

```

addchoice(X,Res):- length(X,Len),
    numlist(1,Len,NumL),
    map(NumL,X,Res).

map([],[],[99-exitShell]).

map([H|T], [X|TT], [H-X|T1]) :- map(T, TT, T1).

```

ตัวอย่างการใช้งานระบบผู้เชี่ยวชาญเพื่อขอคำแนะนำเกี่ยวกับใช้ก่อนแท็กเลนส์ แสดงได้ดังรูปที่ 5.6 เมื่อรันโปรแกรม expertshell1.pl ผู้ใช้จะเริ่มต้นใช้งาน expert system shell ด้วยการพิมพ์คำสั่ง expertshell (ทุกคำสั่งในภาษาโปรแกรมจะต้องจบคำสั่งด้วยเครื่องหมาย '.') เมื่อ expert system shell เริ่มทำงาน ที่ต้นบรรทัดจะปรากฏข้อความ expert-shell> เพื่อเตรียมรับคำสั่งจากผู้ใช้ คำสั่งแรกของการใช้งานคือคำสั่ง load เพื่อเรียกใช้ไฟล์ฐานความรู้ที่เกี่ยวข้อง ซึ่งในตัวอย่างนี้ใช้ไฟล์ '1.knb' จากนั้นใช้คำสั่ง solve โปรแกรมจะเริ่มตามข้อมูลต่างๆจากผู้ใช้ เมื่อได้ข้อมูลที่ต้องการเพียงพอแล้ว จะแสดงคำแนะนำให้ผู้ใช้ทราบ พร้อมทั้งค่าความน่าจะเป็นเพื่อให้ผู้ใช้ทราบว่าจะเชื่อมั่นในคำแนะนำนี้ได้มากน้อยเพียงใด และถ้าผู้ใช้ต้องการคำอธิบายประกอบคำแนะนำ สามารถเรียกดูคำอธิบายได้โดยการพิมพ์คำสั่ง why

ในกรณีที่ข้อมูลที่ผู้ใช้ระบุไม่ปรากฏในกฎใดๆ ของฐานความรู้ ระบบผู้เชี่ยวชาญจะได้ตอบด้วยข้อความดังรูปที่ 5.7

```
[c:\SWI-Prolog -- c:/Documents and Settings/Nittaya/Desktop/expertshell1.pl]
File Edit Settings Run Debug Help

1 ?- expertshell.
This is the Easy Expert System shell.
Type help, load, solve, why, quit, or 99,
at the prompt.
expert-shell> load.
Enter file name in single quotes (ex. '1.knb'): '1.knb'.
% 1.knb compiled 0.01 sec, 2,336 bytes
expert-shell> solve.

What is the value for tear?
[1-reduced, 2-normal, 99-exitShell]
Enter the choice> 2.

What is the value for age?
[1-young, 2-pre_presbyopic, 3-presbyopic, 99-exitShell]
Enter the choice> 1.
The answer is yes with probability 0.166667
expert-shell> why.

The answer is ...yes... with probability = 0.166667.
The known storage are
[age(young), tear(normal)]
expert-shell>
```

รูปที่ 5.6 ระบบผู้เชี่ยวชาญที่ให้คำแนะนำเกี่ยวกับคอนแท็กเลนส์

```
[c:\SWI-Prolog -- c:/Documents and Settings/Nittaya/Desktop/expertshell1.pl]
File Edit Settings Run Debug Help

1 ?- expertshell.
This is the Easy Expert System shell.
Type help, load, solve, why, quit, or 99,
at the prompt.
expert-shell> load.
Enter file name in single quotes (ex. '1.knb'): '1.knb'.
% 1.knb compiled 0.00 sec, 2,336 bytes
expert-shell> solve.

What is the value for tear?
[1-reduced, 2-normal, 99-exitShell]
Enter the choice> 2.

What is the value for age?
[1-young, 2-pre_presbyopic, 3-presbyopic, 99-exitShell]
Enter the choice> 3.
No answer found.
expert-shell>
```

รูปที่ 5.7 การตัดตอนของระบบผู้เชี่ยวชาญกรณีไม่มีข้อมูลปรากฏในฐานความรู้

## 5.2 การทดสอบโปรแกรมเพื่อการประมวลผลหลังการทำเหมืองข้อมูล

### 5.2.1 วิธีการทดสอบโปรแกรมเพื่อการประมวลผลหลังการทำเหมืองข้อมูล

การทำเหมืองข้อมูลในงานวิจัยนี้เน้นที่การทำเหมืองข้อมูลเพื่อการจำแนก วิธีการสร้างโมเดลข้อมูลใช้หลักการของการสร้างต้นไม้ตัดสินใจตามอัลกอริทึม ID3 (Quinlan 1993) ที่ใช้การสร้างโหนดของต้นไม้เป็นเครื่องมือในการแยกข้อมูลที่มี屬性คลาสปะปนกัน ให้เหลือเป็นกลุ่มข้อมูลย่อยที่เป็นคลาสเดียวกัน จากนั้นอ่านลักษณะของข้อมูลในแต่ละกลุ่มย่อยจากโครงสร้างโหนดและกิ่งของต้นไม้ตัดสินใจ วิธีการจำแนกข้อมูลเพื่อให้ได้โมเดลในลักษณะนี้ได้รับการยอมรับว่ามีความถูกต้องของโมเดลสูง และข้อเด่นของวิธีการนี้คือ โมเดลเข้าใจได้ง่าย

โมเดลที่ได้จากการทำเหมืองข้อมูลนี้จะถูกประมวลผลต่อไป โดยโมเดลจะถูกเปลี่ยนเป็นกฎการตัดสินใจที่มีค่าความน่าจะเป็นกำกับ ค่าความน่าจะเป็นนี้ถูกใช้เป็นเกณฑ์เพื่อวัดอัตราส่วนของจำนวนข้อมูลที่สามารถอธิบายได้ด้วยกฎการตัดสินใจ (หรือเรียกว่าค่า coverage) ซึ่งค่านี้จะแปลความหมายได้ถึงโอกาสที่กฎหมายจะประยุกต์ใช้ได้กับข้อมูลใหม่ที่จะเกิดขึ้นในอนาคต

ดังนั้นวิธีการทดสอบความสามารถของโปรแกรมเพื่อการประมวลผลหลังการทำเหมืองข้อมูลจะใช้วิธีแยกข้อมูลส่วนใหญ่เป็นข้อมูลฝึก เพื่อสร้างโมเดลข้อมูลและสร้างกฎการตัดสินใจที่จะถูกแปลงเป็นกฎในระบบผู้ช่วยแพทย์ จำนวนนี้จะทดสอบความถูกต้องในการให้คำแนะนำของระบบผู้ช่วยแพทย์ โดยข้อมูลที่ใช้ทดสอบเป็นข้อมูลขนาดเล็กมีจำนวน 16 รายการ ชุดข้อมูลที่ใช้ในการทดสอบโปรแกรมนี้เป็นข้อมูลมาตรฐานของ UCI Machine Learning Repository: Data Sets (<http://archive.ics.uci.edu/ml/datasets.html>) โดยเลือกใช้ข้อมูล post-operative patients (จำนวนข้อมูลฝึกมี 70 เรคคอร์ด แต่ละเรคคอร์ดประกอบด้วย 8 แอทริบิวต์) และข้อมูล breast-cancer recurrences (จำนวนข้อมูลฝึกมี 175 เรคคอร์ด แต่ละเรคคอร์ดประกอบด้วย 9 แอทริบิวต์) ข้อมูลฝึกและข้อมูลทดสอบของชุดข้อมูลทั้งสองในรูปแบบของโปรดักต์ ปรากฏในภาคผนวกฯ

ตัวอย่างวิธีการทดสอบความถูกต้องของระบบผู้ช่วยแพทย์ข้อมูลคนไข้รายที่ 71 ในชุดข้อมูล post-operative patients แสดงได้ดังรูปที่ 5.8 ขั้นตอนการใช้งาน expert system shell ที่แสดงในรูปเป็นการสอนตามคำแนะนำกรณีไข้หลังผ่าตัด มีค่าอุณหภูมิภายในร่างกาย ค่าความดัน และค่าอื่นๆ เป็น [internalTemp= mid, surfaceTemp=mid, oxygenSaturation=excellent, bloodPressure=high, tempStability=stable, coreTempStability=stable, bpStability=stable, comfort=10] ผลการวินิจฉัยของแพทย์ระบุให้ส่งคนไข้รายนี้ไปที่หอผู้ป่วยหรือ ward และผลจากคำแนะนำของระบบผู้ช่วยแพทย์เป็น ward (คำแนะนำอนุญาตจากกฎที่ 12 ในฐานความรู้ของระบบผู้ช่วยแพทย์) แสดงว่าคำแนะนำที่ระบบผู้ช่วยแพทย์ให้แก่คนไข้รายนี้ถูกต้อง กฎที่ใช้ในระบบผู้ช่วยแพทย์ความตัวอย่างนี้ สร้างจากโปรแกรมคัดเลือกกฎการตัดสินใจที่กำหนดค่าความน่าจะเป็น

ขั้นค่า 0.001 กดทั้งหมดในระบบผู้ชี้ยวชาญแสดงได้ดังรูปที่ 5.9 ในกรณีของข้อมูล breast-cancer recurrences ฐานความรู้ของระบบผู้ชี้ยวชาญแสดงดังรูปที่ 5.10

```
/* *** Test Data
=====
instance{71, class=ward, [internalTemp=mid, surfaceTemp=mid, oxygenSaturation=excellent,
                           bloodPressure=high, tempStability=stable, coreTempStability=stable,
                           bpStability=stable, comfort=10]}.
```

```
% 1.knb
% for expert shell. --- written by Postprocess
% top_goal where the inference starts.

top_goal(X,V) :- type(X,V).

type(ward,0.1):-comfort(10),bloodPressure(high),surfaceTemp(low). % generated rule
type(ward,0.0714286):-comfort(10),bloodPressure(mid),surfaceTemp(low),bpStability(stable). % generated rule
type(ward,0.0714286):-comfort(10),bloodPressure(mid),surfaceTemp(high),bpStability(mod_stable). % generated rule
type(ward,0.0571429):-comfort(10),bloodPressure(high),surfaceTemp(mid),bpStability(mod_stable). % generated rule
type(ward,0.0428571):-comfort(10),bpStability(unstable),surfaceTemp(mid). % generated rule
type(ward,0.0428571):-comfort(10),bloodPressure(mid),surfaceTemp(mid),bpStability(stable),internalTemp(mid),tempSt
type(ward,0.0428571):-comfort(10),bloodPressure(low). % generated rule
type(ward,0.0285714):-comfort(15),bpStability(unstable),surfaceTemp(high). % generated rule
type(ward,0.0285714):-comfort(15),bpStability(stable),internalTemp(mid),surfaceTemp(mid). % generated rule
type(ward,0.0285714):-comfort(15),bpStability(mod_stable). % generated rule
type(home,0.0285714):-comfort(10),bloodPressure(mid),surfaceTemp(mid),bpStability(mod_stable). % generated rule
type(home,0.0142857):-comfort(10),bloodPressure(mid),surfaceTemp(mid),bpStability(stable),internalTemp(mid),tempSt
type(home,0.0142857):-comfort(15),bpStability(unstable),surfaceTemp(low). % generated rule
type(home,0.0142857):-comfort(15),bpStability(stable),internalTemp(mid),surfaceTemp(low),oxygenSaturation(good).
```

```
KL-Querying -> Documentation and Tutorials -> Introductory Tutorials -> expert-shell
File Edit Options Run Using Help
expert-shell> solve.

What is the value for comfort?
[1-5, 2-7, 3-10, 4-15, 99-exitShell]
Enter the choice> 3.

What is the value for bloodPressure?
[1-high, 2-mid, 3-low, 99-exitShell]
Enter the choice> 1.

What is the value for surfaceTemp?
[1-mid, 2-high, 3-low, 99-exitShell]
Enter the choice> 1.

What is the value for bpStability?
[1-stable, 2-mod_stable, 3-unstable, 99-exitShell]
Enter the choice> 1.

What is the value for oxygenSaturation?
[1-excellent, 2-good, 3-fair, 4-poor, 99-exitShell]
Enter the choice> 1.
The answer is ward with probability 0.0285714
expert-shell> why.

The answer is ...ward... with probability = 0.0285714.
The known storage are
[oxygenSaturation(excellent), bpStability(stable), surfaceTemp(mid), bloodPressure(high), comfort]
expert-shell>
```

รูปที่ 5.8 ตัวอย่างการทดสอบความถูกต้องของระบบผู้ชี้ยวชาญ

```

1 WordPad
File Edit View Insert Format Help
top_goal(X,V) :- type(X,V).

type(ward,0.1):-comfort(10),bloodPressure(high),surfaceTemp(low). % generated rule
type(ward,0.0714286):-comfort(10),bloodPressure(mid),surfaceTemp(low),bpStability(stable). % generated rule
type(ward,0.0714286):-comfort(10),bloodPressure(mid),surfaceTemp(high),bpStability(mod_stable). % generated rule
type(ward,0.0571429):-comfort(10),bloodPressure(high),surfaceTemp(mid),bpStability(mod_stable). % generated rule
type(ward,0.0428571):-comfort(15),bpStability(unstable),surfaceTemp(mid). % generated rule
type(ward,0.0428571):-comfort(10),bloodPressure(mid),surfaceTemp(mid),bpStability(stable),internalT.
type(ward,0.0428571):-comfort(10),bloodPressure(low). % generated rule
type(ward,0.0285714):-comfort(15),bpStability(unstable),surfaceTemp(high). % generated rule
type(ward,0.0285714):-comfort(15),bpStability(stable),internalTemp(mid),surfaceTemp(mid). % generated rule
type(ward,0.0285714):-comfort(15),bpStability(mod_stable). % generated rule
type(home,0.0285714):-comfort(10),bloodPressure(mid),surfaceTemp(mid),bpStability(mod_stable). % generated rule
type(ward,0.0285714):-comfort(10),bloodPressure(high),surfaceTemp(mid),bpStability(stable),oxygenSa.
type(home,0.0142857):-comfort(15),bpStability(unstable),surfaceTemp(low). % generated rule
type(home,0.0142857):-comfort(15),bpStability(stable),internalTemp(mid),surfaceTemp(low),oxygenSatu.
type(ward,0.0142857):-comfort(15),bpStability(stable),internalTemp(mid),surfaceTemp(low),oxygenSatu.
type(home,0.0142857):-comfort(15),bpStability(stable),internalTemp(low),surfaceTemp(mid). % generated rule
type(ward,0.0142857):-comfort(15),bpStability(stable),internalTemp(low),surfaceTemp(high). % generated rule
type(home,0.0142857):-comfort(15),bpStability(stable),internalTemp(high). % generated rule
type(home,0.0142857):-comfort(10),bloodPressure(mid),surfaceTemp(mid),bpStability(unstable),tempSta.
type(ward,0.0142857):-comfort(10),bloodPressure(mid),surfaceTemp(mid),bpStability(unstable),tempSta.
type(ward,0.0142857):-comfort(10),bloodPressure(mid),surfaceTemp(mid),bpStability(stable),internalT.
type(home,0.0142857):-comfort(10),bloodPressure(mid),surfaceTemp(mid),bpStability(stable),internalT.
type(ward,0.0142857):-comfort(10),bloodPressure(mid),surfaceTemp(low),bpStability(unstable),internalT.
type(home,0.0142857):-comfort(10),bloodPressure(mid),surfaceTemp(low),bpStability(mod_stable). % generated rule
type(ward,0.0142857):-comfort(10),bloodPressure(mid),surfaceTemp(high),bpStability(unstable). % generated rule
type(home,0.0142857):-comfort(10),bloodPressure(mid),surfaceTemp(high),bpStability(stable),internalT.
type(ward,0.0142857):-comfort(10). % generated rule
type(home,0.0142857):-comfort(5). % generated rule

internalTemp(X):-menuask(internalTemp,X,[mid, high, low]). %generated menu
surfaceTemp(X):-menuask(surfaceTemp,X,[mid, high, low]). %generated menu
oxygenSaturation(X):-menuask(oxygenSaturation,X,[excellent, good, fair, poor]). %generated menu
bloodPressure(X):-menuask(bloodPressure,X,[high, mid, low]). %generated menu
tempStability(X):-menuask(tempStability,X,[stable, mod_stable, unstable]). %generated menu
coreTempStability(X):-menuask(coreTempStability,X,[stable, mod_stable, unstable]). %generated menu
bpStability(X):-menuask(bpStability,X,[stable, mod_stable, unstable]). %generated menu
comfort(X):-menuask(comfort,X,[5, 7, 10, 15]). %generated menu
class(X):-menuask(class,X,[home, ward]). %generated menu

```

รูปที่ 5.9 กฎทั้งหมดของระบบผู้ช่วยชาญที่สร้างด้วยเกณฑ์ความน่าจะเป็นขั้นต่ำ 0.001

```

% 1.knb
% for expert shell. --- written by Postprocess
% top_goal where the inference starts.

top_goal(X,V) :- type(X,V).

type(no,0.0514286):-invNodes(range0_2),menopause(ge40),breast(right),degMalign(1),age(range1_1).
type(no,0.04):-invNodes(range0_2),menopause(premeno),breastQuad(right_low). % generated rule
type(no,0.04):-invNodes(range0_2),menopause(ge40),breast(left),degMalign(1). % generated rule
type(no,0.0342857):-invNodes(range0_2),menopause(ge40),breast(left),degMalign(3). % generated rule
type(no,0.0342857):-invNodes(range0_2),menopause(ge40),breast(left),degMalign(2),irradiat(nc).
type(no,0.0285714):-invNodes(range0_2),menopause(premeno),breastQuad(left_low),irradiat(nc).
type(no,0.0228571):-invNodes(range0_2),menopause(premeno),breastQuad(central),breast(left).
type(no,0.0228571):-invNodes(range0_2),menopause(ge40),breast(right),degMalign(2),irradiat(nc).
type(yes,0.0171429):-invNodes(range6_8),breastQuad(right_low). % generated rule
type(yes,0.0171429):-invNodes(range3_5),degMalign(2),breast(left),irradiat(yes). % generate rule
type(no,0.0171429):-invNodes(range3_5),degMalign(1). % generated rule
type(yes,0.0171429):-invNodes(range0_2),menopause(premeno),breastQuad(right_up),irradiat(nc).
type(no,0.0171429):-invNodes(range0_2),menopause(premeno),breastQuad(left_up),degMalign(2). % generated rule
type(no,0.0171429):-invNodes(range0_2),menopause(ge40),breast(right),degMalign(3),irradiat(nc).
type(no,0.0171429):-invNodes(range9_11),irradiat(yes),nodeCaps(yes). % generated rule
type(yes,0.0114286):-invNodes(range9_11),irradiat(no). % generated rule
type(yes,0.0114286):-invNodes(range6_8),breastQuad(left_low). % generated rule
type(yes,0.0114286):-invNodes(range3_5),degMalign(3),irradiat(yes),breast(left). % generate rule
type(no,0.0114286):-invNodes(range3_5),degMalign(2),breast(right),irradiat(yes). % generate rule
type(no,0.00571429):-invNodes(range0_2),menopause(premeno),breastQuad(left_low),irradiat(nc).
type(no,0.00571429):-invNodes(range0_2),menopause(premeno),breastQuad(central),breast(right).
type(no,0.00571429):-invNodes(range0_2),menopause(lt40),degMalign(3). % generated rule
type(no,0.00571429):-invNodes(range0_2),menopause(lt40),degMalign(2). % generated rule
type(no,0.00571429):-invNodes(range0_2),menopause(lt40),degMalign(1),age(range60_69). % generated rule
type(yes,0.00571429):-invNodes(range0_2),menopause(ge40),breast(right),degMalign(3),irradiat(nc).
type(yes,0.00571429):-invNodes(range0_2),menopause(ge40),breast(left),degMalign(2),irradiat(nc).
type(no,0.00571429):-invNodes(range0_2),menopause(ge40),breast(left),degMalign(2),irradiat(nc).

age(X):-menuask(age,X,[range20_29, range30_39, range40_49, range50_59, range60_69]). %generated menu
menopause(X):-menuask(menopause,X,[lt40, ge40, premeno]). %generated menu
tumorSize(X):-menuask(tumorSize,X,[range0_4, range5_9, range10_14, range15_19, range20_24, range25_29]). %generated menu
invNodes(X):-menuask(invNodes,X,[range0_2, range3_5, range6_8, range9_11, range15_17, range18_20]). %generated menu
nodeCaps(X):-menuask(nodeCaps,X,[missing, yes, no]). %generated menu
degMalign(X):-menuask(degMalign,X,[1, 2, 3]). %generated menu
breast(X):-menuask(breast,X,[left, right]). %generated menu
breastQuad(X):-menuask(breastQuad,X,[left_up, left_low, right_up, right_low, central]). %generated menu
irradiat(X):-menuask(irradiat,X,[yes, no]). %generated menu
class(X):-menuask(class,X,[no, yes]). %generated menu

%end of automatic post process

```

รูปที่ 5.10 ฐานความรู้ของระบบผู้เชี่ยวชาญในการแนะนำเกี่ยวกับ breast-cancer recurrences

การทดสอบความถูกต้องในการให้คำแนะนำของระบบผู้เชี่ยวชาญที่พัฒนาขึ้นในงานวิจัยนี้ จะเปรียบเทียบกับผลการทดสอบในการจำแนกข้อมูลด้วยอัลกอริทึม ID3 (decision-tree induction algorithm), PRISM (rule induction algorithm) และ neural network (multi-layer perceptron algorithm)

### 5.2.2 ผลการทดสอบโปรแกรม

ผลการทดสอบความถูกต้องในการให้คำแนะนำของระบบผู้เชี่ยวชาญ ในกรณีของข้อมูล post-operative patients แสดงดังตารางที่ 5.1 และผลการทดสอบความถูกต้องในการให้คำแนะนำของระบบผู้เชี่ยวชาญในกรณีของข้อมูล breast-cancer recurrences แสดงดังตารางที่ 5.2

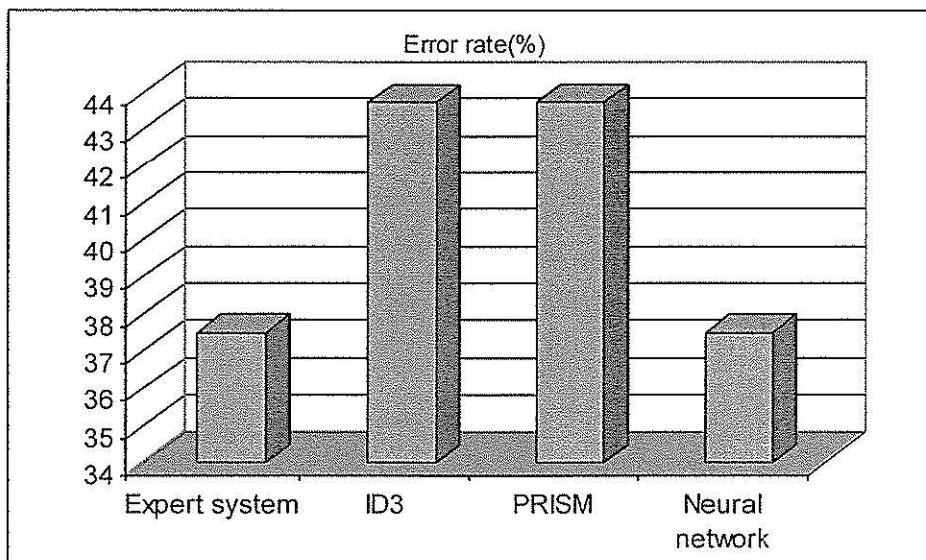
ตารางที่ 5.1 ผลการทดสอบความถูกต้องของระบบผู้เชี่ยวชาญกับข้อมูล post-operative patients

ข้อมูลที่	การวินิจฉัยของแพทย์	คำแนะนำของระบบผู้เชี่ยวชาญ	ผลการทำนายของ ID3	ผลการทำนายของ PRISM	ผลการทำนายของ Neural network
1	Ward	Ward	Ward	Ward	Ward
2	Ward	Ward	Ward	Ward	Ward
3	Ward	Ward	Unclassified	Home	Ward
4	Ward	Home	Home	Home	Home
5	Ward	Ward	Ward	Unclassified	Ward
6	Home	Ward	Ward	Home	Home
7	Ward	Home	Home	Home	Home
8	Ward	Ward	Ward	Ward	Ward
9	Home	No answer found	Ward	Ward	Ward
10	Ward	Home	Home	Home	Home
11	Ward	Ward	Ward	Unclassified	Ward
12	Ward	Ward	Ward	Ward	Ward
13	Home	Ward	Ward	Ward	Ward
14	Ward	Ward	Ward	Ward	Ward
15	Ward	Ward	Ward	Ward	Ward
16	Home	Ward	Ward	Ward	Ward

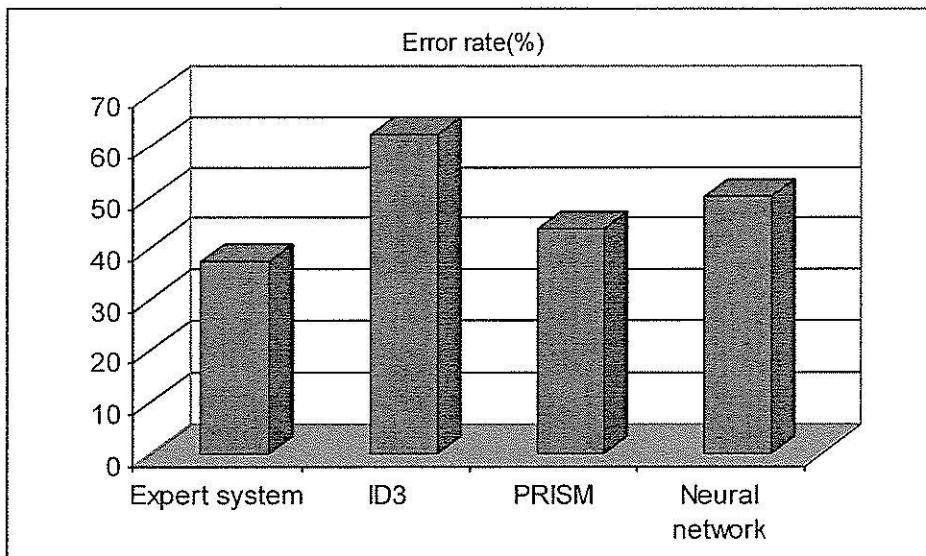
ตารางที่ 5.2 ผลการทดสอบความถูกต้องของระบบผู้เชี่ยวชาญกับข้อมูล breast-cancer recurrences

ข้อมูลที่	การวินิจฉัยของแพทย์	คำแนะนำของระบบผู้เชี่ยวชาญ	ผลการทำนายของ ID3	ผลการทำนายของ PRISM	ผลการทำนายของ Neural network
1	No	No	Yes	No	Yes
2	No	Yes	Yes	Yes	Yes
3	Yes	Yes	No	No	No
4	Yes	No answer found	No	No	Yes
5	No	Yes	Unclassified	No	No
6	No	No answer found	Yes	No	No
7	Yes	No	No	No	No
8	No	No	Yes	Yes	No
9	Yes	No	No	Yes	No
10	No	Yes	No	No	Yes
11	No	No	No	No	No
12	No	Yes	Yes	Yes	Yes
13	Yes	Yes	No	No	Yes
14	No	No answer found	No	No	No
15	No	No	Unclassified	No	Yes
16	Yes	Yes	Yes	Yes	Yes

ผลการเปรียบเทียบความผิดพลาดในการให้คำแนะนำ หรือการทำนายคลาสของข้อมูลทดสอบของโปรแกรม expert system, ID3, PRISM, Neural network กับข้อมูล post-operative patients และ breast-cancer recurrences แสดงดังกราฟในรูปที่ 5.11 และ 5.12 ตามลำดับ



รูปที่ 5.11 กราฟเกริยบเทียบ error rate เมื่อทดสอบกับข้อมูล post-operative patients



รูปที่ 5.12 กราฟเกริยบเทียบ error rate เมื่อทดสอบกับข้อมูล breast-cancer recurrences

### อภิปรายผล

จากผลการทดสอบความถูกต้องของโปรแกรมประมวลผลหลังการทำเหมืองข้อมูล หรือโปรแกรม expert system ในทั้งสองชุดข้อมูลเมื่อเทียบกับโปรแกรม ID3 พบว่าโปรแกรม expert system ให้ผลลัพธ์ที่ถูกต้องมากกว่าทั้งๆที่โปรแกรม expert system ใช้ไมคेलข้อมูลเริ่มต้น เป็นดันไม้ตัดสินใจเหมือนกับโปรแกรม ID3 แต่ข้อแตกต่างอยู่ที่ โปรแกรม expert system มีการ จัดลำดับกฎการตัดสินใจตามค่าความน่าจะเป็นและคัดเลือกใช้เฉพาะกฎที่มีค่าความน่าจะเป็นสูง

เมื่อเปรียบเทียบความผิดพลาดในการให้คำแนะนำ หรือความผิดพลาดในการทำนาย (error rate) ของโปรแกรมทั้งสี่พบว่าโปรแกรม expert system ให้คำความผิดพลาดที่ต่ำที่สุด (ถือ 37.50% ในข้อมูลห้องสองชุด) และเมื่อวิเคราะห์ความผิดพลาดในลักษณะของ false negative (ดังตารางที่ 5.3) พบว่าโปรแกรม expert system ให้ความผิดพลาดชนิดนี้ต่ำที่สุด ซึ่งในการวินิจฉัยทางด้านการแพทย์ความผิดพลาดประเภท false negative (เช่นคนไข้เป็นมะเร็ง แต่ได้รับการวินิจฉัยว่าสุขภาพแข็งแรงเป็นปกติ) ถือว่ามีความร้ายแรงมากกว่าความผิดพลาดประเภท false positive (เช่นคนไข้ที่ไม่เป็นมะเร็ง แต่ได้รับการวินิจฉัยว่าเป็นมะเร็งและจะต้องถูกส่งไปตรวจทางคลินิกเพิ่มเติม)

ตารางที่ 5.3 ผลการวิเคราะห์ความผิดพลาดในลักษณะของ false negative

False negative error	Expert system	ID3	PRISM	Neural network
ข้อมูล post-operative patients ลักษณะการทำนายผิด จากส่งกลับหอผู้ป่วย (ward) เป็นส่งกลับบ้าน (home)	Error = 3/16 = 18.75%	Error = 3/16 = 18.75%	Error = 4/16 = 25%	Error = 3/16 = 18.75%
ข้อมูล breast-cancer recurrences ลักษณะการทำนายผิด จากเป็นมะเร็งช้ำ (yes) เป็นไม่เป็นมะเร็ง (no)	Error = 2/16 = 12.50%	Error = 5/16 = 31.25%	Error = 4/16 = 25%	Error = 3/16 = 18.75%

โปรแกรมที่ใช้ไม้เดลข้อมูลในลักษณะของต้นไม้ตัดสินใจ (ID3) หรือในลักษณะของกฎ (expert system และ PRISM) จะมีข้อบกพร่องที่เห็นได้ชัดเจนจากผลการทดลองคือ ไม้เดลที่ได้ไม่สมบูรณ์ เนื่องจากจะมีบางกรณีที่ไม่สามารถให้คำแนะนำ หรือไม่สามารถทำนายคลาสของข้อมูลได้ ซึ่งจะต่างจากโปรแกรม Neural network ที่มีพื้นฐานการสร้างโมเดลจากการใช้ฟังก์ชันทางคณิตศาสตร์ (ในการทดลองนี้ใช้ sigmoid function) ทำให้สามารถทำนายคลาสของข้อมูลได้ครอบคลุมหมดทุกรูปนี้

### 5.3 สรุปผลโครงการวิจัยที่ 4

โปรแกรมเพื่อการทำเหมืองข้อมูลในปัจจุบัน มักจะได้รับการพัฒนาโปรแกรมจนถึงขั้นให้สามารถแสดงผลลัพธ์เป็นไม้เดลข้อมูล หรือแพทเทิร์นของกลุ่มข้อมูล ขั้นตอนต่อจากนั้นที่เป็นการนำไม้เดลหรือแพทเทิร์นไปใช้ประโยชน์มักจะให้อัญญานุสิขของนักวิเคราะห์ข้อมูล ซึ่งนักวิเคราะห์ข้อมูลที่ไม่คุ้นเคยกับกระบวนการการทำเหมืองข้อมูล มักจะประสบกับอุปสรรคสำคัญของ การคัดเลือกความรู้ในไม้เดลไปใช้งานต่อไป นี่เป็นสาเหตุที่ทำให้ไม้เดลไม่ได้รับความนิยมอย่างแพร่หลายในวงการอุตสาหกรรม

ผลลัพธ์เป็น โนมเดลที่มีความซับซ้อนและมีขนาดใหญ่ท่าให้แปลผลได้ยาก ตัวอย่างเช่นจากข้อมูล post-operative patients เมื่อสร้าง โนมเดลข้อมูลด้วยโปรแกรม ID3 จะได้ผลลัพธ์ที่เป็นโครงสร้างต้นไม้ขนาดใหญ่ (รูปที่ 5.13) และข้อมูลเดียวกันนี้เมื่อสร้าง โนมเดลด้วยโปรแกรม Multi-layer perceptron ซึ่งเป็นโปรแกรมในกลุ่ม Neural network จะได้ผลลัพธ์ (รูปที่ 5.14) เป็น โนมเดลข้อมูลในลักษณะฟังก์ชันที่แปลผลได้ค่อนข้างหากสำหรับผู้ที่ไม่คุ้นเคย

<pre> comfort = 05: home comfort = 07: home comfort = 10   bloodPressure = high     surfaceTemp = mid       bpStability = stable         oxygenSaturation = excellent: ward         oxygenSaturation = good         surfaceTempStability = stable: home         surfaceTempStability = mod-stable: null         surfaceTempStability = unstable: ward         oxygenSaturation = fair: null         oxygenSaturation = poor: null         bpStability = mod-stable: ward         bpStability = unstable         surfaceTemp = high         internalTemp = mid: home         internalTemp = high: ward         internalTemp = low: null         surfaceTemp = low: ward         bloodPressure = mid         surfaceTemp = mid         bpStability = stable         internalTemp = mid           surfaceTempStability = stable: ward           surfaceTempStability = mod-stable: null           surfaceTempStability = unstable: ward           internalTemp = high: home           internalTemp = low           oxygenSaturation = excellent: home           oxygenSaturation = good: home           oxygenSaturation = fair: null           oxygenSaturation = poor: null           bpStability = mod-stable: home           bpStability = unstable           internalTemp = mid </pre>	<pre>           surfaceTempStability = stable: ward           surfaceTempStability = mod-stable: null           surfaceTempStability = unstable: home           internalTemp = high: ward           internalTemp = low: null           surfaceTemp = high           bpStability = stable           internalTemp = mid: home           internalTemp = high: null           internalTemp = low: ward           bpStability = mod-stable: ward           bpStability = unstable: ward           surfaceTemp = low           bpStability = stable: ward           bpStability = mod-stable: home           bpStability = unstable           internalTemp = mid: home           internalTemp = high: null           internalTemp = low: home           bloodPressure = low: ward   comfort = 15   bpStability = stable     bloodPressure = high: home     bloodPressure = mid       internalTemp = mid: ward       internalTemp = high: null       internalTemp = low         surfaceTemp = mid: home         surfaceTemp = high: ward           surfaceTemp = low: null           bloodPressure = low: null           bpStability = mod-stable: ward           bpStability = unstable           surfaceTemp = mid: ward           surfaceTemp = high: ward           surfaceTemp = low: home </pre>
--	---

รูปที่ 5.13 โนมเดลของข้อมูล breast-cancer recurrences สร้างจาก โปรแกรม ID3

Sigmoid Node 0	...
Inputs Weights	
Threshold 4.838013774039095	
Node 2 -3.908582636087111	
Node 3 -3.162267392436414	
Node 4 1.0981619846468047	
Node 5 0.18908775947239695	
Node 6 -5.74938601906933	
Node 7 4.422399319810025	
Node 8 0.1999742473645021	
Node 9 -3.5324578914467377	
Node 10 0.11046630190222735	
Node 11 -1.7079259280625576	
Node 12 2.566868144965138	
Node 13 -1.1374211603297253	
Node 14 -2.7865026549167866	
Node 15 0.5042240856020124	
Sigmoid Node 1	
Inputs Weights	
Threshold -4.837381256263012	
Node 2 3.9522624615165793	
Node 3 3.1682972818602746	
Node 4 -1.094499095299558	
Node 5 -0.13283814684003517	
Node 6 5.746872610366041	
Node 7 -4.424392875653778	
Node 8 -0.18722208735744159	
Node 9 3.527387810727785	
Node 10 -0.10472586398059963	
Node 11 1.6962159718097416	
Node 12 -2.560804638307743	
Node 13 1.0737048825607642	
Node 14 2.7877184996555053	
Node 15 -0.5273986540734854	
Sigmoid Node 2	
Inputs Weights	
Threshold -0.27814804385505276	
Attrib internalTemp=mid 0.5810283641710741	
Attrib internalTemp=high 0.21179494161259477	
Attrib internalTemp=low -0.5449481721523186	
Attrib surfaceTemp=mid 1.1141644074041142	
Attrib surfaceTemp=high 1.5150741028274102	
...	
...	
Sigmoid Node 15	
Inputs Weights	
Threshold -0.2930395536777638	
Attrib internalTemp=mid 0.062120538342274045	
Attrib internalTemp=high 0.3128132567811115	
Attrib internalTemp=low 0.018576988447827396	
Attrib surfaceTemp=mid 0.04411226345984964	
Attrib surfaceTemp=high 0.5845640457361527	
Attrib surfaceTemp=low -0.3416470192893855	
Attrib oxygenSaturation=excellent -0.022407433837484465	
Attrib oxygenSaturation=good -0.0017430323732858114	
Attrib oxygenSaturation=fair -0.01474001719084124	
Attrib oxygenSaturation=poor -0.02503529326219822	
Attrib bloodPressure=high 0.3330125093594764	
Attrib bloodPressure=mid -0.3816134197463625	
Attrib bloodPressure=low 0.32842425053023594	
Attrib surfaceTempStability=stable 0.11418920446981239	
Attrib surfaceTempStability=mod-stable -0.0132397526586	
Attrib surfaceTempStability=unstable -0.07986194908507	
Attrib coreTempStability=stable -0.14532864396285983	
Attrib coreTempStability=mod-stable 0.31474360142549024	
Attrib coreTempStability=unstable 0.12862619667684774	
Attrib bpStability=stable 0.21950090896499233	
Attrib bpStability=mod-stable -0.10037656428787754	
Attrib bpStability=unstable 0.1820629305281999	
Attrib comfort=05 0.04690470481373389	
Attrib comfort=07 0.09299279029838585	
Attrib comfort=10 -0.024417921014600892	
Attrib comfort=15 0.4216833375087676	
Class home	
Input	
Node 0	
Class ward	
Input	
Node 1	

รูปที่ 5.14 โน๊มเดลของข้อมูล breast-cancer recurrences สร้างจากโปรแกรม Multi-layer perceptron

โครงการวิจัยเรื่องการประมวลผลหลังกระบวนการทำเหมือนข้อมูลนี้ จึงมีวัตถุประสงค์หลักเพื่อจะพัฒนาโปรแกรมเพื่อรับอินพุตเป็นโน๊มเดลข้อมูล จากนั้นแปลงโน๊มเดลข้อมูลให้อยู่ในรูปแบบที่นักวิเคราะห์ข้อมูลโดยทั่วไปเข้าใจได้ง่ายกว่าในรูปแบบของ decision tree ในรูปที่ 5.13 หรือรูปแบบ sigmoid functions ในรูปที่ 5.14 นอกจากแปลงรูปแบบ โน๊มเดลข้อมูลให้เข้าใจได้ง่ายแล้ว งานวิจัยนี้ยังได้เพิ่มเทคนิคของการกลั่นกรอง โน๊มเดลให้มีขนาดเด็กลง ทั้งนี้เพื่อความสะดวกในการแปลงผลและนำไปใช้งาน งานวิจัยนี้ได้อ่านวิเคราะห์ความต่างด้านการใช้งาน โน๊มเดลที่ได้รับการกลั่นกรองแล้วด้วยการจัดสร้างฐานความรู้โดยอัตโนมัติจาก โน๊มเดลข้อมูล และสร้าง expert system shell ที่ผู้ใช้สามารถสอบถาม โน๊มเดลข้อมูลที่อยู่ในฐานความรู้ได้อย่างสะดวก ตัวอย่างของ

ฐานความรู้ที่สร้างจากข้อมูล post-operative patients และกตัญกรองไว้จะพำนีไม่เดลที่มีค่าความน่าจะเป็นสูงกว่า 0.05 แสดงได้ดังรูปที่ 5.15 และแสดงการใช้ expert system shell สอบถามไม่เดลข้อมูลนี้ในรูปที่ 5.16

```

type(ward,0.1) :- comfort(10), bloodPressure(high), surfaceTemp(low).
type(ward,0.07142) :- comfort(10), bloodPressure(mid), surfaceTemp(low), bpStability(stable).
type(ward,0.07142) :- comfort(10), bloodPressure(mid), surfaceTemp(high), bpStability(mod_stable).
type(ward,0.05714) :- comfort(10), bloodPressure(high), surfaceTemp(mid), bpStability(mod_stable).
type(ward,0.04285) :- comfort(15), bpStability(unstable), surfaceTemp(mid).
type(ward,0.04285) :- comfort(10), bloodPressure(mid), surfaceTemp(mid), bpStability(stable),
internalTemp(mid), tempStability(unstable).
type(ward,0.04285) :- comfort(10), bloodPressure(low).
type(ward,0.02857) :- comfort(15), bpStability(unstable), surfaceTemp(high).
type(ward,0.02857) :- comfort(15), bpStability(stable), internalTemp(mid), surfaceTemp(mid).
type(ward,0.02857) :- comfort(15), bpStability(mod_stable).
type(home,0.02857) :- comfort(10), bloodPressure(mid), surfaceTemp(mid), bpStability(mod_stable).
type(ward,0.02857) :- comfort(10), bloodPressure(high), surfaceTemp(mid),
bpStability(stable), oxygenSaturation(excellent).

```

รูปที่ 5.15 ไม่เดลของข้อมูล post-operative patients ที่มีค่าความน่าจะเป็นสูงกว่า 0.02

```

SWI-Prolog - c:\Documents and Settings\Nittaya\Desktop\expertshe11.pl
File Edit Settings Run Debug Help
% c:/Documents and Settings/Nittaya/Desktop/expertshe11.pl compiled 0.00 sec. 6,620 bytes
Welcome to SWI-Prolog (Multi-threaded, 32 bits, Version 5.7.11)
Copyright (c) 1990-2009 University of Amsterdam.
SWI-Prolog comes with ABSOLUTELY NO WARRANTY. This is free software,
and you are welcome to redistribute it under certain conditions.
Please visit http://www.swi-prolog.org for details.

For help, use ?- help(Topic). or ?- apropos(Word).

1 ?- expertshe11.
This is the Easy Expert System shell.
Type help, load, solve, why, quit, or 99.
at the prompt.
expert-shell> load.
Enter file name in single quotes (ex. '1.knb'): '1.knb'.
% 1.knb compiled 0.00 sec. 4,844 bytes
expert-shell> solve.

What is the value for comfort?
[1-high, 2-mid, 3-low, 99-exitShell]
Enter the choice> 3.

What is the value for bloodPressure?
[1-high, 2-mid, 3-low, 99-exitShell]
Enter the choice> 3.
The answer is _ward_ with probability 0.0428571
expert-shell> why.

The answer is ...ward... with probability = 0.0428571.
The known storage are
[bloodPressure(low), comfort(10)]
expert-shell>

```

รูปที่ 5.16 การใช้ expert system shell สอบถามไม่เดลข้อมูล

### ข้อเสนอแนะ

(1) โปรแกรมสร้างโมเดลข้อมูลที่พัฒนาขึ้นนี้มีข้อกำหนดเกี่ยวกับชนิดข้อมูล โดยข้อมูลที่ใช้จะต้องเป็นชนิด nominal หรือ categorical ถ้าข้อมูลใดเป็นจำนวนเลข (numeric) จะต้องแปลงตัวเลขให้เป็นข้อความ และการจำแนกคลาสของข้อมูลเป็นชนิด binary classification ดังนั้นแนวทางการปรับปรุงงานวิจัยนี้ต่อไปคือพัฒนาวิธีการจำแนกข้อมูลให้เป็นแบบหลายคลาส หรือ multi-class classification และเพิ่มฟังก์ชันการแปลงชนิดข้อมูลจากจำนวนเลขเป็นช่วงของค่า (interval)

(2) การสร้างกฎการตัดสินใจในงานวิจัยนี้สร้างจาก classification rules ทั้งนี้โมเดลที่ได้การดำเนินข้อมูลประเภทอื่น เช่น clustering model, association model สามารถแปลงให้เป็นกฎการตัดสินใจได้เช่นเดียวกัน

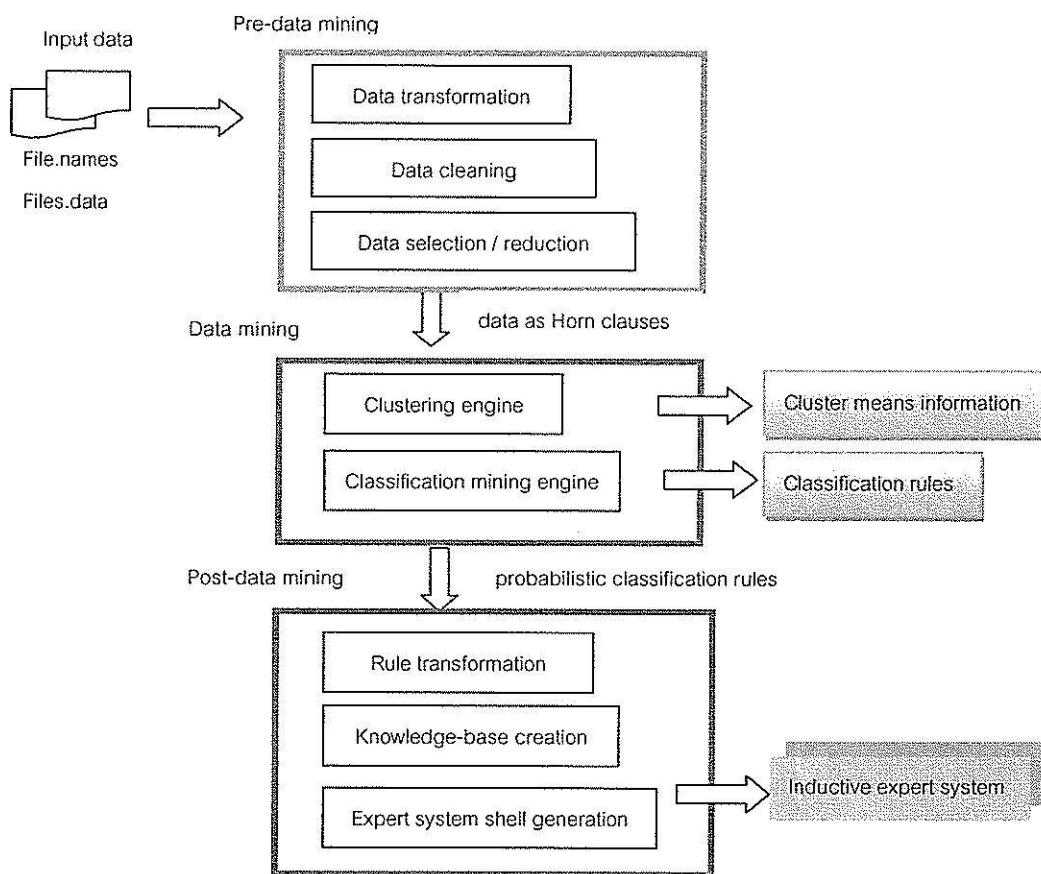
(3) จากแนวทางการลดขนาดของโมเดล ด้วยการใช้เฉพาะกฎการตัดสินใจที่มีค่าความน่าจะเป็นสูง จะทำให้ได้โมเดลที่มีจำนวนกฎน้อย แต่ผลที่อาจตามมาคือกฎที่ถูกกัดเลือกไว้อาจจะมีเงื่อนไขการพิจารณาไม่ครบถ้วนทำให้โมเดลไม่สมบูรณ์ หรือกฎบางส่วนอาจขัดแย้งกัน แนวทางแก้ไขปัญหากรณีเงื่อนไขไม่ครบถ้วนคือจะต้องมี default rule เครื่อยมไว้ ส่วนในการกรณีกฎขัดแย้งอาจใช้วิธีการโหวตจากทุกกฎที่เกี่ยวข้อง จากนั้นใช้ค่าที่มีรายเป็นค่าส่วนใหญ่จากผลโหวต

## บทที่ 6

### บทสรุป

#### 6.1 ลักษณะเด่นของระบบ SUT Miner

ระบบเหมืองข้อมูล SUT Miner ประกอบขึ้นจากโมดูลต่างๆ เพื่อทำหน้าที่ในส่วน pre-data mining, data mining และ post-data mining โดยมีโมดูลหลักในระบบเหมืองข้อมูลแต่ละส่วนแสดงได้ดังรูปที่ 6.1



รูปที่ 6.1 ระบบเหมืองข้อมูล SUT Miner และโมดูลหลักในแต่ละส่วน

ข้อมูลที่เป็นอินพุตเข้ามาในระบบเหมืองข้อมูล จะเป็นชุดข้อมูลที่ประกอบด้วยไฟล์สองชนิดคือ names file และ data file ซึ่งลักษณะไฟล์แบบนี้เป็นรูปแบบปกติของข้อมูลใน UCI repository ระบบเหมืองข้อมูล SUT Miner จะเริ่มต้นทำงานด้วยส่วน Pre-data mining (หรือ preprocessing) ที่ทำหน้าที่รวมทั้งสองไฟล์แล้วแปลงรูปแบบไฟล์ให้อยู่ในลักษณะคล่อง畅 ไปปรับรีอก ในส่วน Pre-data mining ยังมีโมดูล Data cleaning และ Data selection/reduction ทำหน้าที่

จัดการกับ missing values และลดขนาดข้อมูลด้วยการคัดเลือกແອທทริบิวต์ และสุ่มเลือกข้อมูล ตัวแทน เทคนิคการสุ่มจะมีทั้งการสุ่มแบบปักติ (simple random sampling with/without replacement) และการสุ่มตามความหนาแน่น density-biased sampling

ส่วนที่ทำหน้าที่ค้นหาโมเดลจากข้อมูล คือส่วน Data mining ที่ประกอบด้วย Clustering engine (โมดูลทำเหมือนข้อมูลแบบจัดกลุ่ม) และ Classification mining engine (โมดูลทำเหมือนข้อมูลแบบจำแนก)

โมดูลทำเหมือนข้อมูลแบบจัดกลุ่มพัฒนาจากอัลกอริทึม incremental k-means clustering ซึ่งเป็นการจัดกลุ่มข้อมูลแบบเพิ่มพูน เพื่อให้สามารถรองรับข้อมูลขนาดใหญ่ได้ ผลลัพธ์ที่ได้จากโมดูลนี้คือ ค่าตัวแทนกลุ่ม (cluster means) และกลุ่มข้อมูล (clusters)

ในส่วนของการทำเหมือนข้อมูลแบบจำแนก จะแสดงโมเดลที่เป็นผลลัพธ์ของโมดูลนี้ได้ ในสองรูปแบบคือ โมเดลในลักษณะของต้นไม้ตัดสินใจ และโมเดลในลักษณะของกฎการตัดสินใจ โดยส่วนสร้างกฎการตัดสินใจจะมีฟังก์ชันให้ผู้ใช้สามารถระบุการสร้างกฎ ให้สร้างเฉพาะกฎการตัดสินใจที่มีค่าความน่าจะเป็นสูง (probabilistic decision rules) ที่จะสามารถประยุกต์ใช้โมเดลกับข้อมูลในอนาคต

Probabilistic decision rules ที่ได้จากโมเดลทำเหมือนข้อมูลแบบจำแนก จะถูกส่งต่อไปยังส่วน Post-data mining (หรือ postprocessing) เพื่อเปลี่ยนกฎการตัดสินใจให้เป็นความรู้ในฐานความรู้ของระบบผู้เชี่ยวชาญ ความรู้นี้จะถูกสร้างด้วยกระบวนการอัตโนมัติในโมดูล Expert system shell generation และถูกผนวกเข้าเป็นส่วนหนึ่งของ expert system shell ของระบบผู้เชี่ยวชาญ กระบวนการนี้จะช่วยให้ผู้ใช้สามารถเรียกกฎผลลัพธ์ของการทำเหมือนข้อมูลกับข้อมูลอินพุตผ่านระบบผู้เชี่ยวชาญ ซึ่งจะทำความเข้าใจได้ง่ายกว่าการพิจารณาโดยตรงจากโมเดลในลักษณะต้นไม้ตัดสินใจที่เป็นผลลัพธ์จากโมดูลทำเหมือนข้อมูล

เมื่อเปรียบเทียบกับระบบเหมือนข้อมูลในปัจจุบัน เช่น WEKA (Hall et al, 2009) ระบบ SUT Miner จะมีความสามารถที่สูงกว่าในด้านการผนวกผลลัพธ์ของการทำเหมือนข้อมูลแบบจำแนกให้เข้าสู่ฐานความรู้ของระบบผู้เชี่ยวชาญได้โดยอัตโนมัติ ความสามารถในด้านนี้เกิดขึ้นได้จากการที่ระบบเหมือนข้อมูล SUT Miner พัฒนาขึ้นด้วยภาษาโปรแกรมล็อก ที่หมายความกับงาน rule processing และการค้นหาคำต้องห้ามด้วยเทคนิค backtracking

## 6.2 ข้อจำกัดของระบบ SUT Miner

ระบบเหมือนข้อมูล SUT Miner ได้รับการพัฒนาขึ้นในลักษณะของ rapid prototyping เพื่อให้สามารถทดสอบความถูกต้องของข้อตกลงใหม่ที่พัฒนาขึ้น (ได้แก่อัลกอริทึม density-

biased sampling, probabilistic rule induction, incremental k-means clustering และ expert system shell generation) ภายในเวลาที่รวดเร็ว เนื่องจากระบบเหมือนข้อมูล SUT Miner ยังเป็นโปรแกรมด้านแบบ จึงบังเมื่อจำต้องใช้ภาษาอังกฤษในการเขียนโปรแกรม แต่ส่วนติดต่อกับผู้ใช้ยังขาดลักษณะของ graphical user interface, ข้อมูลที่จะนำเข้ายังระบบต้องอยู่ในหน่วยความจำหลัก ดังนั้นขนาดของข้อมูลที่ระบบรองรับได้จะขึ้นอยู่กับขนาดหน่วยความจำของเครื่องคอมพิวเตอร์, รูปแบบของข้อมูลเข้ายังจำต้องมีเฉพาะรูปแบบที่ใช้โดย UCI repository, ยังขาดฟังก์ชันในการวิเคราะห์แอ็พทริบิวต์ เช่น principal component analysis

### 6.3 ข้อเสนอแนะและแนวทางการพัฒนาในอนาคต

ระบบเหมือนข้อมูล SUT Miner ที่พัฒนาขึ้นนี้ยังสามารถปรับปรุงให้มีความสามารถสูงขึ้นในด้านต่างๆ ดังนี้

- (1) การคัดเลือกแอ็พทริบิวต์ข้อมูลในงานวิจัยนี้ ใช้วิธีแสดงการกระจายค่าของข้อมูลในลักษณะของอิสโทแกรม จากนั้นให้ผู้ใช้กำหนดว่าจะคัดเลือกแอ็พทริบิวต์ใดบ้าง ในส่วนนี้สามารถพัฒนาให้ดีขึ้นได้โดยการเพิ่มเทคนิคการพิจารณาความเหมาะสมของแอ็พทริบิวต์ (เช่น ค่านิยม gain value) จากนั้นแสดงคำแนะนำให้ผู้ใช้ตัดสินใจว่าควรจะเลือกแอ็พทริบิวต์ใด
- (2) โมดูลทำเหมือนข้อมูลแบบจัดกลุ่ม เน้นการจัดกลุ่มข้อมูลที่มีชนิดข้อมูลเป็นข้อความ (nominal, categorical) การจัดกลุ่มข้อมูลที่แอ็พทริบิวต์มีค่าเป็นจำนวนเลข สามารถทำได้โดยปรับปรุงซอฟต์แวร์นี้เพียงเล็กน้อย แต่ถ้าค่าตัวเลขไม่สามารถแบ่งช่วงค่าที่เป็นไปได้กว้างมาก เช่นในกรณีแอ็พทริบิวต์อายุ ที่มีค่าอยู่ระหว่าง 0-120 ควรเพิ่มฟังก์ชัน normalization เช่นใช้เทคนิค max-min normalization หรือ z-score standardization เพื่อปรับลดช่วงกว้างของค่าสูงสุด-ต่ำสุด ทั้งนี้เพื่อลด bias ของการคำนวณค่า mean ของกลุ่มข้อมูล
- (3) โมดูลทำเหมือนข้อมูลแบบจำแนกมีแนวทางการลดขนาดของโมเดล ด้วยการใช้เทคนิคการตัดสินใจที่มีค่าความน่าจะเป็นสูง จะทำให้ได้โมเดลที่มีจำนวนกฎน้อย แต่ผลที่อาจตามมาคือกฎที่ถูกคัดเลือกไว้อาจจะมีเงื่อนไขการพิจารณาไม่ครบถ้วน ทำให้โมเดลไม่สมบูรณ์ หรือกฎบางส่วนอาจขัดแย้งกัน แนวทางแก้ไขปัญหากรณีเงื่อนไขไม่ครบถ้วนคือจะต้องมี default rule เตรียมไว้ ส่วนในกรณีที่กฎขัดแย้งอาจใช้วิธีการโหวตจากทุกกฎที่เกี่ยวข้อง จากนั้นใช้ค่าทำนายเป็นค่าส่วนใหญ่จากผลโหวต

- (4) การสร้างกฎการตัดสินใจในงานวิจัยนี้สร้างจาก classification rules ทั้งนี้ไม่เดลที่ได้ทำการทำเหมือนข้อมูลประเภทอื่น เช่น clustering model, association model ความสามารถแปลงให้เป็นกฎที่มีลักษณะคล้ายกฎการตัดสินใจได้ เช่นเดียวกัน
- (5) การทำเหมือนข้อมูลเป็นกระบวนการที่ต้องมีการทำซ้ำหลายครั้ง ทำให้ใช้เวลาในการประมวลผลค่อนข้างสูง โดยเฉพาะเมื่อข้อมูลมีขนาดใหญ่ การปรับปรุงในส่วนนี้อาจใช้วิธีการประมวลผลแบบขนาน และใช้วิธีการประมวลผลแบบหดหายหน่วยประมวลผล (multi-core programming) ซึ่งแนวทางนี้จะเป็นแนวทางที่ผู้วิจัยเลือกใช้เพื่อพัฒนาระบบที่มีองค์ความรู้ SUT Miner ให้มีประสิทธิภาพสูงขึ้นในเรื่องรับต่อไป

## បរទានអង្គម

- G. Adomavicius & A. Tuzhilin (2001). Expert-driven validation of rule-based user models in personalization applications. *Journal of Data Mining and Knowledge Discovery*, 5(1/2): 33-58.
- D.W. Aha (1992). Tolerating noisy, irrelevant and novel attributes in instance-based learning algorithms. *International Journal of Man-Machine Studies*, 36(1), 267-287.
- D.P. Ballou & G.K. Tayi (1999). Enhancing data quality in data warehouse environments. *Communications of ACM*, 42, 73-78.
- D. Barbara, W. DuMouchel, C. Faloutsos, P.J. Haas, J.H. Hellerstein, Y. Ioannidis, H.V. Jagadish, T. Johnson, R. Ng., V. Poosala, K.A. Ross, & K.C. Serveik (1997). The New Jersey data reduction report. *Bulletin of the Technical Committee on Data Engineering*, 20, 3-45.
- R.J. Bayardo, R. Agrawal, & D. Gunopulos (1999). Constraint-based rule mining in large, dense databases. In *Proceedings of the 15<sup>th</sup> International Conference on Data Engineering*.
- C. Blake, E. Keogh, & C.J. Merz (1998). UCI Repository of machine learning databases, Department of Information and Computer Science, University of California, Irvine. [<http://www.ics.uci.edu/~mlearn/MLRepository.html>]
- L. Breiman, J. Friedman, R. Olshen, & C. Stone (1984). *Classification and Regression Trees*. Monterey, CA: Wadsworth International Group.
- S. Brin, R. Motwani, J.D. Ullman, & S. Tsur (1997). Dynamic itemset counting and implication rules for market basket data. In *Proceedings of the ACM SIGMOD Conference*.
- P. Clark and S. Matwin (1993). Using qualitative models to guide induction learning. In *Proceedings of the International Conference on Machine Learning*.
- M. Dash & H. Liu (1997). Feature selection methods for classification. *Intelligent Data Analysis: An International Journal*, 1.
- M. Dash, H. Liu, & J. Yao (1997). Dimensionality reduction of unsupervised data. In *Proceedings of 9<sup>th</sup> IEEE International Conference on Tools with AI (ICTAI)*, 532-539.

- J. Devore & R. Peck (1997). *Statistics: The Exploration and Analysis of Data*. New York: Duxbury Press.
- W.J. Frawley, G. Piatetsky-Shapiro, & C.J. Matheus (1991). Knowledge discovery in databases: an overview. In G.Piatetsky-Shapiro and W.J. Frawley (Eds.), *Knowledge Discovery in Databases*, AAAI/MIT Press.
- J.H. Friedman (1977). A recursive partitioning decision rule for nonparametric classifiers. *IEEE Transactions on Computing*, 26, 404-408.
- J. Han & M. Kamber (2001). *Data Mining: Concepts and Techniques*. San Francisco: Morgan Kaufmann.
- M. Hall, E. Frank, G. Holmes, B. Pfahringer, P. Reutemann, & I. Witten (2009). The WEKA data mining software: An update. *SIGKDD Explorations*, 11(1), 10-18.
- G.H. John & P. Langley (1996). Static versus dynamic sampling for data mining. In *Proceedings 1996 International Conference on Knowledge Discovery and Data Mining (KDD'96)*, 367-370.
- K. Josien, G. Wang, T.W. Liao, E. Triantaphyllou, & M.C. Liu (2001). An evaluation of sampling methods for data mining with fuzzy c-means. In *Data Mining for Design and Manufacturing*, Chapter 15, 351-365. Kluwer Academic Publishers.
- R.L. Kennedy, Y. Lee, B. Van Roy, C.D. Reed, & R.P. Lippman (1998). *Solving Data Mining Problems Through Pattern Recognition*. Upper Saddle River, NJ:Prentice Hall.
- J. Kivinen & H. Mannila (1994). The power of sampling in knowledge discovery. In *Proceedings 13<sup>th</sup> ACM Symposium on Principles of Database Systems*, 77-85.
- M. Klemettinen, H. Mannila, P. Ronkainen, H. Toivonen, and A.I. Verkamo (1994). Finding interesting rules from large sets of discovered association rules. In *Proceedings of the Third International Conference on Information and Knowledge Management*.
- R. Kohavi & G.H. John (1997). Wrappers for feature subset selection. *Artificial Intelligence*, 97, 273-324.
- P. Langley, W. Iba, & K. Thompson (1992). An analysis of bayesian classifiers. *Proceedings of the 10<sup>th</sup> National Conference on Artificial Intelligence*, 223-228.