรรมชาติ (natural language information extraction) ในการทดลองได้ใช้ตัวอย่างใน ขั้นตอนการเรียนรู้เป็นประกาศรับสมัครงานคู่กับข้อมูลสำคัญที่มีอยู่ในประกาศนั้น เช่น ลักษณะงาน เงินเดือน สถานที่ บริษัทนายจ้าง ฯลฯ ซึ่งผู้สอนเป็นผู้ป้อนข้อมูลเหล่านี้ให้ จากนั้นจึงทดสอบโดยให้ระบบ ดึงลักษณะต่างๆ เหล่านี้จากข้อความในประกาศ ผลการทดลองปรากฏว่า ได้ค่าความแม่นยำ (precision) เฉลี่ย 83.7 เปอร์เซ็นต์ และค่าเรียกคืน (recall) เฉลี่ย 53.1 เปอร์เซ็นต์

#### 8. Saso Dzeroski, Nico Jacobs, Martin Molina และ Carlos Moure (1998)

คณะนักวิจัยกลุ่มนี้ได้เรียนรู้เพื่อหาลักษณะของทางแยกซึ่งทำให้เกิดอุบัติเหตุทางรถยนต์ โดยใช้ ข้อมูลจากเครื่องตรวจจับสัญญาณซึ่งติดตั้งในบริเวณทางแยกต่างๆ โดยตัวอย่างที่ใช้ในการเรียนรู้ประกอบด้วยความเร็วของรถยนต์ ความหนาแน่นของรถยนต์ ลักษณะของถนน ทำการทดลองโดยเปรียบเทียบผล ระหว่างวิธีการโปรแกรมตรรกะเชิงอุปนัย 3 วิธี กับวิธีการเรียนรู้แบบตรรกศาสตร์ประพจน์ ผลการทดลอง ปรากฏว่า วิธีการโปรแกรมตรรกะเชิงอุปนัยทั้งสามวิธีให้เปอร์เซ็นต์ความถูกต้องสูงกว่าวิธีการเรียนรู้แบบ ตรรกศาสตร์ประพจน์

#### 9. Sam Roberts, Wimi Van Laer, Nico Jacobs, Stephen Muggleton และ Jeremy Broughton (1998)

คณะนักวิจัยกลุ่มนี้ได้ทดลองเปรียบเทียบวิธีการโปรแกรมตรรกะเชิงอุปนัย และการเรียนรู้แบบ ตรรกศาสตร์ประพจน์ เรียนรู้ข้อมูลตัวอย่างอุบัติเหตุทางรถยนต์ของวัยรุ่นชายที่อยู่ในรูปแบบตรรกศาสตร์ ประพจน์ จากข้อมูลอุบัติเหตุทางรถยนต์ที่เกิดขึ้นทั้งหมด ผลการทดลองปรากฏว่า เปอร์เซ็นต์ความถูกต้อง ของทุกวิธีการต่ำกว่าเปอร์เซ็นต์ความถูกต้องของวิธีการเลือกตามกลุ่มหลัก เพราะว่า จำนวนตัวอย่างบวกมี น้อยกว่าจำนวนตัวอย่างลบมาก จึงได้ทดลองโดยปรับจำนวนตัวอย่างที่ใช้ในการเรียนรู้ให้จำนวนตัวอย่างบวก เท่ากับตัวอย่างลบ ทำให้เปอร์เซ็นต์ความถูกต้องของทุกวิธีสูงกว่าเปอร์เซ็นต์ความถูกต้องของวิธีการเลือกโดย คลาสที่มีตัวอย่างมากกว่า และเปอร์เซ็นต์ความถูกต้องของวิธีการโปรแกรมตรรกะเชิงอุปนัยและวิธีการเรียนรู้ แบบตรรกศาสตร์ประพจน์มีค่าใกล้เคียงกัน

#### 10. Peter Flach and Nicolas Lachiche (1999)

นักวิจัยทั้งสองนี้ได้นำวิธีการจำแนกแบบเบย์ (Bayesian Classification) มาใช้กับปัญหาที่มีลักษณะเป็นตรรกะลำดับที่หนึ่ง ซึ่งจากเดิมวิธีการจำแนกแบบเบย์จะถูกนำไปใช้ในปัญหาที่มีลักษณะเป็นแบบตรรกศาสตร์ประพจน์ ทำการสร้างระบบ 1BC ขึ้นเพื่อให้สามารถใช้วิธีการของเบย์มาจำแนกตัวอย่างที่มีลักษณะเป็นตรรกะลำดับที่หนึ่ง โดยแบ่งลักษณะของเพรดิเคตออกเป็น 2 ประเภท คือ เพรดิเคตโครงสร้าง (structural predicate) และเพรดิเคตลักษณะ (property predicate) โดยให้ผู้ใช้กำหนดว่าเพรดิเคตใดจัดอยู่ในประเภทใด จากนั้นระบบจึงสร้างลักษณะสำคัญขึ้นจากเพรดิเคตทั้งสองประเภท แล้วจึงใช้วิธีการนาอิวเบย์ (Naive Bayes) เข้ามาใช้เรียนรู้และจำแนกตัวอย่าง ทำการทดลองกับกลุ่มปัญหาการวิเคราะห์ความสามารถก่อกลายพันธุ การวิเคราะห์ไฟไนต์เอลิเมนต์ และการวิเคราะห์ตำแหน่งของหมากรุก ผลการทดลองให้เปอร์เซ็นต์ความถูกต้อง 80.9%, 66.2% และ 88.3% ในปัญหาการวิเคราะห์ความสามารถก่อกลายพันธุ การวิเคราะห์ไฟไนต์เอลิเมนต์ และการวิเคราะห์ตำแหน่งหมากรุก ตามลำดับ