


บทที่ 3

วิธีการวิจัย

ในงานวิจัยนี้เสนอวิธีการใช้ตัวเรียนรู้ที่สามารถแลกเปลี่ยนความรู้กันได้หรือ (Knowledge Exchangeable ILP Learners: KEIL) ที่สามารถทำให้ตัวเรียนรู้แต่ละตัวเรียนรู้แยกกันด้วยเซตตัวอย่างเรียนรู้ที่มีการกระจายเดียวกัน และมีการกระจายเหมือนกับเซตตัวอย่างเรียนรู้ทั้งหมดโดยเมื่อตัวเรียนรู้แต่ละตัวเรียนรู้เพื่อสร้างสมมติฐานจนเสร็จเรียบร้อยแล้ว จะทำการเลือกสมมติฐานจากการเรียนรู้ของตัวเรียนรู้อื่นๆ มาเสริมในกลุ่มสมมติฐานของตัวเอง โดยมีวิธีการเรียนรู้ดังนี้

ภาพที่ 3.1

ตัวอย่างของสายโซ่ของสัญลักษณ์



คำนิยามที่ 1 สายโซ่ของสัญลักษณ์ (literal chain) คือ เซตของอนุประโยค (clause) ใดๆ ในส่วนตัว (body) ของกฎ ซึ่งสายโซ่สัญลักษณ์นี้จะประกอบด้วย สัญลักษณ์ $l_1, l_2, \dots, l_n$ โดยที่ตัวแปรซึ่งเป็นอินพุตทุกตัวของสัญลักษณ์ l_j จะต้องเคยปรากฏเป็นเอาต์พุตมาก่อนแล้วในสัญลักษณ์ l_i โดย $i < j$ และในสัญลักษณ์ l_n จะต้องไม่ปรากฏตัวแปรเอาต์พุตที่ปรากฏในสัญลักษณ์อื่นในส่วนตัวของกฎที่ไม่ถูกรวมไว้ก่อนแล้วในสายโซ่สัญลักษณ์

จากภาพที่ 3.1 แสดงให้เห็นรูปแบบของสายโซ่สัญญาณที่เชื่อมต่อกันประโยคทั้งหมดของกฎที่กำหนด ซึ่งเราสามารถแตกย่อยสายโซ่สัญญาณของกฎที่แสดงในภาพออกเป็นสายโซ่สัญญาณย่อยได้ดังนี้

free(A)
 neighbour_zx_r(A,B)
 neighbour_zx_r(A,B), free(B)
 neighbour_zx_r(A,B), usual(B)
 neighbour_zx_r(A,B), not_loaded(B)
 neighbour_zx_r(A,B), free(B), usual(B)
 neighbour_zx_r(A,B), free(B), not_loaded(B)
 neighbour_zx_r(A,B), free(B), usual(B), not_loaded(B)
 neighbour_zx_l(C,A)

ซึ่งจากสายโซ่สัญญาณย่อยที่ได้ ในบางอนุประโยคซึ่งมีการอ้างถึงตัวแปรอินพุตตั้งต้น ไม่จำเป็นต้องมีอนุประโยคอื่นมาเชื่อมต่อ เช่น free(A) neighbour_zx_r(A,B) และ neighbour_zx_l(C,A) ก็สามารถสร้างสายโซ่สัญญาณขึ้นได้ ในขณะที่บางอนุประโยคนั้น จำเป็นต้องมีการอ้างถึงอนุประโยคที่แสดงถึงความสัมพันธ์และเชื่อมต่อกับอนุประโยคที่มีตัวแปรอินพุตตั้งต้นหรือตัวแปรอินพุตก่อนหน้าจึงจะสามารถสร้างสายโซ่สัญญาณได้ เช่น free(B) จำเป็นต้องมีอนุประโยค neighbour_zx_r(A,B) มาเชื่อมต่อ จึงทำให้สายโซ่สัญญาณที่มีอนุประโยค free(B) จำเป็นต้องอยู่ในรูปแบบของ neighbour_zx_r(A,B), free(B)

แนวคิดของสายโซ่สัญญาณนั้นมีความใกล้เคียงกับแนวคิดของสายเปิด(open chain) และสายปิด(close chain) ใน (B. Kijirikul, S. Sinthupinyo and K. Chongkasemwongse, 2001)


เมื่อกำหนดคำนิยามของสายโซ่สัญญาณเรียบร้อยแล้ว เราจะสามารถอธิบายถึงขั้นตอนสำหรับการเรียนรู้ปัญหาที่มีความรู้ภูมิหลัง(Background knowledge) B ได้ดังนี้

- แบ่งเซตตัวอย่างเรียนรู้ E ซึ่งประกอบด้วยเซตตัวอย่างบวกและเซตตัวอย่างลบออกเป็นเซตตัวอย่างย่อย $E_1, E_2, \dots, E_n$ โดยการสุ่มอย่างง่าย
- ใช้ตัวอย่างเรียนรู้ $L_1, L_2, \dots, L_n$ เรียนรู้เพื่อสร้างสมมติฐาน $H_1, H_2, \dots, H_n$ จากเซตตัวอย่าง $E_1, E_2, \dots, E_n$ ตามลำดับ โดยสมมติฐาน $H_i \wedge B \models E_i^+$ และ $H_i \wedge B \not\models E_i^-$

- เลือกสมมติฐาน H_i ที่ให้ความถูกต้องสูงสุดบนเซตตัวอย่าง E_i มาเป็นสมมติฐานหลัก จากนั้นทำการปรับสมมติฐาน H_i โดย
- สำหรับทุกตัวอย่างบวก e^+ ทุกตัวอย่างในเซต E_i ที่ไม่ครอบคลุมด้วยสมมติฐาน H_i
 - ให้รวมสมมติฐาน h ใดๆ จาก H_j ซึ่ง $k \neq j$ และ $h \wedge B \models e^+$ ตัวนั้นเข้าไปใน H_i โดยถ้า $h \wedge B \models E_k^-$ ซึ่ง $k \neq j$ จะต้องปรับ h ให้เฉพาะเจาะจงขึ้น โดยการนำสายใช้สัญญาณหนึ่งอันหรือมากกว่าจาก H_k มารวมเข้าไปใน h เป็น h' แล้วทำให้ความถูกต้องของ h' บนเซตตัวอย่างเรียนรู้ E สูงขึ้นกว่าค่าความถูกต้องของ h บนเซตตัวอย่างเรียนรู้ E
- สำหรับทุกตัวอย่างบวก e^+ ทุกตัวอย่างในเซต E_j โดยที่ $i \neq j$ ที่ไม่ครอบคลุมด้วยสมมติฐาน H_i
 - ให้รวมสมมติฐาน h ใดๆ จาก H_j ซึ่ง $h \wedge B \models e^+$ ตัวนั้น เข้าไว้ใน H_i โดยถ้า $h \wedge B \models E_k^-$ ซึ่ง $k \neq j$ จะต้องปรับ h ให้เฉพาะเจาะจงขึ้น โดยการนำสายใช้สัญญาณหนึ่งอันหรือมากกว่าจาก H_k มารวมเข้าไปใน h เป็น h' แล้ว ทำให้ความถูกต้องของ h' บนเซตตัวอย่างเรียนรู้ E สูงขึ้นกว่าความถูกต้องของ h บนเซตตัวอย่างเรียนรู้ E
- นำเซตของสมมติฐาน H_i ไปใช้จำแนกตัวอย่างทดสอบ

ภาพที่ 3.2

รูปแสดงวิธีการแลกเปลี่ยนความรู้โดยการปรับปรุงกฎด้วยการเพิ่มสายโซ่สัญญา



วิธีการในการแลกเปลี่ยนความรู้โดยการนำสายโซ่สัญญาจากกฎที่ได้ตัวเรียนรู้อื่นๆ จากภาพสมมติให้กฎตั้งต้นเป็นกฎที่เราต้องการจะทำการปรับปรุงให้มีความเฉพาะเจาะจงมากขึ้นซึ่งสามารถสร้างสายโซ่สัญญาได้ตามภาพที่ 3.2 โดยกฎตั้งต้นนั้นสามารถแตกออกเป็นสายโซ่สัญญาย่อยได้ดังนี้

```

not_loaded(A)
short(A)
eighbour_xy_r(A,B)
neighbour_xy_r(A,B), two_side_fixed(B)
neighbour_xy_l(C,A)
neighbour_xy_l(C,A), fixed(C)

```

และให้กฎที่ได้จากตัวเรียนรู้อื่นเป็นกฎที่จะใช้ในการเปรียบเทียบและเลือกหยิบสายโซ่สัญญาณ
เพื่อใช้ในการปรับปรุงกฎตั้งต้น ซึ่งจะมีสายโซ่สัญญาณดังนี้

```

short(A)
fixed(A)
neighbour_xy_r(A,B), neighbour_xy_l(B,A)
neighbour_xy_r(A,B), neighbour_xy_l(B,A), neighbour_yl_r(B,D),usual(D)
neighbour_xy_r(A,B), neighbour_yl_r(B,D)
neighbour_xy_r(A,B), neighbour_yl_r(B,D),usual(D)

```

จากสายโซ่สัญญาณของกฎทั้ง 2 จะเห็นได้ว่ามีสายโซ่สัญญาณที่ปรากฏอยู่ในกฎทั้ง 2 คือ
short(A) และ neighbour_xy_r(A,B) ดังแสดงในภาพที่ 3.2 ในส่วนที่เป็นเส้นหนา ซึ่งแสดงให้เห็น
ว่ากฎทั้ง 2 มีส่วนที่มีความคล้ายคลึงกันอยู่และน่าจะสมารถทำการเพิ่มสายโซ่สัญญาณได้ที่ไม่
ปรากฏอยู่ในกฎตั้งต้นได้จากจุดนี้ ซึ่งจะทำให้กฎที่ได้มีความเฉพาะเจาะจงขึ้นได้เป็น 2 กฎคือ
กฎ A

```

mesh(A) :- not_loaded(A), short(A), neighbour_xy_r(A,B), two_side_fixed(B)
neighbour_xy_l(C,A), fixed(C), fixed(A).

```

และ กฎ B

```

mesh(A) :- not_loaded(A), short(A), neighbour_xy_r(A,B), two_side_fixed(B)
neighbour_xy_l(C,A), fixed(C), neighbour_yl_r(B,D),usual(D).


```

จากนั้น จึงนำกฎ A และ B ที่สร้างได้ไปทำการทดสอบกับเซตตัวอย่างบวกและเซตตัวอย่างลบของ
ตัวเรียนรู้อื่น ซึ่งก็จะได้ค่าความถูกต้องและการครอบคลุมตัวอย่างของแต่ละกฎออกมา จากนั้น
จะทำการเปรียบเทียบค่าความถูกต้องและการครอบคลุมตัวอย่างของกฎตั้งต้น กฎ A และ กฎ B ซึ่ง

กฎที่ให้ค่าความถูกต้องและการครอบคลุมตัวอย่างได้สูงสุดจะถูกเลือก ซึ่งในที่นี้สมมติให้กฎ B มีค่าความถูกต้องและการครอบคลุมตัวอย่างสูงสุด ก็จะนำกฎ B มาแทนกฎตั้งต้น ซึ่งในภาพที่ 3.2 แสดงให้เห็นกฎที่ทำการเพิ่มสายโซ่สัจพจน์ โดยสายโซ่สัจพจน์ที่ถูกนำมาเพิ่มจะแสดงให้เห็นให้เป็นเส้นประ

ภาพที่ 3.3

รูปแสดงวิธีการทำงานของวิธีการใช้ตัวเรียนรู้ที่สามารถแลกเปลี่ยนความรู้กันได้



จากภาพที่ 3.3 แสดงวิธีการที่ได้นำเสนอในงานวิจัยนี้ ซึ่งจะขออธิบายเป็นขั้นตอนดังต่อไปนี้

1. การทำงานของระบบจะถูกควบคุมโดยผู้จัดการ (manager) ซึ่งจะทำหน้าที่แบ่งเซตตัวอย่างทั้งตัวอย่างบวกและตัวอย่างลบสำหรับการเรียนรู้ให้กับตัวแทน (agent) จำนวน 3 ตัว และแจกจ่ายเซตตัวอย่างย่อยซึ่งตัวแทนแต่ละตัวจะได้เซตตัวอย่างที่มีข้อมูลตัวอย่างไม่ซ้ำกับตัวแทนตัวอื่นและความรู้ภูมิหลังให้กับตัวแทนแต่ละตัวเพื่อนำไปทำการเรียนรู้
2. ตัวแทนแต่ละตัวก็จะทำการเรียนรู้โดยวิธีการโปรแกรมตรรกะเชิงอุปนัยด้วยเครื่องมือในการสร้างกฎด้วยวิธีการโปรแกรมตรรกะเชิงอุปนัย Aleph และหลังจากการเรียนรู้ด้วยตัวแทนแต่ละตัวเสร็จสิ้น เซตของกฎและค่าความถูกต้องจากตัวแทนแต่ละตัวจะถูกส่งกับไปยังผู้จัดการ
3. ผู้จัดการจะทำการคัดเลือกเซตของกฎที่มีค่าความถูกต้องสูงสุดในเซตตัวอย่างย่อยของตัวเองซึ่งในภาพที่ 3.3 สมมติให้เซตของกฎ R1 จากตัวแทนตัวที่ 1 เป็นเซตของกฎที่ให้ค่าความถูกต้องในเซตตัวอย่างย่อยของตัวเองสูงที่สุด
4. ผู้จัดการจะทำการปรับปรุงเซตของกฎ R1 โดยหากกฎที่สามารถเพิ่มค่าความถูกต้องให้กับเซตของกฎ R1 เมื่อทำการทดสอบกับเซตตัวอย่างของตัวแทนตัวที่ 1 โดยการนำกฎที่ได้จากการเรียนรู้จากตัวแทนตัวที่ 2 และ 3 เข้ามาเพิ่มในเซตของกฎ R1 โดยกฎที่จะนำมาเพิ่มนั้นจะต้องทำให้เซตของกฎ R1 สามารถครอบคลุมตัวอย่างบวกในเซตตัวอย่างของตัวแทนตัวที่ 1 ได้เพิ่มขึ้นหรือสามารถเพิ่มค่าความถูกต้องให้กับเซตของกฎ R1 ได้ อย่างไรก็ตามกฎที่จะนำมาเพิ่มนั้นมีการครอบคลุมตัวอย่างลบในเซตตัวอย่างย่อยของตัวแทนตัวที่ 1 กฎที่จะนำมาเพิ่มนี้จำเป็นต้องถูกปรับปรุงโดยการนำสายโซ่สัญญาณจากกฎใดๆ ในเซตของกฎ R1 มาเพิ่ม(ซึ่งวิธีการปรับปรุงกฎโดยการเพิ่มสายโซ่สัญญาณนี้ได้แสดงให้เห็นในภาพที่ 3.2) และทำการทดสอบกับเซตตัวอย่างย่อยของตัวแทนตัวที่ 1 ซึ่งหลังจากทำการเพิ่มกฎที่ทำการปรับปรุงแล้วจากตัวแทนตัวที่ 2 และ 3 แล้ว ก็จะได้เซตของกฎ R1'
5. ต่อจากนั้นผู้จัดการจะนำเซตของกฎ R1' ไปทดสอบกับเซตตัวอย่างบวกและเซตตัวอย่างลบของตัวแทนตัวที่ 2 และ 3 และทำการปรับปรุงความถูกต้องของเซต R1' บนเซตตัวอย่างย่อยของตัวแทนตัวที่ 2 และ 3 อยู่ 2 แบบ คือ การตัดกฎและการปรับปรุงกฎโดยการเพิ่มสายโซ่สัญญาณ โดยการตัดกฎออกนั้นจะตรวจสอบค่าความถูกต้องของกฎในเซต R1' ซึ่งถ้ามีกฎใดที่ครอบคลุมตัวอย่างบวกได้น้อยกว่าครอบคลุมตัวอย่างลบในเซตตัวอย่างย่อยของตัวแทนตัวที่ 2 และ 3 และนำไปทำการปรับปรุงแล้วไม่สามารถเพิ่มค่าความถูกต้องให้กับกฎนั้นได้ กฎข้อนั้นจะถูกตัดออกจากเซตของกฎ R1' ส่วนในการปรับปรุงกฎโดยการเพิ่มสายโซ่สัญญาณนั้น จะทำการปรับปรุงกฎที่ครอบคลุมตัวอย่างลบในเซตตัวอย่างย่อยของ

ตัวแทนตัวที่ 2 และ 3 โดยการเพิ่มสายโซ่สัญญาณที่ได้จากเซตของกฎ R2 และ R3 ซึ่งเป็นเซตของกฎที่ได้จากการเรียนรู้ของตัวแทนตัวที่ 2 และ 3 ตามลำดับ โดยในขั้นตอนนี้การปรับปรุงกฎหนึ่งกฎ อาจเกิดกฎใหม่ที่มาจากการเพิ่มสายโซ่สัญญาณที่แตกต่างกันได้หลายกฎ ในที่นี้จะทำการเลือกกฎใหม่ที่ทำให้ค่าความถูกต้องสูงสุดบนเซตตัวอย่างของตัวแทนที่ 2 และ 3 มาเปรียบเทียบกับเซตของกฎเดิม ซึ่งถ้ากฎใหม่สามารถให้ค่าความถูกต้องสูงกว่ากฎเดิมบนเซตตัวอย่างของตัวแทนที่ 2 และ 3 กฎนั้นก็จะถูกนำมาแทนที่กฎเดิม


6. จากข้อ 5 จะเห็นได้ว่าเซตของกฎ R1' จะมีความเฉพาะเจาะจงสูงขึ้นบนเซตตัวอย่างของตัวแทนที่ 2 และ 3 ซึ่งเพื่อให้เซตตัวอย่าง R1' สามารถครอบคลุมตัวอย่างบวกบนเซตตัวอย่างของตัวแทนที่ 2 และ 3 ได้มากขึ้น เราจะทำกรเพิ่มกฎที่ได้จากเซตของกฎ R2 และ R3 ซึ่งเป็นเซตของกฎที่ได้จากการเรียนรู้ของตัวแทนตัวที่ 2 และ 3 ตามลำดับ เข้าไป โดยที่กฎที่จะนำมาเพิ่มให้กับเซตของกฎ R1' นั้น จะต้องทำให้เซตของกฎ R1' มีค่าความถูกต้องบนเซตตัวอย่างของตัวแทนที่ 2 และ 3 สูงขึ้นเท่านั้นและถ้ากฎที่นำมาเพิ่มนั้นไปครอบคลุมตัวอย่างลบบนเซตตัวอย่างของตัวแทนที่ 2 และ 3 กฎนั้นก็ต้องถูกปรับปรุงเพื่อให้กฎที่จะนำไปเพิ่มครอบคลุมตัวอย่างลบน้อยที่สุด ยกตัวอย่างเช่น กฎ A ซึ่งจะถูกนำมาเพิ่มในเซตของกฎ R1' นั้นเป็นกฎที่อยู่ในเซตของกฎ R2 ที่เมื่อนำมาทดสอบกับเซตตัวอย่างของตัวแทนที่ 2 และ 3 แล้วพบว่า ครอบคลุมตัวอย่างลบบ่อย เราจะทำกรปรับปรุงกฎนี้โดยการนำสายโซ่สัญญาณที่ได้จากเซตของกฎ R3 มาทำการเพิ่มเติม และนำไปทดสอบกับเซตตัวอย่างเดิม ซึ่งถ้ากฎ A ที่ถูกทำการปรับปรุงแล้วนั้น สามารถเพิ่มเข้าไปในเซตตัวอย่าง R1' แล้วทำให้ค่าความถูกต้องของเซตของกฎ R1' เพิ่มขึ้นได้ กฎ A ก็จะถูกเพิ่มเข้าไปใน R1' เป็นต้น

เมื่อทำการเพิ่มกฎที่ได้จากเซตของกฎ R2 และ R3 จนครบถ้วนหรือไม่สามารถเพิ่มค่าความถูกต้องให้กับเซตของกฎ R1' ได้อีก ก็จะกำหนดให้ R1' เป็นผลลัพธ์ของการทำงาน

ซึ่งจากวิธีการทำงานข้างต้น ผู้จัดการจะทำการแบ่งตัวอย่างสำหรับการใช้ในการเรียนรู้เป็น 3 ส่วน นั้นทำให้ตัวเรียนรู้แต่ละตัวมีโอกาสในการเรียนรู้กับเซตข้อมูลตัวอย่างเพียงบางส่วนหรือประมาณ 33 เปอร์เซ็นต์ของเซตตัวอย่างทั้งหมด ทำให้ระยะเวลาในการเรียนรู้เพื่อทำการสร้างกฎนั้นลดลง แต่จากภาพที่ 3.4 ซึ่งแสดงค่าความถูกต้องของการเรียนรู้กับเซตข้อมูลตัวอย่างการวิเคราะห์ความสามารถก่อกลายพันธุ์ของโมเลกุล (Mutagenesis) ที่ใช้ข้อมูลตัวอย่างในการเรียนรู้ในจำนวนเป็นเปอร์เซ็นต์ที่แตกต่างกัน ให้ค่าความถูกต้องที่ลดลงเมื่อเปรียบเทียบกับกรเรียนรู้กับเซตข้อมูลทั้งหมด

ภาพที่ 3.4

รูปแสดงค่าความถูกต้องของเซตข้อมูลเมื่อทำการเรียนรู้ด้วยเซตข้อมูลเมื่อทำการเรียนรู้โดยการแบ่งเซตข้อมูลตัวอย่างตามเปอร์เซ็นต์



แต่ด้วยวิธีการที่นำเสนอในงานวิจัย สามารถทำให้การเรียนรู้กับเซตข้อมูลตัวอย่างเพียงบางส่วนนั้นสามารถให้ค่าความถูกต้องได้ใกล้เคียงกับการเรียนรู้กับข้อมูลตัวอย่างทั้งหมด ดังที่จะแสดงต่อไปในส่วนของผลการทดลอง