

บทที่ 4

ผลการทดลอง

การทดลองนี้ใช้เซตตัวอย่างของ การวิเคราะห์ความสามารถก่อกลายพันธุ์ของโมเลกุล (Mutagenesis) ข้อมูลการก่อมะเร็ง (Carcinogenesis) และการหาจำนวนองค์ประกอบจำกัดของโครงข่าย (Finite-Element Mesh) แต่เนื่องจากปัญหานี้เป็นปัญหาแบบหลายกลุ่ม ซึ่งก่อให้เกิดความซับซ้อนเนื่องจากปัจจัยต่างๆ ของการจำแนกตัวอย่างออกเป็นหลายกลุ่ม ในการทดลองนี้จึงได้ทอนปัญหานี้ให้กลายเป็นปัญหาเพียงสองกลุ่ม คือ การจำแนกตัวอย่างออกเป็นคลาส 1 จากคลาสอื่นๆ (Mesh1) โดยที่ตัวอย่างที่เป็นคลาส 1 จะเป็นตัวอย่างบวกและตัวอย่างอื่นที่ไม่ใช่คลาส 1 จะเป็นตัวอย่างลบ และการจำแนกตัวอย่างออกเป็นคลาส 2 จากคลาสอื่นๆ (Mesh2) ซึ่งตัวอย่างที่เป็นคลาส 2 ทั้งหมดจะเป็นตัวอย่างบวกและตัวอย่างอื่นที่ไม่ใช่คลาส 2 จะเป็นตัวอย่างลบ จำนวนตัวอย่างบวกและจำนวนตัวอย่างลบได้แสดงให้เห็นในตารางที่ 4.1

ตารางที่ 4.1

แสดงจำนวนตัวอย่างในเซตเรียนรู้ที่ใช้ในงานวิจัย

เซตตัวอย่าง	จำนวนตัวอย่างบวก	จำนวนตัวอย่างลบ
Mesh1	123	520
Mesh2	110	533
Mutagenesis	125	63
Carcinogenesis	162	136

การทำงานจะใช้ตัวเรียนรู้จำนวน 3 ตัว ใช้ Aleph (A. Srinivasan, 2001) เครื่องมือในการสร้างกฎด้วยวิธีการโปรแกรมตรรกะเชิงอุปนัย สำหรับการเรียนรู้บนเซตตัวอย่างเรียนรู้ และใช้การทดสอบแบบไขว้ข้ามห้ากลุ่ม (5-fold cross validation) ผลการทดลองพร้อมนัยสำคัญทางสถิติโดยใช้วิธีทดสอบแบบที่จับคู่ทางเดียว และส่วนเบี่ยงเบนมาตรฐานของความถูกต้องของแต่ละวิธีแสดงไว้ในตารางที่ 4.2

ตารางที่ 4.2

แสดงผลการทดลองเปรียบเทียบกับการเรียนรู้ที่นำเสนอ (KEIL) การรวมกฎอย่างง่ายโดยนำกฎที่ได้จากตัวเรียนรู้ทั้งหมดมายูเนียนกัน (All Rules: AR) การใช้ตัวเรียนรู้ที่ให้ผลการเรียนรู้สูงสุดบนเซตตัวอย่างเรียนรู้มาจำแนกตัวอย่าง (Best Learner: BL) และการเรียนรู้ด้วยตัวอย่างทั้งหมดโดยใช้ Aleph โดย * ** *** และ **** แสดงการมีระดับนัยสำคัญที่ต่ำกว่า .10 ที่ระดับ .10 ที่ระดับ .05 และที่ระดับ .01 ตามลำดับ

เซตตัวอย่าง	วิธีการนี้	AR	BL	Aleph
Mesh1	90.36±1.78	84.92±2.44****	87.10±2.34****	91.91±2.32**
Mesh2	84.29±2.30	79.32±4.02****	81.03±2.09**	85.38±2.75*
Mutagenesis	89.36±4.25	81.38±1.11**	82.50±5.64**	86.16±3.54***
Carcinogenesis	59.02±5.36	55.99±5.78**	49.66±2.51****	56.76±2.78*

จากผลการทดลองพบว่าวิธีการที่นำเสนอในงานวิจัยสามารถให้กฎที่มีค่าความถูกต้องสูงกว่าวิธีการเรียนรู้แบบการรวมกฎอย่างง่ายโดยนำกฎที่ได้จากตัวเรียนรู้ทั้งหมดมายูเนียนกัน (All Rules: AR) และการใช้ตัวเรียนรู้ที่ให้ผลการเรียนรู้สูงสุดบนเซตตัวอย่างเรียนรู้มาจำแนกตัวอย่าง (Best Learner: BL) ในทุกเซตตัวอย่างเรียนรู้ และเมื่อเปรียบเทียบวิธีการที่นำเสนอกับการเรียนรู้โดยใช้ตัวอย่างทั้งหมดจากเซตตัวอย่างเรียนรู้พบว่า การเรียนรู้บนเซตตัวอย่างเรียนรู้ทั้งหมดมีเปอร์เซ็นต์ความถูกต้อง 91.91±2.32 ซึ่งให้ผลที่ดีกว่าอย่างมีนัยสำคัญทางสถิติที่ระดับ 0.05 บน Mesh1 และมีเปอร์เซ็นต์ความถูกต้อง 85.38±2.75 ซึ่งให้ผลที่ดีกว่าอย่างมีนัยสำคัญทางสถิติที่ระดับต่ำกว่า 0.10 บน Mesh2 อย่างไรก็ตามวิธีการที่นำเสนอก็สามารถให้ผลลัพธ์ได้ดีกว่าในเซตตัวอย่างเรียนรู้ Mutagenesis และ Carcinogenesis โดยการเรียนรู้กับเซตตัวอย่าง Mutagenesis นั้น วิธีการที่นำเสนอสามารถให้เปอร์เซ็นต์ความถูกต้องที่ 89.36±4.25 ซึ่งให้ผลที่ดีกว่าอย่างมีนัยสำคัญทางสถิติที่ระดับ 0.05 และ นำเสนอสามารถให้เปอร์เซ็นต์ความถูกต้องที่ 59.02±5.36 ซึ่งให้ผลที่ดีกว่าอย่างมีนัยสำคัญทางสถิติที่ระดับต่ำกว่า 0.10 บนเซตตัวอย่างเรียนรู้ Carcinogenesis

เหตุผลที่วิธีการที่นำเสนอมีค่าความถูกต้องที่สูงกว่าเมื่อเปรียบเทียบวิธีการ All rules เนื่องมาจากเซตของกฎของวิธีการ All rules นั้นมีการวางนัยโดยทั่วไป (general) สูงกว่าเซตของ

กฎที่ได้จากวิธีการที่นำเสนอ เนื่องมาจากวิธีการ All rules มีเป็นการยูเนียนกฎที่ได้จากตัวเรียนรู้หลายๆ ตัวเข้าด้วยกัน ซึ่งตัวเรียนรู้แต่ละตัวก็ทำการเรียนรู้กับข้อมูลตัวอย่างเพียงบางส่วน กฎที่ได้บางตัวในเซตตัวอย่างจึงมีการวางนัยโดยทั่วไปสูง ทำให้กฎเหล่านั้นไม่สามารถตัดตัวอย่างลบที่ไม่เคยทำการเรียนรู้ออกได้ หรือ กฎบางตัวมีความเฉพาะเจาะจงสูงกับเซตตัวอย่างที่ทำการเรียนรู้มากเกินไป ทำให้ไม่สามารถครอบคลุมตัวอย่างบวกที่ไม่ได้ทำการเรียนรู้ได้ และเนื่องจากการเรียนรู้กับเซตตัวอย่างเพียงบางส่วน กฎที่ได้อาจจะไม่สามารถตัดตัวอย่างลบได้ ทำให้ค่าความถูกต้องของกฎที่ลดลง เพื่อความเข้าใจจะขอยกตัวอย่างดังนี้

ตัวอย่างที่ 4.1 แสดงการปรับปรุงกฎที่มีการวางนัยโดยทั่วไปสูง

active(A) :- ar_halide(A, B), has_property(A, cytogen_sce, p), atm(A, C, c, 10, D),
sybond(A, C, E, 1), has_property(A, salmonella, n).

กฎข้างต้นได้จากการเรียนรู้โดยตัวเรียนรู้ตัวหนึ่งในการทดลองกับเซตข้อมูลการก่อมะเร็ง ซึ่งกฎข้อนี้มีอยู่ในเซตของกฎด้วยวิธีการ All rules และ เป็นกฎที่ผ่านการปรับปรุงและอยู่ในเซตของกฎที่ใช้วิธีการที่นำเสนอด้วย ซึ่งกฎข้อนี้เมื่อนำไปทำการทดสอบกับกับเซตตัวอย่างสำหรับการใช้ในการทดสอบ พบว่ากฎนี้ครอบคลุมตัวอย่างบวก 2 ตัวและครอบคลุมตัวอย่างลบ 3 ตัว ด้วยวิธีการที่นำเสนอ กฎข้อนี้จะถูกนำไปทดสอบกับเซตตัวอย่างย่อยสำหรับตัวเรียนรู้อื่น ซึ่งครอบคลุมตัวอย่างบวก 8 ตัวและครอบคลุมตัวอย่างลบ 5 ตัวในเซตตัวอย่างย่อยของตัวเรียนรู้ตัวอื่น เราจำเป็นต้องทำการปรับปรุงกฎข้อนี้ก่อนที่จะถูกนำไปรวมในเซตของกฎที่เป็นคำตอบโดยการเพิ่มสายใช้สัญลักษณ์ให้กับกฎ ซึ่งเมื่อทำการทดสอบและสร้างกฎใหม่หลายๆ กฎพบว่าการเพิ่มสายใช้สัญลักษณ์ alkyl_halide(A, B) ให้กับกฎให้ค่าความถูกต้องได้ดีที่สุด

active(A) :- ar_halide(A, B), has_property(A, cytogen_sce, p), atm(A, C, c, 10, D),
sybond(A, C, E, 1), has_property(A, salmonella, n), alkyl_halide(A,
B).

หลังจากทำการปรับปรุง เมื่อนำกฎที่ได้ไปทำการทดสอบกับเซตตัวอย่างย่อยที่ใช้ในการเรียนรู้กับตัวเรียนรู้อื่น พบว่ากฎข้อนี้ครอบคลุมตัวอย่างบวกได้ 6 ตัวและครอบคลุมตัวอย่างลบเหลือ 1 ตัว ซึ่งดีกว่ากฎเดิม และเมื่อนำไปทดสอบกับเซตตัวอย่างสำหรับการทดสอบ พบว่ากฎที่ได้รับการ

ปรับปรุงนี้ครอบคลุมตัวอย่างบวก 1 ตัวและครอบคลุมตัวอย่างลบ 1 ตัว ซึ่งเมื่อเทียบกับกฎเดิมแล้ว กฎใหม่ครอบคลุมตัวอย่างบวกลดลง 1 ตัวและครอบคลุมตัวอย่างลบลดลง 2 ตัวในเซตตัวอย่างสำหรับการทดสอบกฎ นั่นคือ กฎใหม่ที่มีการปรับปรุงโดยการเพิ่มสายโซ่สัญญาณสามารถให้ค่าความถูกต้องได้ดีกว่าเดิม

ตัวอย่างที่ 4.2 แสดงการตัดกฎที่ทำให้ค่าความถูกต้องของเซตของกฎลดลง

active(A) :- atm(A, B, c, 10, C), symbond(A, B, D, 1), has_property(A, mouse_lymph, p), gteq(C, -0.11), has_property(A, cytogen_sce, n).

กฎในตัวอย่างที่ 2 นี้เมื่อนำไปทดสอบกับเซตตัวอย่างสำหรับการทดสอบกฎ จะพบว่า กฎข้อนี้ไม่ครอบคลุมตัวอย่างบวกแต่ครอบคลุมตัวอย่างลบอยู่ 2 ตัว ซึ่งด้วยวิธีการรวมกฎแบบ All rules นั้น กฎข้อนี้จะไม่ถูกตัดออกไปจากเซตของกฎที่ แต่ด้วยวิธีการที่นำเสนอซึ่งกฎข้อนี้เมื่อนำมาทดสอบกับเซตตัวอย่างย่อยของตัวเรียนรู้จะพบว่า กฎข้อนี้ครอบคลุมตัวอย่างบวก 3 ตัว และครอบคลุมตัวอย่างลบ 7 ตัว ซึ่งด้วยวิธีการที่นำเสนอจะไม่ตัดกฎนี้ออกทันที แต่จะนำไปทำการปรับปรุงกฎโดยการเพิ่มสายโซ่สัญญาณก่อน แต่อย่างไรก็ดีหลังจากทำการปรับปรุงแล้ว กฎใหม่ที่ได้ไม่ทำให้ค่าความถูกต้องของกฎสูงขึ้น กฎข้อนี้จึงถูกตัดออก นั่นทำให้เซตของกฎที่เป็นคำตอบเมื่อนำไปทดสอบกับเซตตัวอย่างสำหรับการทดสอบกฎแล้ว สามารถลดการครอบคลุมตัวอย่างลบออกไปได้ 2 ตัว

จะเห็นได้ว่ากฎที่ผ่านการปรับปรุงแล้วจะครอบคลุมตัวอย่างลบลดลงมากกว่ากฎเดิมที่มีอยู่ในเซตของกฎที่ใช้วิธีการ All rules และด้วยการทำการปรับปรุงกับกฎทุกกฎจะทำให้เซตของกฎที่ได้จากวิธีการที่นำเสนอ จะทำให้กฎทุกกฎในเซตมีความเฉพาะเจาะจงสูงขึ้น ในส่วนของตัวอย่างบวกซึ่งลดลงเมื่อทำการปรับปรุงกฎนั้น วิธีการที่นำเสนอมีการนำกฎจากตัวเรียนรู้อื่น มาเพิ่มเข้าในเซตของกฎ โดยที่กฎที่นำมาเพิ่มก็ผ่านการปรับปรุงโดยการเพิ่มสายโซ่สัญญาณด้วย ทำให้เซตของกฎที่ได้จากวิธีการที่นำเสนอ สามารถครอบคลุมตัวอย่างบวกได้ใกล้เคียงกับวิธีการ All rules แต่สามารถตัดการครอบคลุมในตัวอย่างลบออกได้มากกว่า จึงให้ค่าความถูกต้องได้ดีกว่า หรือมีการวางนัยโดยทั่วไปน้อยกว่าเซตของกฎจากวิธีการ All rules นั่นเอง

ส่วนเหตุผลที่วิธีการนำเสนอที่ดีกว่าวิธีการ Best Learner นั้นเนื่องมาจากวิธีการ Best Learner นั้นทำการเรียนรู้กับเซตข้อมูลเพียงบางส่วน ดังที่แสดงให้เห็นในภาพที่ 3.4 นั้น การเรียนรู้กับเซตข้อมูลเพียงบางส่วนทำให้ค่าความถูกต้องที่ได้ลดลง เซตของกฎที่ได้จึงทำให้ไม่สามารถครอบคลุมเซตตัวอย่างทั้งหมดได้ ในขณะที่วิธีการที่นำเสนอนอกจากจะทำการปรับปรุงกฎที่ได้

จากตัวเรียนรู้ที่ดีที่สุดที่ในเซตตัวอย่างของตัวเองแล้ว ยังทำการเพิ่มกฎที่ได้จากตัวเรียนรู้อื่นที่ได้รับการปรับปรุงให้ไม่มีการวางนัยโดยทั่วไปเข้ามาเพิ่มในเซตของกฎที่เป็นคำตอบด้วย นั่นทำให้เซตของกฎที่ใช้วิธีการที่นำเสนอสามารถครอบคลุมตัวอย่างบวกได้มากกว่าเซตของกฎที่ได้จากวิธีการ Best Learner ในขณะที่ยังคงพยายามที่จะทำให้เซตของกฎไม่ครอบคลุมตัวอย่างลบเพิ่มขึ้นด้วย จึงทำให้เซตของกฎที่ได้จากวิธีการที่นำเสนอมีความถูกต้องสูงกว่ำนั่นเอง

ตัวอย่างที่ 4.3 แสดงการปรับปรุงเซตของกฎด้วยวิธีการทำนำเสนอเปรียบเทียบกับการใช้เซตของกฎที่ได้จากวิธีการ Best Learner

จากการเรียนรู้โดยใช้ตัวเรียนรู้กับเซตข้อมูลการวิเคราะห์ความสามารถก่อกลายพันธุ์ของโมเลกุล (Mutagenesis) ด้วยวิธีการ Best Learner จะได้เซตของกฎดังที่มีกฎดังต่อไปนี้

active(A) :- lumo(A, B), bond(A, C, D, 7), atm(A, C, c, 22, E), atm(A, D, c, 22, E),
ring_size_6(A, F), lteq(E, -0.12), lteq(B, -1.87).

active(A) :- lumo(A, B), nitro(A, C), logp(A, D), gteq(D, 1.46), lteq(B, -2.227).

active(A) :- atm(A, B, c, 27, C), benzene(A, D), atm(A, E, c, 22, F), ring_size_6(A, D),
nitro(A, G), bond(A, E, B, 7).

active(A) :- benzene(A, B), atm(A, C, c, 22, D), atm(A, E, c, 22, D), ring_size_6(A, B),
ring_size_6(A, F), ring_size_6(A, G), carbon_6_ring(A, G).

active(A) :- atm(A, B, c, 22, C), benzene(A, D), atm(A, E, c, 22, C), ring_size_6(A, F),
lumo(A, G), lteq(G, -1.387), ring_size_5(A, H).

active(A) :- atm(A, B, c, 22, C), lumo(A, D), lteq(D, -1.178), ring_size_6(A, E), bond(A,
F, G, 7), bond(A, B, H, 1), lteq(C, -0.128).

เมื่อนำไปทำการทดสอบกับเซตตัวอย่างสำหรับใช้ทดสอบ พบว่าเซตของกฎนี้ให้ค่าความถูกต้อง 0.815789 ที่หรือ เซตของกฎครอบคลุมตัวอย่างบวก 21 ตัว จากทั้งหมด 25 ตัว และครอบคลุมตัวอย่างลบ 3 ตัวจากตัวอย่างลบทั้งหมด 13 ตัว ซึ่งเซตของกฎที่ได้จากวิธีการ Best Learner ก็เป็นเซตตั้งต้นของการทำวิธีการที่นำเสนอ โดยเซตของกฎชุดนี้จะถูกนำไปทดสอบและปรับปรุงกับเซตตัวอย่างสำหรับตัวเรียนรู้ตัวอื่น ซึ่งในขั้นต้นจะได้เซตของกฎ

active(A) :- lumo(A, B), bond(A, C, D, 7), atm(A, C, c, 22, E), atm(A, D, c, 22, E),
ring_size_6(A, F), lteq(E, -0.12), lteq(B, -1.87).

active(A) :- lumo(A, B), nitro(A, C), logp(A, D), gteq(D, 1.46), lteq(B, -2.227).

active(A) :- atm(A, B, c, 27, C), benzene(A, D), atm(A, E, c, 22, F), ring_size_6(A, D),
nitro(A, G), bond(A, E, B, 7), logp(A, H), gteq(H, 3.52).

active(A) :- benzene(A, B), atm(A, C, c, 22, D), atm(A, E, c, 22, D), ring_size_6(A, B),
ring_size_6(A, F), ring_size_6(A, G), carbon_6_ring(A, G).

active(A) :- atm(A, B, c, 22, C), benzene(A, D), atm(A, E, c, 22, C), ring_size_6(A, F),
lumo(A, G), lteq(G, -1.387), ring_size_5(A, H).

active(A) :- atm(A, B, c, 22, C), lteq(C, -0.128), lumo(A, D), lteq(D, -1.178),
ring_size_6(A, E), bond(A, F, G, 7), bond(A, B, H, 1), ring_size_5(A, I),
logp(A, I), gteq(I, 3.35).

เมื่อนำเซตของกฎชุดนี้ไปทำการทดสอบกับเซตตัวอย่างสำหรับการทดสอบจะพบว่าเซตของกฎนี้ให้ค่าความถูกต้อง 0.842105 ที่หรือ เซตของกฎครอบคลุมตัวอย่างบวก 19 ตัว จากทั้งหมด 25 ตัว และไม่ครอบคลุมตัวอย่างลบเลย ซึ่งเห็นได้ว่าค่าความถูกต้องของเซตของกฎดีขึ้น แต่จำนวนตัวอย่างบวกที่ครอบคลุมนั้นลดลง แต่ด้วยวิธีการที่น่าเสนอขึ้นไป จึงเป็นการนำกฎที่ได้จากตัวเรียนรู้อื่นๆ มาเพิ่มให้กับเซตของกฎชุดนี้ (กฎที่เป็นตัวหนาเป็นกฎที่เพิ่มเติมเข้ามา)

active(A) :- lumo(A, B), bond(A, C, D, 7), atm(A, C, c, 22, E), atm(A, D, c, 22, E),
ring_size_6(A, F), lteq(E, -0.12), lteq(B, -1.87).

active(A) :- lumo(A, B), nitro(A, C), logp(A, D), gteq(D, 1.46), lteq(B, -2.227).

active(A) :- atm(A, B, c, 27, C), benzene(A, D), atm(A, E, c, 22, F), ring_size_6(A, D),
nitro(A, G), bond(A, E, B, 7), logp(A, H), gteq(H, 3.52).

active(A) :- benzene(A, B), atm(A, C, c, 22, D), atm(A, E, c, 22, D), ring_size_6(A, B),
ring_size_6(A, F), ring_size_6(A, G), carbon_6_ring(A, G).

active(A) :- atm(A, B, c, 22, C), benzene(A, D), atm(A, E, c, 22, C), ring_size_6(A, F),
lumo(A, G), lteq(G, -1.387), ring_size_5(A, H).

`active(A) :- atm(A, B, c, 22, C), lteq(C, -0.128), lumo(A, D), lteq(D, -1.178),
 ring_size_6(A, E), bond(A, F, G, 7), bond(A, B, H, 1), ring_size_5(A, I),
 logp(A, I), gteq(I, 3.35) .`
`active(A) :- atm(A, B, c, 22, C), bond(A, D, E, 7), nitro(A, F), logp(A, G), gteq(G,
 3.52), gteq(C, -0.12).`
`active(A) :- atm(A, B, c, 22, C), bond(A, D, E, 7), logp(A, F), bond(A, B, G, 1),
 gteq(F, 2.74), ring_size_5(A, H).`
`active(A) :- bond(A, B, C, 7), ring_size_6(A, D), bond(A, E, F, 7), bond(A, B, G, 1),
 logp(A, H), gteq(H, 2.74), ring_size_5(A, I).`
`active(A) :- benzene(A, B), lumo(A, C), bond(A, D, E, 7), bond(A, E, F, 1), nitro(A,
 G), nitro(A, H), lteq(C, -2.142).`
`active(A) :- atm(A, B, c, 22, C), lumo(A, D), bond(A, B, E, 7), atm(A, E, c, 22, C),
 bond(A, E, F, 7), gteq(C, -0.114), lteq(D, -1.937).`
`active(A) :- logp(A, B), bond(A, C, D, 7), atm(A, E, c, 22, F), bond(A, E, G, 1),
 ring_size_6(A, H), gteq(B, 2.29), gteq(F, 0.188).`

ซึ่งเมื่อทำการทดสอบเซตของกฎชุดสุดท้ายนี้กับเซตตัวอย่างสำหรับทดสอบจะพบว่าเซตของกฎนี้ให้ค่าความถูกต้อง 0.921053 ที่เซตของกฎครอบคลุมตัวอย่างบวก 23 ตัว จากทั้งหมด 25 ตัว และครอบคลุมตัวอย่างลบเพิ่มขึ้นมา 1 ตัว ดังนั้นจะเห็นได้ว่าเซตของกฎที่ใช้วิธีการที่นำเสนอสามารถครอบคลุมตัวอย่างบวกได้มากขึ้น ในขณะที่พยายามจำกัดไม่ให้เกิดการเพิ่มขึ้นของตัวอย่างลบจึงทำให้เซตของกฎที่ได้ด้วยวิธีการที่นำเสนอดีกว่าเซตของกฎจากวิธีการ Best Learner

อย่างไรก็ดีวิธีการที่นำเสนอสามารถปรับปรุงเซตของกฎที่ได้ให้มีความถูกต้องสูงขึ้นใกล้เคียงกับการเรียนรู้กับเซตตัวอย่างเรียนรู้ทั้งหมดได้ ซึ่งเมื่อเปรียบเทียบกับการเรียนรู้กับเซตตัวอย่างที่ถูกแบ่งเป็นเปอร์เซ็นต์ต่างๆ ดังแสดงในภาพที่ 3.4 จะเห็นได้ว่าวิธีการนี้ตัวเรียนรู้แต่ละตัวจะทำการเรียนรู้กับเซตตัวอย่างที่ประมาณ 30 เปอร์เซ็นต์จากเซตตัวอย่างเรียนรู้ทั้งหมด แต่ด้วยวิธีการปรับปรุงกฎโดยการเพิ่มสายโซ่สัญญาณจากกฎที่ได้จากตัวเรียนรู้ตัวอื่นและการนำกฎที่ได้จากการเรียนรู้ของตัวเรียนรู้อื่นเข้ามารวม ทำให้เซตของกฎที่ได้จากวิธีการที่นำเสนอครอบคลุมเซตตัวอย่างได้มากขึ้นและยังคงความถูกต้องของเซตของกฎได้

สำหรับเวลาในการเรียนรู้โดยวิธีการที่นำเสนอในตารางที่ 4.3 แสดงให้เห็นถึงจำนวนของอนุประโยคที่ถูกสร้างขึ้นมากที่สุดในการเรียนรู้ด้วยวิธีการที่นำเสนอ เปรียบเทียบกับจำนวน

ของอนุประโยคที่ถูกสร้างขึ้นมากที่สุดในการเรียนรู้โดยใช้เซตตัวอย่างข้อมูลทั้งหมด โดยใช้ Aleph เป็นเครื่องมือในการสร้างกฎด้วยวิธีการโปรแกรมตรรกะเชิงอุปนัย

ตารางที่ 4.3

แสดงจำนวนของอนุประโยคสูงสุดที่ถูกสร้างขึ้นในการค้นหากฎ

เซตตัวอย่าง	วิธีการนี้	Aleph
Mesh1	11,929	29,532
Mesh2	17,060	40,969
Mutagenesis	9,668	21,359
Carcinogenesis	22,240	62,382

จากตารางที่ 4.3 จะเห็นได้ว่าวิธีการที่นำเสนอใช้นั้นสร้างอนุประโยคเพื่อใช้ในการค้นหากฎในจำนวนที่น้อยกว่าการเรียนรู้กับเซตตัวอย่างเรียนรู้ทั้งหมด โดยจำนวนอนุประโยคที่นำมาแสดงนี้จะนำมาจากตัวเรียนรู้ตัวใดตัวหนึ่งที่ให้ค่าจำนวนอนุประโยคที่ถูกสร้างเพื่อใช้ในการค้นหากฎที่มีค่าสูงสุดในแต่ละเซตตัวอย่างเปรียบเทียบกับจำนวนอนุประโยคที่ถูกสร้างโดยใช้เซตตัวอย่างเรียนรู้ทั้งหมด ซึ่งจำนวนของอนุประโยคนั้นมีความสัมพันธ์กับเวลาที่ใช้ในการค้นหาเพื่อให้ได้กฎที่ได้ตามเงื่อนไขที่กำหนด ทั้งนี้เนื่องมาจากการแบ่งเซตตัวอย่างข้อมูลออกเป็นส่วนย่อยทำให้จำนวนของอนุประโยคที่ถูกสร้างและใช้ในการค้นหาจะมีจำนวนน้อยกว่าเมื่อเปรียบเทียบกับการใช้เซตตัวอย่างเรียนรู้ทั้งหมด ทำให้เวลาที่ใช้ในการค้นหาที่ตรงตามเงื่อนไขที่กำหนดน้อยกว่าการเรียนรู้กับเซตตัวอย่างเรียนรู้ทั้งหมดไปด้วยนั่นเอง

ดังนั้นจึงจะเห็นได้ว่าวิธีการที่นำเสนอเมื่อนำมาทำการเรียนรู้โดยวิธีการประมวลผลแบบขนาน โดยการแบ่งเซตตัวอย่างเรียนรู้ออกเป็นเซตตัวอย่างย่อยแล้วนำไปทำการเรียนรู้ จึงสามารถที่จะลดเวลาในการเรียนรู้ด้วยวิธีการโปรแกรมตรรกะเชิงอุปนัยลงได้เมื่อเปรียบเทียบกับการเรียนรู้กับเซตตัวอย่างเรียนรู้ทั้งหมด โดยที่ยังคงความถูกต้องได้ใกล้เคียงเทียบเท่ากับการเรียนรู้โดยใช้เซตตัวอย่างเรียนรู้ทั้งหมดได้