

algorithm เพื่อแปลงข้อมูลและวัดความหนาแน่นของข้อมูลในแต่ละ window ข้อมูลที่ถูกแปลงแล้วแต่ยังไม่มีการสุ่มเพื่อลดขนาดข้อมูล จะถูกส่งไปยังโปรแกรม k-means เพื่อทดสอบผลการจัดกลุ่ม ในขณะเดียวกันข้อมูลที่ถูกแปลงและวัดความหนาแน่นแล้วจะถูกส่งต่อไปยังโมดูล Sampling techniques เพื่อทดสอบวิธีการสุ่มในแบบต่างๆ ซึ่งประกอบด้วย

- Simple random sampling เป็นวิธีการสุ่มเลือกข้อมูลอย่างง่าย โดยไม่มีการพิจารณาความหนาแน่นของข้อมูล
- Density-biased sampling เป็นวิธีการสุ่มเลือกข้อมูล โดยคัดเลือกจากข้อมูลที่มีความหนาแน่นถึงเกณฑ์ที่กำหนด โดยมีการใช้โครงสร้างข้อมูลประกอบกับเทคนิคการคัดเลือกข้อมูลดังนี้
 - Hashing ใช้น่อที่เก็บข้อมูลขนาดใหญ่ (ด้วยสมมติฐานว่าข้อมูลที่ความหนาแน่นถึงเกณฑ์ทั้งหมด สามารถเก็บลงตารางแข็งได้) และมีวิธีการเข้าถึงข้อมูลโดยตรง
 - Reservoir + Hashing ใช้น่อที่เก็บข้อมูลที่มีขนาดจำกัด (ด้วยโครงสร้างข้อมูลแบบແຕກລຳນັ້ນທີ່ເຮັດວຽກ reservoir) และมีวิธีการเข้าถึงข้อมูลได้โดยตรง (วິທີນີ້ເປັນເຫດີນີກແບບເດືອກກັບທີ່ Palmer ແລະ Faloutsos (2000) ໃຊ້ໃນງານວິຈີຍ)
 - Reservoir + Simple random sampling (SRS) ใช้น่อที่เก็บข้อมูลที่มีขนาดจำกัด และใช้วิธีการคัดเลือกข้อมูลเพื่อเก็บลง reservoir แบบการสุ่มอย่างง่าย
 - Reservoir + Rejection sampling ใช้น่อที่เก็บข้อมูลที่มีขนาดจำกัด และใช้การสุ่มสองครั้ง (rejection sampling) เพื่อพิจารณาว่าจะทิ้งข้อมูล หรือจะเก็บข้อมูลลงเนื้อที่ reservoir

ข้อมูลที่ได้รับการสุ่มเลือกด้วยเทคนิคต่างๆ กัน จะถูกนำไปจัดกลุ่มด้วยโปรแกรม k-means เพื่อพิจารณาค่า cluster means ที่เป็นผลลัพธ์ของการจัดกลุ่ม เปรียบเทียบกับค่า real centroids เทคนิคการสุ่มเลือกที่ศึกษาจะต้องให้ผลลัพธ์การจัดกลุ่มที่เบี่ยงเบนไปจาก real centroids น้อยที่สุด ชุดคำสั่งในภาษาເຂົ້າແຂງແລ້ວໆທີ່ກໍານົດທີ່ສຸມข้อมูลตามความหนาแน่นແດດงໄດ້ ดັ່ງຮູບທີ່ 2 ແລະ ໂປຣແກຣມສຸມข้อมูลດ້ວຍອັດກອຣີ໌ກິ່ນ k-means ແສດງໄດ້ດັ່ງຮູບທີ່ 3

```
%== Density-biased sampling
% Firstly, generate back from slidingWindows -> POINTS
genWin2P([])->[];
genWin2P([(P,Den)|T])-> if Den>=1 -> dup(center(P),Den)++genWin2P(T);
                           true -> genWin2P(T)
                           end.
%--- Then, select sampling technique as: Hash-based sampling
specificDensBin(Bin,L,Den) -> take(Bin,specificDens(L,Den)).
specificDens([],_)->[];
specificDens([(P,D)|T],Den)-> if D>=Den -> [(P,D)|specificDens(T,Den)];
                                         true -> specificDens(T,Den)
                                         end.
%--- Or: Simple Random with density bias
simpleRandom(_,_,-1)->[];
simpleRandom(WindowL,Dens,Bin)->
  Nth=random:uniform(length(WindowL)),
  {P,D}=lists:nth(Nth,WindowL),
  if D>=Dens -> [{P,D}|simpleRandom(WindowL,Dens,Bin-1)] ;
    true-> simpleRandom(WindowL,Dens,Bin)
  end.
%--- Or: Rejection sampling with density bias
rejectionRandom(_,_,-1)->[];
rejectionRandom(Para,WindowL,Dens,Bin)->
  Nth=random:uniform(length(WindowL)),
  Par=random:uniform(),
  {P,D}=lists:nth(Nth,WindowL),
  if (0.5-Par)<Par, Par<=(0.5+Para),D>=Dens ->
    [{P,D}|rejectionRandom(Para,WindowL,Dens,Bin-1)] ;
    true-> rejectionRandom(Para,WindowL,Dens,Bin)
  end.
% -----
```

ຮູບທີ່ 2. ชຸດคำສັ່ງການເຂົ້າແຂງແລ້ວໆທີ່ກໍານົດທີ່ສຸມข้อมูลตามความหนาแน่น

```

kMeans(PL)-> {_ ,N)=read('enter number of clustering'),
    CL=take(N,sets:to_list(sets:from_list(PL))), %initial centroid
    clustering(1,CL,PL).

take(0,_)->[]; % take first distinct-n element of list
take(N,[H|T])->[H|take(N-1,T)].
clustering(N,CL,PL)->
    L1= lists:map( fun(A) -> nearCentroid(A,CL) end ,PL),
    L2 = transform(CL,L1),
    NewCentroid = lists:map(fun({_ ,GL})-> findMeans(GL) end, L2),
    N1= N+1,
    if NewCentroid==CL -> NewCentroid; % return new centroid
        N>=90 -> NewCentroid; % max iterations=90
        true -> clustering(N1,NewCentroid,PL)
    end.
nearCentroid(Point,CentroidL)->
    LenList=lists:zip(lists:map(fun(A)-> distance(Point,A) end,CentroidL),CentroidL),
    [{_,Centroid}|_]=lists:keysort(1,LenList),
    {Point,Centroid}.

% transform Point-CentroidList to Centroid-PointList
transform([],_)->[];
transform([C|TC],PC)->[{C,t1(C,PC)} | transform(TC,PC)].
t1( ,[])->[] ;
t1(C1,[H|T])->{P,C}=H,
    if C1==C -> [P|t1(C1,T)];
        C1=/=C -> t1(C1,T)
    end.
% compute Euclidean distance
distance([],[])-> 0;
distance([X1|T1],[X2|T2])-> math:sqrt((X2-X1)*(X2-X1)+distance(T1,T2) ) .

% findMeans([[1,2],[3,4]]) --> [2.0,3.0]
findMeans(PointL) ->[H|_]=PointL ,Len=length(H),
    AllDim=lists:reverse(allDim(Len,PointL)),
    lists:map(fun(A)-> mymean(A) end, AllDim ).
mymean(L)->lists:sum(L)/length(L).

allDim(0,_)->[];
allDim(D,L)->[eachDimList(D,L)|allDim(D-1,L)].
eachDimList( ,[] ) ->[];
eachDimList(N,[H|T]) ->[lists:nth(N,H)|eachDimList(N,T)].
% -----

```

รูปที่ 3. โปรแกรม k-means clustering ในรูปแบบของภาษา Erlang

ผลการทดลองและวิจารณ์

การทดสอบโปรแกรมของโครงการวิจัยนี้ มีวัตถุประสงค์หลักเพื่อการทดสอบประสิทธิภาพของโปรแกรมสุ่มข้อมูลตามความหนาแน่นทั้ง 4 เทคนิคได้แก่ (1) Density-biased sampling: hashing (unlimited number of bins), (2) Density-biased sampling: reservoir and hashing, (3) Density-biased sampling: reservoir and simple random sampling, และ (4) Density-biased sampling: reservoir and rejection sampling และเพื่อความสมบูรณ์ในการเปรียบเทียบ ผู้วิจัยได้เพิ่มเติมการจัดกลุ่มข้อมูลกับข้อมูลที่ถูกสุ่มอย่างง่าย โดยไม่มีการพิจารณาค่าความหนาแน่นและไม่ต้องมีการแบ่งข้อมูลด้วยเทคนิค window sliding โดยกำหนดขนาดและจำนวนของ bin หรือเนื้อที่เก็บข้อมูลในโครงสร้าง reservoir ให้เท่ากันที่ใช้ในเทคนิคที่ (2), (3) และ (4) ส่วนในเทคนิคที่ (1) จะใช้จำนวน bin ให้มากที่สุดเท่าที่เนื้อที่หน่วยความจำหนึ่งจะจัดสรรให้ได้ ทั้งนี้เพื่อใช้เป็นเกณฑ์เปรียบเทียบประสิทธิภาพการใช้เนื้อที่หน่วยความจำกับเทคนิคที่ (2)-(4)

การจัดกลุ่มตามความหนาแน่น มีวัตถุประสงค์ที่จะพัฒนาเทคนิคการจัดกลุ่มกับข้อมูลขนาดใหญ่ที่สามารถพัฒนาต่อไปให้จัดการกับข้อมูลสตรีมได้ ดังนั้นเทคนิคการสุ่มและการจัดกลุ่มที่ดี จะต้องใช้เนื้อที่หน่วยความจำต่ำ แต่ให้ผลการจัดกลุ่มที่คล้ายเดลีอันไปจากกลุ่มที่แท้จริงเป็นระยะทางน้อยที่สุด ดังนั้นการสรุปผลเทคนิคต่างๆที่ใช้ในการจัดกลุ่ม กำหนดเกณฑ์ในการเปรียบเทียบว่าแต่ละเทคนิคจะต้องใช้หน่วยความจำไม่มากกว่า 30% ของหน่วยความจำที่โปรแกรม k-means ใช้ในการ

จัดกลุ่มข้อมูลสังเคราะห์ทั้งหมด เช่น ถ้าการรัน k-means กับข้อมูลทั้งหมดใช้หน่วยความจำ 4,800 ไบต์ เทคนิคการสุ่มและการจัดกลุ่มจะต้องใช้หน่วยความจำไม่เกิน 1,440 ไบต์ ผลการเปรียบเทียบความถูกต้องของการจัดกลุ่มข้อมูลแสดงได้ดังตารางที่ 1 โดยค่าความคลาดเคลื่อนที่แสดงในตารางเป็นค่าเฉลี่ยจากการทดสอบในทุกค่า density และทุกค่า bin เครื่องหมาย '-' ที่ปรากฏในตารางหมายถึงเทคโนโลยีนั้นๆ ใช้หน่วยความจำมากกว่าเกณฑ์ขั้นต่ำที่กำหนด จึงไม่สามารถนำผลการจัดกลุ่มมาเปรียบเทียบร่วมกับเทคนิคอื่นๆ ได้

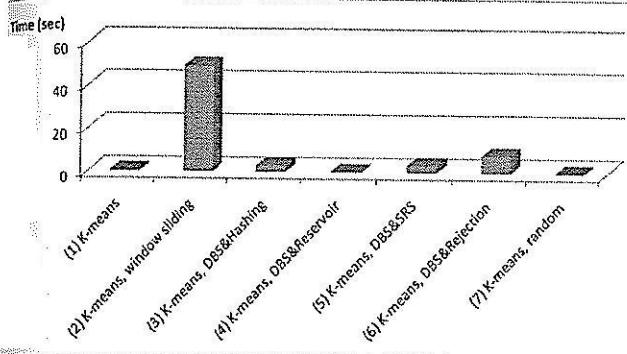
ตารางที่ 1. การเปรียบเทียบค่าความคลาดเคลื่อนของกลุ่มข้อมูลเมื่อใช้เทคนิคการสุ่มแต่ละแบบ

ลักษณะของข้อมูล	K-means, DBS &Hashing	K-means, DBS &Reservoir	K-means, DBS&SRS	K-means, DBS &Rejection	K-means, random
ข้อมูลกระจายสม่ำเสมอ					
ขนาดเล็ก 2 มิติ, 4 กลุ่ม	--	--	6.067	6.029	4.552
2 มิติ, 8 กลุ่ม	--	10.739	14.661	16.471	13.930
3 มิติ, 4 กลุ่ม	--	8.032	9.479	10.723	8.709
3 มิติ, 8 กลุ่ม	--	55.889	26.051	25.071	31.979
ขนาดใหญ่ 2 มิติ, 4 กลุ่ม	--	3.557	6.600	6.800	13.520
2 มิติ, 8 กลุ่ม	--	15.22	13.721	15.385	15.446
3 มิติ, 4 กลุ่ม	--	--	--	--	44.721
3 มิติ, 8 กลุ่ม	--	48.965	29.364	31.560	20.318
ข้อมูลกระจายแบบชิฟ					
ขนาดเล็ก 2 มิติ, 4 กลุ่ม	--	20.377	15.098	14.124	14.634
2 มิติ, 8 กลุ่ม	--	27.889	23.689	23.350	24.704
3 มิติ, 4 กลุ่ม	--	45.873	16.320	17.525	17.589
3 มิติ, 8 กลุ่ม	--	90.360	33.534	34.580	34.083
ขนาดใหญ่ 2 มิติ, 4 กลุ่ม	--	37.888	18.310	15.228	19.528
2 มิติ, 8 กลุ่ม	--	32.780	31.408	30.598	35.520
3 มิติ, 4 กลุ่ม	--	30.481	11.709	13.003	14.503
3 มิติ, 8 กลุ่ม	--	39.551	27.707	28.434	32.479

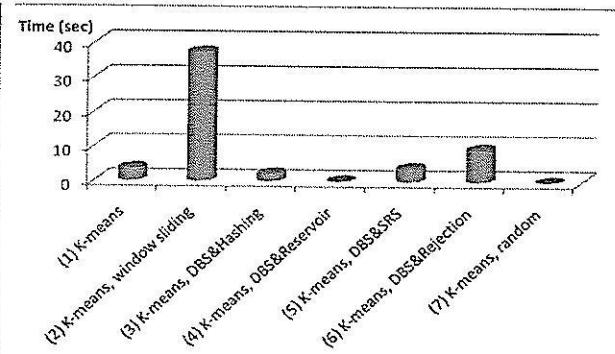
เมื่อพิจารณาจากผลการทดลองตามตารางที่ 1 จะเห็นได้ว่าเทคนิค K-means, DBS & Hashing เมื่อทดสอบกับข้อมูลทุกชุด ปรากฏผลเป็นเครื่องหมาย '-' ทั้งนี้เนื่องจากเทคโนโลยีไม่มีข้อกำหนดเกี่ยวกับจำนวน bin ทำให้ใช้หน่วยความจำมากกว่าเกณฑ์ที่ตั้งไว้ จากการเปรียบเทียบค่าความคลาดเคลื่อนของกลุ่มข้อมูล จะเห็นได้ว่าเมื่อกลุ่มข้อมูลมีการกระจายแบบสม่ำเสมอและเป็นข้อมูลขนาดเล็ก เทคนิค K-means, DBS&Reservoir ที่ใช้การเข้าถึงข้อมูลแบบหยาดให้ผลลัพธ์ที่ดี แต่สำหรับข้อมูลขนาดใหญ่เทคนิค K-means, random จะให้ผลลัพธ์การจัดกลุ่มที่ดี ในกรณีที่ข้อมูลกระจายแบบชิฟและเป็นข้อมูลขนาดสองมิติ เทคนิค K-means, DBS& Rejection จะให้ผลลัพธ์การจัดกลุ่มที่ดี แต่เมื่อข้อมูลเพิ่มขนาดเป็นสามมิติ เทคนิค K-means, DBS& SRS จะให้ผลลัพธ์การจัดกลุ่มที่ดีกว่า

การเปรียบเทียบเวลาในการประมวลผล จำนวนเวลาห้าวในการขั้นตอนการจัดกลุ่มของทั้ง 7 เทคนิค ประกอบด้วย (1) K-means, (2) K-means, window sliding, (3) K-means, DBS&Hashing, (4) K-means, DBS&Reservoir, (5) K-means, DBS&SRS, (6) K-means, DBS&Rejection และ (7) K-means, random

การแสดงผลทดสอบเบรี่ยบเทียบเวลาและการใช้เนื้อที่หน่วยความจำในรูปที่ 4 และ 5 ตามลำดับ จะแสดงเฉพาะกรณีของข้อมูล 3 มิติ เป็นข้อมูลขนาดใหญ่จำนวน 8 กลุ่ม (ข้อมูลลักษณะอื่นๆ ให้มลองคลองเช่นเดียวกัน) โดยแสดงเปรียบเทียบทั้งกรณีข้อมูลกระจายสม่ำเสมอ และข้อมูลกระจายแบบชิฟ

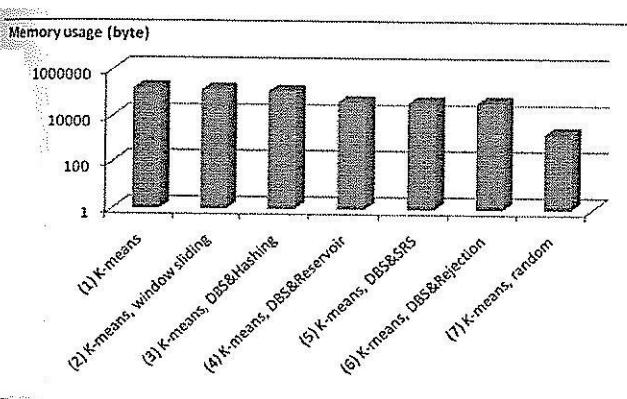


(a) ข้อมูลกระจายแบบ uniform

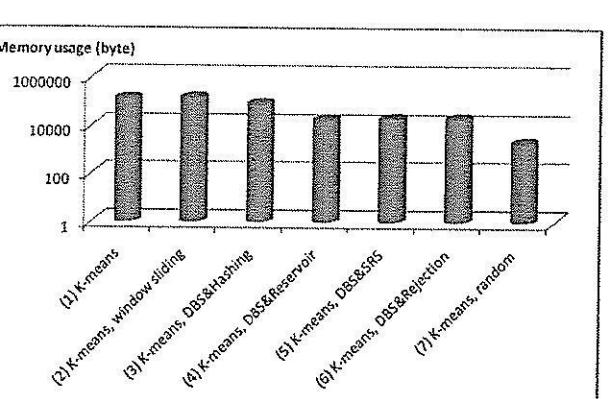


(b) ข้อมูลกระจายแบบ Zipf

รูปที่ 4. เปรียบเทียบเวลาที่ใช้ในการจัดกลุ่มข้อมูล 3 มิติ ขนาดใหญ่และมีจำนวน 8 กลุ่ม



(a) ข้อมูลกระจายแบบ uniform



(b) ข้อมูลกระจายแบบ Zipf

รูปที่ 5. เปรียบเทียบหน่วยความจำที่ใช้ในการจัดกลุ่มข้อมูล 3 มิติ ขนาดใหญ่และมีจำนวน 8 กลุ่ม

บทสรุป

งานวิจัยนี้ศึกษาวิธีการลดขนาดของข้อมูลด้วยเทคนิคการสุ่ม โดยค่าที่ได้ถึงลักษณะการกระจายของข้อมูล ถ้าข้อมูลมีการกระจายอย่างสม่ำเสมอการสุ่มข้อมูลจะให้น้ำหนักข้อมูลทุกตัวเท่าเทียมกัน แต่ถ้าข้อมูลมีการกระจายไม่สม่ำเสมอ เช่นมีการกระจายแบบชิฟ ข้อมูลในบางช่วงมีความหนาแน่นมากกว่าข้อมูลในช่วงอื่นๆ ด้วยสัดส่วนความหนาแน่นที่แตกต่างกันมาก การสุ่มข้อมูลจะเพิ่มโอกาสการถูกสุ่มให้กับข้อมูลในช่วงที่มีความหนาแน่นสูง และเรียกเทคนิคการสุ่มแบบนี้ว่า การสุ่มตามความหนาแน่น (density-biased sampling, DBS) โดยการวัดความหนาแน่นของข้อมูลจะใช้เทคนิคการเลื่อนกรอบหน้าต่าง (window sliding) ซึ่งเป็นกรอบขนาดเล็กที่เคลื่อนไปบนแกนข้อมูลและวัดจำนวนจุดข้อมูลที่ปรากฏภายในแต่ละกรอบ เพื่อบันทึกเป็นค่าความหนาแน่นของกรอบหน้าต่าง การสุ่มตามความหนาแน่นจึงเป็นการคัดเลือกกรอบหน้าต่างที่มีจำนวนจุดภายในกรอบตรงตามเกณฑ์ที่กำหนด จากนั้นใช้พิกัดของกรอบหน้าต่างเหล่านี้สร้างกลับเป็นจุดข้อมูลที่มีจำนวนจุดเท่ากับค่าความหนาแน่นของกรอบหน้าต่าง

งานวิจัยนี้ได้ทดสอบการจัดกลุ่มข้อมูลกับข้อมูลที่ผ่านกระบวนการสุ่ม หังที่เป็นการสุ่มอย่างง่ายที่ไม่มีการพิจารณาความหนาแน่นของข้อมูล และการสุ่มตามความหนาแน่นของข้อมูล ในการทดสอบได้ใช้ข้อมูลสังเคราะห์รวมทั้งหมด 16 ชุด ข้อมูลแบดชุดแรกเป็นข้อมูลสองมิติ และข้อมูลอีกแบดชุดเป็นข้อมูลสามมิติ ในข้อมูลแบดชุดแบ่งย่อยออกเป็นข้อมูลที่มีการกระจายอย่างสม่ำเสมอ จำนวนสี่ชุดที่มีหังข้อมูลขนาดเล็กและข้อมูลขนาดใหญ่ และข้อมูลที่มีการกระจายแบบชิฟ จำนวนสี่ชุด ที่มีหังขนาดเล็กและใหญ่ เช่นเดียวกัน เทคนิคการสุ่มข้อมูลประกอบด้วย (1) DBS: hashing (unlimited number of bins), (2) DBS: reservoir and hashing, (3) DBS: reservoir with simple random sampling, (4) DBS: reservoir with rejection sampling, และ (5) Simple random sampling on the original data set (no window sliding technique)

ผลการทดสอบพบว่าในข้อมูลที่มีการกระจายสม่ำเสมอ เทคนิคที่ 2 และ 5 ให้ผลการจัดกลุ่มที่ค่อนข้างดี กลุ่มข้อมูลที่ได้คาดเดตื่อนไปจากกลุ่มที่แท้จริงเพียงเล็กน้อย แต่มีข้อสังเกตว่าเทคนิคที่ 5 ที่เป็นการสุ่มเลือกข้อมูลแล้วนำข้อมูลนั้นไปจัดกลุ่มด้วยโปรแกรม k-means จะใช้เนื้อที่หน่วยความจำอย่างมากเมื่อเทียบกับเทคนิคอื่นๆ ดังนั้นจึงอาจสรุปได้ว่าเมื่อข้อมูลมีการกระจายสม่ำเสมอ ไม่จำเป็นต้องทำการสุ่มตามความหนาแน่น เพราะเทคนิคนี้จะใช้เวลาและหน่วยความจำมากกว่าการสุ่มข้อมูลแบบปกติ และผลการจัดกลุ่มที่ได้จะไม่ดีเท่ากับอย่างมีนัยสำคัญ แต่ในกรณีที่ข้อมูลมีการกระจายแบบชิฟ นั้นคือข้อมูลในแต่ละกลุ่มมีขนาดเล็ก-ใหญ่ต่างกันมาก และบริมาณข้อมูลในกลุ่มหรือความหนาแน่นก็แตกต่างกันมากเช่นเดียวกัน กรณีเช่นนี้ พบว่าการสุ่มตามความหนาแน่นจะมีผลช่วยให้ข้อมูลที่คัดเลือกมาเพื่อการจัดกลุ่มได้ข้อมูลตัวแทนที่ดี ความหนาแน่นของข้อมูลที่ถูกคัดเลือกใกล้เคียงกับความหนาแน่นที่ปรากฏในกลุ่มข้อมูลดังเดิมที่สังเคราะห์ขึ้น

เทคนิคการสุ่มที่ทำงานได้กับข้อมูลที่กระจายแบบชิฟ คือเทคนิคที่ 3 และ 4 นั้นคือเทคนิคที่มีการวัดความหนาแน่นข้อมูลด้วยการทำ window sliding คัดเลือกข้อมูลด้วยเกณฑ์ความหนาแน่นขั้นต่ำ จากนั้นนำรอบหน้าต่างที่มีความหนาแน่นถึงเกณฑ์แปลงข้อมูลกลับ ให้ได้จำนวนจุดข้อมูลเท่ากับค่าความหนาแน่นของรอบหน้าต่าง ขั้นตอนต่อจากนั้นเป็นการสุ่มเลือกข้อมูลใหม่ปริมาณเท่ากันเนื่องจาก reservoir โดยการสุ่มในขั้นนี้อาจจะเป็นการสุ่มแบบ simple random sampling หรืออาจจะใช้วิธี rejection sampling ก็ได้ ซึ่งจากการทดลองพบว่าให้ผลลัพธ์ที่ใกล้เคียงกัน แต่วิธี simple random sampling จะใช้เนื้อที่หน่วยความจำ และใช้เวลาที่น้อยกว่าเล็กน้อย

กิตติกรรมประกาศ

งานวิจัยนี้ดำเนินการโดยหน่วยวิจัยต้านวิเคราะห์ข้อมูลและการค้นหาความรู้ และได้รับการสนับสนุนเงินประมาณจากมหาวิทยาลัยเทคโนโลยีสุรนารี สำนักงานกองทุนสนับสนุนการวิจัยและสำนักงานคณะกรรมการการวิจัยแห่งชาติ

เอกสารอ้างอิง

- [1] S. Guha, R. Rastogi, & K. Shim, Cure: An efficient clustering algorithm for large databases, *Proceedings of the ACM SIGMOD Int. Conf. on Management of Data*, 1998, 73-84.
- [2] A.K. Jain & R.C. Dubes, *Algorithms for Clustering Data* (Englewood Cliffs, New Jersey: Prentice Hall, 1988).
- [3] G. Karypis, E.-H. Han, & V. Kumar, Chameleon: A hierarchical clustering algorithm using dynamic modeling, *IEEE Computer*, 32(8), 1999, 68-75.
- [4] G. Kollios, D. Gunopulos, N. Koudas, & S. Berchtold, Efficient biased sampling for approximate clustering and outlier detection in data sets, *IEEE Transactions on Knowledge and Data Engineering*, 15(5), 2003, 1170-1187.
- [5] J.B. MacQueen. Some methods for classification and analysis of multivariate observations. *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probabilistic*, Vol.1, 1967, 281-297.
- [6] C. Palmer & C. Faloutsos, Density biased sampling: An improve method for data mining and clustering, *Proceedings of the ACM SIGMOD Int. Conf. on Management of Data*, 2000, 82-92.
- [7] J. Sander, M. Ester, H.-P. Kriegel, & X. Xu, Density-based clustering in spatial databases: The algorithm gbscan and its application, *Data Mining and Knowledge Discovery*, 2(2), 1998, 169-194.
- [8] A. Stehl, J. Ghosh, & R. Mooney, Impact of similarity measures on web-page clustering, *Proceedings of the Workshop of Artificial Intelligence for Web Search, 17th National Conference on Artificial Intelligence*, 2000.
- [9] J.S. Vitter, Random sampling with a reservoir, *ACM Transaction on Mathematical Software*, 11(1), 1985, 37-57.

การประมวลผลหลังกระบวนการทำเหมืองข้อมูล

Post-Data Mining Processing

นิตยา เกิดประสาร และ กิตติศักดิ์ เกิดประสาร

หน่วยวิจัยวิศวกรรมข้อมูลและการค้นหาความรู้ สาขาวิชาวิศวกรรมคอมพิวเตอร์ มหาวิทยาลัยเทคโนโลยีสุรนารี จ.นครราชสีมา

E-mail: nittaya@sut.ac.th

Nittaya Kerdprasop and Kittisak Kerdprasop

Data Engineering and Knowledge Discovery (DEKD) Research Unit, School of Computer Engineering,

Suranaree University of Technology, Nakhon Ratchasima 30000

บทคัดย่อ

กระบวนการทำเหมืองข้อมูลประกอบด้วยสามขั้นตอนหลัก คือก่อน การทำเหมืองข้อมูล ขณะทำเหมืองข้อมูล และหลังกระบวนการทำเหมืองข้อมูล ระบบทำเหมืองข้อมูลสามารถจัดสัมสุดกระบวนการที่การนำเสนอความรู้ในขั้นตอนขณะทำเหมืองข้อมูล แต่ในงานวิจัยนี้ได้นำเสนอขั้นตอนต่อจากนั้น คือ ขั้นตอนการใช้ประযุทธ์จากความรู้ที่ได้จากการทำเหมืองข้อมูล งานวิจัยนี้แสดงวิธีการนำเสนอความรู้ในรูปแบบของกฎการจำแนกใช้ประโยชน์ โดยความรู้ในรูปแบบของกฎการจำแนก จะถูกนำมาประเมินคุณภาพด้วยเกณฑ์ความครอบคลุมข้อมูล กฎที่ครอบคลุมข้อมูลได้มาก จะได้รับการคัดเลือกมาใช้ในระบบผู้เชี่ยวชาญ การทดสอบความสามารถของระบบผู้เชี่ยวชาญที่ใช้การสร้างฐานความรู้แบบอัตโนมัตินี้ ให้มีวัดความถูกต้องของค่าແນະนำที่ให้โดยระบบผู้เชี่ยวชาญ จากนั้นเปรียบเทียบกับความถูกต้องของกระบวนการทำนายโดยโปรแกรมการทำเหมืองข้อมูลแบบจำแนก รวมสามโปรแกรมได้แก่ โปรแกรมที่ใช้หลักการสร้างต้นไม้ตัดสินใจ (ID3) โปรแกรมสร้างกฎการจำแนก (PRISM) และ โปรแกรมข่ายงานประสาท (Neural network) ผลการทดสอบยืนยันความถูกต้องในการให้ค่าແນະนำของระบบผู้เชี่ยวชาญ คำหลัก การทำเหมืองข้อมูล กฎการจำแนก ระบบผู้เชี่ยวชาญ

Abstract

The process of data mining comprises of three major steps: pre-data mining, mining, and post-data mining. This research studies the post-data mining processing. Most data mining systems finish their processing at the knowledge presentation of the mining step. Our work further the post-data mining processing to the step of knowledge deployment. This research illustrates the knowledge deployment step in which its input is the induced knowledge, in the formalism of classification rules. These rules are evaluated and filtered on

the basis of coverage measurement. High coverage rules are transformed into decision rules to be used by the inference engine of the expert system. The accuracy of recommendation given by the expert system is evaluated and compared to other three classification systems, i.e. decision-tree induction (ID3), rule induction (PRISM), and neural network. The experimental results confirm the high accuracy of our expert system and the induced knowledge base.

Keywords: data mining, classification rules, expert system

1. บทนำ

การทำเหมืองข้อมูลเป็นเทคโนโลยีใหม่ที่มีความทันสมัยให้การวิเคราะห์ข้อมูล และการใช้ประโยชน์จากข้อมูลเป็นไปได้อย่างรวดเร็วและสะดวกมากขึ้น แต่กับสิ่งที่สำคัญคือความรู้ที่ค้นพบโดยโปรแกรมทำเหมืองข้อมูล วิ่งจำนวนมาก แต่ความรู้ที่เป็นประโยชน์โดยแท้จริงมีน้อยมาก นอกจากนี้ในบางครั้งความรู้ที่ค้นพบได้มีความซ้ำซ้อนกัน หรือในบางกรณีเป็นความรู้ที่ไม่ใช้การค้นพบใหม่ เช่น “พ่อบ้านในทุกด้วยเรื่องเป็นเพศชาย” ซึ่งถึงแม้ว่าจะเป็นความรู้ที่ถูกต้องแต่ไม่เกิดประโยชน์ ดังนั้นขั้นตอนสุดท้ายที่สำคัญของใช้เทคโนโลยีการทำเหมืองข้อมูล คือ การคัดเลือกและกลั่นกรองความรู้ที่ได้รับ จะนำความรู้โดยรายงานต่อผู้บริหารเพื่อใช้ประโยชน์ในการตัดสินใจ และความรู้ด้วยเครื่องทั้งไปเพื่อประชาชั่วข้อนี้ หรือไม่เกิดประโยชน์ ในปัจจุบันกระบวนการพิจารณาและคัดแยกความรู้นั้นกระทำโดยผู้เชี่ยวชาญ ที่มีความเชี่ยวชาญด้านข้อมูล และมีความสามารถในการตัดความผิดพลาดที่ได้จากการทำเหมืองข้อมูล ในหน่วยงานหรือองค์กรขนาดใหญ่ซึ่งต้องใช้ทีมบุคลากรที่มีประสบการณ์ด้านการทำเหมืองข้อมูลจำนวนมาก การจะพัฒนาเทคโนโลยีการทำเหมืองข้อมูลให้หน่วยงานขนาดเล็กหรือบุคคลทั่วไปใช้ประโยชน์ได้อย่างทั่วถึง จึงจำเป็นจะต้องมีการพัฒนากระบวนการ การคัดเลือกความรู้ รวมถึงรวมฐานความรู้ให้มีลักษณะเป็นอัตโนมัติกว่านี้

การพิจารณาความน่าสนใจ (interestingness) ของความรู้ที่ค้นพบโดยการทำเหมือนข้อมูลเป็นประเด็นปัญหาสำคัญ ที่ได้รับความสนใจจากนักวิจัยจำนวนมากตั้งแต่ยุคเริ่มต้นของการวิจัยด้านการทำเหมือนข้อมูล เนื่องจากได้เห็นถึงความสำคัญว่าความรู้ที่จะนำไปใช้ประโยชน์ได้ จะต้องเป็นความรู้ที่เป็นการค้นพบใหม่และน่าสนใจ โดย Platek-Shapiro และ Matheus [10] ได้พัฒนาระบบที่ชื่อ KEFIR ซึ่งมาเพื่อให้กับงานด้านการประดับสุภาพ ระบบจะพิจารณาข้อมูลที่มีอยู่ในไปจากข้อมูลปกติ และตัดสินใจว่าข้อมูลที่เบี่ยงเบนนี้เป็นข้อมูลที่ควรแก้การให้ความสนใจ การพิจารณาเกิดที่ความน่าสนใจของระบบนี้ จึงเป็นการพิจารณาในขอบเขตที่จำกัดมาก ในหัวข้อเดียวกัน Silberschatz และ Tuzhilin [12] ได้ร่วมมือกันเสนอวิธีการพิจารณาความน่าสนใจของความรู้ที่ค้นพบ โดยใช้ probabilistic belief เป็นแนวทางในการพิจารณาความน่าจะเป็นว่าความรู้ใดที่ผู้ใช้จะเห็นว่าสนใจ

ปัจจัยที่นักวิจัยใช้พิจารณาประเมินความน่าสนใจได้หลากหลาย เช่น จำนวนข้อมูลที่ความรู้นั้นสามารถอธิบายได้ (coverage) ความถูกต้องของความรู้ (confidence) ความไม่แน่นอนของความรู้ (strength) ความสำคัญของความรู้ (significance) ความเข้าใจง่ายของความรู้ (simplicity) ความใหม่ของค้นพบ (unexpectedness) และเป็นความรู้ที่นำไปสู่การปฏิบัติได้ (actionability) ปัจจัยเหล่านี้ถูกหยิบยกขึ้นมาพิจารณาโดยนักวิจัยหลายคณะ [7], [10], [11] ปัจจัยในด้าน coverage, confidence, strength, significance, simplicity เป็นปัจจัยที่สามารถสร้างเทคโนโลยีขึ้นมาจัดการได้ โดยไม่ต้องใช้ข้อมูลหรือค่าแนะนำประกอบจากผู้ใช้หรือจากความรู้อื่น แต่ปัจจัยด้าน unexpectedness และ actionability เป็นปัจจัยที่พิจารณาตัดสินได้ยาก

ในส่วนของการจัดการกับปริมาณความรู้ ที่เป็นผลลัพธ์ของกระบวนการการทำเหมือนข้อมูล และมักจะได้ความรู้ที่ไม่เป็นประโยชน์ ประเมินอุปกรณ์เป็นจำนวนมาก เป็นปัญหาที่มีผลกระทบอย่างมาก กับงานการทำเหมือนข้อมูลโดยเฉพาะงานประมวลผล association [2], [4], [6], [13] นักวิจัยส่วนใหญ่ [11], [3] จะใช้วิธีจัดการระหว่างกระบวนการการทำเหมือนข้อมูล เช่นใช้วิธีตัดทิ้ง (pruning) เส้นทางค้นหาที่คาดว่าจะนำไปสู่ความรู้ที่ไม่เกิดประโยชน์ นักวิจัยในอีกกลุ่ม [5], [8], [9] จะใช้วิธีนำความรู้อื่น (domain knowledge) มาใช้ช่วยในการห่วงโซ่ความรู้ โดยใช้สมมุติฐานว่าความรู้อื่นที่เกี่ยวข้องจะช่วยในการตัดสินใจซึ่งต้องผลลัพธ์ของการทำเหมือนข้อมูลที่จะไม่ก่อประโยชน์กับงาน

ถึงแม้แนวทางของเทคนิค pruning และเทคนิคการใช้ domain knowledge จะช่วยลดปริมาณความรู้ที่ไม่ก่อประโยชน์ แต่ตัดสูญประโยชน์ของนักวิจัยในทั้งสองกลุ่มนี้มุ่งเน้นไปที่การลดปริมาณความรู้ที่เพิ่มประสิทธิภาพของกระบวนการค้นหาความรู้ มากกว่าจะเพื่อเอื้อประโยชน์ให้กับผู้ใช้ ให้สามารถใช้ประโยชน์จากผลลัพธ์ของการทำเหมือนข้อมูลได้อย่างเต็มประสิทธิภาพ และเกิดประโยชน์ในเวลาอันรวดเร็ว ในระยะหลังของงานวิจัยในสาขาวิชาการทำเหมือนข้อมูล นักวิจัย [1], [14] เริ่มตระหนักรากที่น้ำว่ากระบวนการจัดการกับผลลัพธ์ (หรือ ความรู้) ที่ได้หลังจากการทำเหมือนข้อมูล

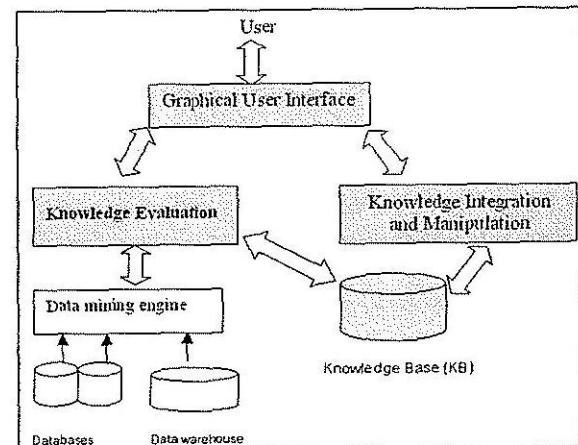
เป็นสิ่งจำเป็น เพื่อให้การใช้ประโยชน์จากการทำเหมือนข้อมูล เป็นอัตโนมัติและทันต่อความต้องการมากขึ้น

งานวิจัยที่พัฒนาขึ้นนี้ อยู่ในแนวทางของกระบวนการจัดการกับความรู้ ซึ่งจัดเป็น post-processing ของกระบวนการการทำเหมือนข้อมูล โดยมีการพัฒนาเทคโนโลยีและกระบวนการในการตรวจสอบความรู้ที่เป็นผลลัพธ์จากการทำเหมือนข้อมูล ให้สามารถแยกแยะความรู้ที่เป็นประโยชน์ออกจากความรู้ที่ใช้ประโยชน์ไม่ได้ จากนั้นเลือกໄว้เฉพาะความรู้ที่ผ่านการคัดสรรแล้ว ส่งต่อไปยังฐานความรู้ เพื่อใช้ประโยชน์ในงานด้านการสนับสนุนการตัดสินใจ (decision support) การคัดเลือกความรู้ในงานวิจัยนี้ใช้เกณฑ์ coverage เพื่อแปลงเป็นความน่าจะเป็นที่ความรู้นั้นจะสามารถประยุกต์ใช้ได้ โดยประกอบกับค่า threshold ที่ผู้ใช้ระบุเป็นเกณฑ์ขั้นต่ำในการคัดเลือกความรู้

2. กระบวนการประมวลผลหลังการทำเหมือนข้อมูล

2.1 ครอบ霞ดิตของงานวิจัย

งานวิจัยนี้มีวัตถุประสงค์หลัก เพื่อการพัฒนาเทคโนโลยีในการจัดการกับความรู้ ที่เป็นผลลัพธ์จากการทำเหมือนข้อมูล การจัดการกับความรู้ที่ได้ จึงหมายถึงการประเมินคุณภาพของความรู้ที่อยู่คัดเลือกเฉพาะความรู้ ที่น่าจะใช้ประโยชน์ได้มากที่สุด โดยระบบดันแบบที่พัฒนาขึ้น จะประกอบด้วยส่วนประกอบหลัก ส่วนที่หนึ่งคือ ส่วนวิเคราะห์ความรู้ (knowledge evaluation) ที่ได้จากการทำเหมือนข้อมูล และส่วนรวมและจัดการกับความรู้ (knowledge integration and manipulation) ซึ่งจะรวมถึงการสอนตามความรู้ที่รวมไว้ในฐานความรู้ สถาปัตยกรรมหลักของระบบจัดการความรู้นี้แสดงได้ดังรูปที่ 1



รูปที่ 1 โครงสร้างของระบบจัดการความรู้หลังการทำเหมือนข้อมูล

ส่วนวิเคราะห์ความรู้ ทำหน้าที่รับโมเดลข้อมูลที่เป็นผลลัพธ์จากการทำเหมือนข้อมูลแบบจำแนก โมเดลข้อมูลนี้จะอยู่ในรูปแบบของต้นไม้ตัดสินใจที่มีโครงสร้างหลักคือโหนดต่างๆ (node) ของต้นไม้ และเส้นเชื่อมโหนดทุกเส้น (edge) เมื่อได้รับข้อมูล node และ edge ทั้งหมดจากโปรแกรม data mining engine ส่วนวิเคราะห์ความรู้จะแปลงข้อมูล node และ edge ให้อยู่ในรูปแบบ

ของกฎการตัดสินใจ (decision rule) ในขั้นตอนนี้จะมีการคำนวณค่า coverage ของแต่ละกฎ และแบ่งเป็นค่าสัดส่วนของจำนวนข้อมูลที่เกี่ยวกับคุณสมบัติของข้อมูลทั้งหมด ค่าสัดส่วนที่ได้จะมีค่าอยู่ระหว่าง 0.0-1.0 ดังนั้นค่าสัดส่วนนี้สามารถแปลความหมายได้ว่า เป็นความน่าจะเป็นที่กฎจะประยุกต์ใช้ได้กับเหตุการณ์ที่จะเกิดขึ้นในอนาคต ส่วนรวมรวมและจัดการกับความรู้ ทำหน้าที่จัดเก็บความรู้ในรูปแบบของกฎการตัดสินใจ และทำหน้าที่เป็น expert system shell เพื่ออำนวยความสะดวก ให้ผู้ใช้สามารถสอบถามความรู้จากฐานความรู้ได้ ผลลัพธ์ที่แสดงให้ผู้ใช้เห็นจะเป็นข้อแนะนำการตัดสินใจหรือกับแสดงค่าความน่าจะเป็น (หรือดับความเชื่อมั่น) ของข้อแนะนำนั้น

2.2 อัลกอริทึมเพื่อการประเมินและตัดเตือนกฎ

ในการออกแบบอัลกอริทึมที่เป็นโมดูลหลักของโปรแกรม จะประกอบด้วยสองโมดูล คือ Knowledge evaluation และ Knowledge integration and manipulation รายละเอียดของแต่ละอัลกอริทึมแสดงได้ดังต่อไปนี้

Algorithm 1 Knowledge evaluation

- Input:** a data model as decision tree with node and edge structures
Output: a set of probabilistic decision rules ranking in descending order
- (1) Display GUI to get a dataset name and a minimum probability value
 - (2) Traverse tree from a root node to each leaf node
 - (2.1) Collect edge information and count number of data instances
 - (2.2) Compute probability as a proportion
 (number of instances at leaf node) / (total data instances in a data set)
 - (2.3) Assert a rule containing a triplet
 <attribute-value pair, class, probability value>
 into temporary KB
 - (3) Sort rules in the KB in descending order according to the rules' probability
 - (4) Remove rules that have probability less than the specified threshold
 - (5) Assert selected rules into the KB and return KB as an output

Algorithm 2 Knowledge integration and manipulation

- Input:** a set of probabilistic decision rules stored in KB
Output: a set of rules to be used by an expert system shell
- (1) For each probabilistic decision rule
 - (1.1) Scan information in the If-part and the Then-part
 - (1.2) Generate head of expert rule from the Then-part type (Then-part, probability value) :-
 - (1.3) Generate body of expert rule from the If-part
 :- attribute_name1(value), ..., attribute_nameN(value).
 - (1.4) Write expert rule in a file, knb-file
 - (2) For each data attribute
 - (2.1) Generate head of consulting rule
 attribute_name(X) :-
 - (2.2) Generate body of consulting rule
 :- menuask(attribute_name, X, [list of attribute values]).

- (3) Assert consulting rules into the knb-file and return KB as an output

3. การพัฒนาโปรแกรมและการประมวลผล

โปรแกรมนี้พัฒนาด้วยภาษา Prolog การอธิบายขั้นตอนพัฒนาโปรแกรมจะใช้ไวยากรณ์ของภาษา Prolog ตามมาตรฐานของ SWI Prolog เวอร์ชัน 5.6.55 (ดาวน์โหลดได้จากเว็บไซต์ www.swi-prolog.org) ลักษณะเด่นประการหนึ่งของภาษา Prolog คือการใช้รูปแบบเดียวทั้งหมดทั้งข้อมูลและคำสั่งที่ทำงานกับข้อมูล

รูปแบบของข้อมูล

ข้อมูลตัวอย่างที่จะเป็นอินพุตของโปรแกรมทำเหมือนข้อมูลจะมีลักษณะเป็นข้อความที่อยู่ในรูปแบบของข้อความที่เป็นจริงหรือ fact ตัวอย่างของข้อมูลแสดงได้ดังรูปที่ 2 ข้อมูลดังรูปเป็นข้อมูลการวินิจฉัยแต่ละรายสามารถได้ค่อนแท็กเลนส์ได้หรือไม่ ถ้าค่อนไข้สามารถใส่ค่อนแท็กเลนส์ได้จะมีค่า class=yes สรุรายที่ไม่สามารถใส่ค่อนแท็กเลนส์ (เนื่องจากพยาธิสภาพไม่เหมาะสม เช่น มีนัยน์ตาแห้งเกินไป) จะมีค่า class=no

```
%% Data lens
% attributes: names and their possible values
attribute(age, [young, pre_presbyopic, presbyopic]).
attribute(spectacle, [myope, hypermetrope]).
attribute(astigmatism, [no, yes]).
attribute(tear, [reduced, normal]).
attribute(class, [yes, no]).

% data
instance(1, class=no, [age=young, spectacle=myope,
                      astigmatism=no, tear=reduced]).
instance(2, class=yes, [age=young, spectacle=myope,
                      astigmatism=no, tear=normal]).
instance(3, class=no, [age=young, spectacle=myope,
                      astigmatism=yes, tear=reduced]).
instance(4, class=yes, [age=young, spectacle=myope,
                      astigmatism=no, tear=normal]).

...
```

รูปที่ 2 ข้อมูลตัวอย่างของผู้ที่ได้รับการตรวจก่อนใส่ค่อนแท็กเลนส์

บรรทัดแรกของข้อมูลเริ่มต้นด้วยเครื่องหมาย % หมายถึง comment โครงสร้างของไฟล์ข้อมูลจะแยกส่วนประกอบออกเป็นสองส่วนคือ ส่วนคำอธิบายและทริบิวต์ (ได้แก่ส่วนข้อความ attribute ...) และส่วนแสดงรายละเอียดของข้อมูลแต่ละเรคคอร์ด (ได้แก่ส่วนข้อความ instance ...) ในส่วนที่อธิบายและทริบิวต์ภาษาในจะประกอบด้วยสองอาร์กิวเม้นต์ อาร์กิวเม้นต์แรกจะประกอบด้วย attribute ... และส่วนแสดงรายละเอียดของข้อมูลแต่ละเรคคอร์ด (ได้แก่ส่วนข้อความ instance ...) ในส่วนที่อธิบายและทริบิวต์ ภายในจะประกอบด้วยสองอาร์กิวเม้นต์ าร์กิวเม้นต์ที่สองเป็นลิสต์ของค่าที่เป็นไปได้ทั้งหมดของทริบิวต์ อาร์กิวเม้นต์ที่สองเป็นลิสต์ของค่าที่เป็นไปได้ทั้งหมดของทริบิวต์นั้น ในส่วนของข้อมูลหรือ instance จะประกอบด้วยสามอาร์กิวเม้นต์ คือ หมายเลขอของข้อมูล, ค่าคลาสของข้อมูล, ลิสต์ที่ระบุค่าของแต่ละแอฟทริบิวต์ โดยวิธีการระบุค่าจะใช้รูปแบบ attribute-value pair หรือ ชื่อแอฟทริบิวต์=ค่าของแอฟทริบิวต์ เมื่อสร้างข้อมูลในรูปแบบที่กำหนดเสร็จ จะต้องบันทึกไฟล์ให้อยู่ในรูปแบบของโปรแกรม Prolog ที่มีส่วนขยาย (file extension) เป็น .pl เช่นตัวอย่างไฟล์ข้อมูลในรูปที่ 2 บันทึกอยู่ในชื่อ lens.pl

โปรแกรมวิเคราะห์ความรู้

การทํางานของโปรแกรมในส่วนนี้ จะเริ่มหลังจากมีการสร้างโมเดลข้อมูลด้วยหลักการของ การสร้างต้นไม้ตัดสินใจ (อัลกอริทึม ID3 [11]) และบันทึกโมเดลไว้ในไฟร์ดิเคตชื่อ node และ edge ค่าตั้งต่างๆ ของโปรแกรมหลักและตั้งให้ตัวนี้

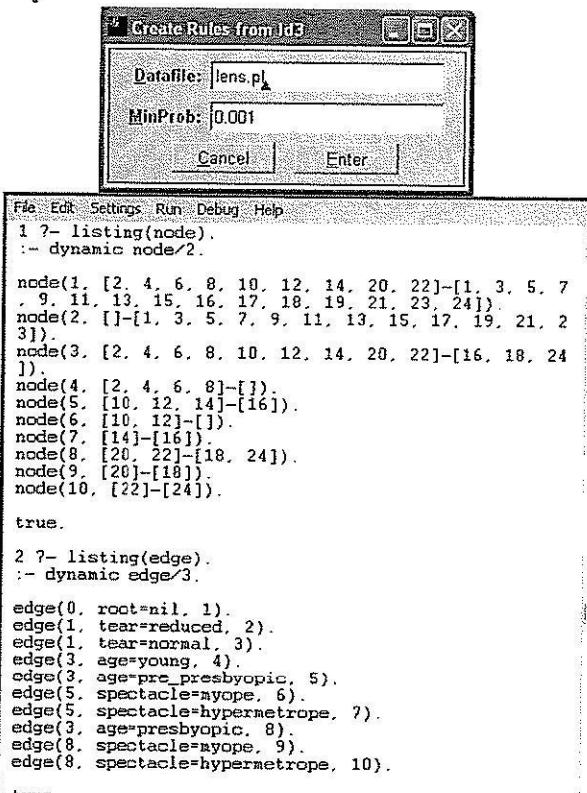
```
mainId3(Min) :-
```

```

init(AllAttr, EdgeList), % initialize node and edge info.
getnode(N), % get node ID
create_edge(N, AllAttr, EdgeList), % create tree
addAllKnowledge, % generate decision rules
selectRule(Min, Res), % select top rules
tell('l.knb'), % write selected decision rules to file
writeHeadF, % transform to expert rules (head)
maplist(createRule1, Res),
nl, writeTailF, % generate body of expert rules
told, % write expert rules to file and close it
writeln(endProcess).

```

โปรแกรมหลักชื่อ `mainld3` จะรับอาร์กิวเม้นต์ `Min` ที่ระบุค่าความกว้างเป็นตัวที่ผู้ใช้ต้องการ จากนั้นเริ่มสร้างต้นไม้ตัดสินใจ ด้วยการเรียกใช้คำสั่ง `yoyosamakasasshio` `init`, `getnode` และ `create_edge` คำสั่ง `create_edge` จะมีการวนทำงานซ้ำเพื่อสร้างต้นไม้ตัดสินใจ การสร้างต้นไม้จะชุด เมื่อสามารถแยกข้อมูลที่มีสองคลาสป็นกัน ให้เป็นข้อมูลคลาสเดียวกันได้ทั้งหมด หรือเมื่อไม่มี例外ทิบิวต์ให้ใช้แยกข้อมูลได้อีกด่อไป จากข้อมูล `lens.pl` ในรูปที่ 2 เมื่อสร้างต้นไม้ตัดสินใจเสร็จ จะได้โครงสร้าง `node` และ `edge` ดังรูปที่ 3



รูปที่ 3 จอกาแฟแสดงการระบุชื่อข้อมูลและผลลัพธ์เป็นโนเมเดลข้อมูล
ในลักษณะโครงสร้าง node และ edge ของต้นไม้ตัดอินไป

ตัวอย่างในปุ่มที่ 3 ระบุค่าความน่าจะเป็นขั้นต่ำ 0.001 จะทำให้ได้กฎการตัดสินใจจำนวนสามกฎ ดังต่อไปนี้

```
0.5 >> [tear=reduced] >> no,  
0.1666667 >> [tear=normal, age=young] >> yes,  
0.0833333 >> [tear=normal, age=pre_presbyopic,  
spectacle=myope] >> yes
```

โครงการสร้างของกฎการดัดสินใจจะประกอบด้วยสามส่วน แต่ละส่วนแยกจากกันด้วยสัญลักษณ์ >> ส่วนแรกจะบุคคลความน่าจะเป็นที่เก็บไว้สามารถตรวจสอบคุณสมบัติ ล้วนที่สองจะบุคลักษณะหรือเอกลักษณ์ที่ใช้ประกอบการดัดสินใจ และส่วนสุดท้ายเป็นผลการวินิจฉัยของแพทย์ ค่า yes หมายถึงแนะนำให้คุณไข้ที่มีปัญหาด้านสายตาใส่คอนแทกเลนส์ได้ ค่า no หมายถึงไม่แนะนำให้ใส่คอนแทกเลนส์ตัวอย่างเช่นกฎข้อแรกจะบุคคลว่า ถ้าคุณไข้มีอัตราการสร้างน้ำตาต่ำ (tear=reduced) แพทย์จะไม่แนะนำให้ใส่คอนแทกเลนส์ ค่าความน่าจะเป็น 0.5 หมายถึงกฎนี้ครอบคลุมข้อมูล 0.5 หรือ 50% (นั่นคือกฎนี้สังเคราะห์ได้จากข้อมูลคนไข้ 12 รายจากข้อมูลคนไข้ทั้งหมดจำนวน 24 ราย)

โปรแกรมรวมและจัดการกับความรู้

กognการตัดสินใจที่ได้จากการวิเคราะห์ความรู้ จะถูกนำไปแปลงให้มีรูปแบบที่ใช้ในระบบผู้เชี่ยวชาญ โปรแกรมแปลงกฎการตัดสินใจให้เป็นกฎประเพณี expert rules และได้ดังนี้

```

format("% I.knb ~n% for expert shell. --- written
       by Postprocess"),
format(~n% top_goal where the inference
       starts.~n'),
format(~ntop_goal(X,V) :- type(X,V).~n').

```

writeTailF:-

```

findall( _,attribute(S,L),
format('~-n~w(X)~-menuask(~w,X,~w).
         %generated menu',[S,S,L))),_),
format('~-n~n%end of automatic post process').

```

โปรแกรมแปลงกฎการตัดสินใจให้เป็นกฎประเภท consult rules แสดงได้ดังนี้

```
transform1([X=V], [Res]) :-  
    atomic_list_concat([X,'(',V,')'], Res1),  
    term_to_atom(Res, Res1)!.
```

```

transformI([X=V|T], [Res|T1]) :-  

    atomic_list_concat([X,'(',V,')'], Res1),  

    term_to_atom(Res, Res1),  

    transformI(T, T1).

```

```

createRule1(I) :- I=Z>>X>>Y,
    transformI(X,BodyL),
    format('`-ntype(~w,~w):-',[Y,Z]),
    myformat(BodyL),
    write(' % generated rule')!.
```

```
myformat([X]) :- write(X), write('.'), !.  
myformat([H|T]) :- write(H), write(','), myformat(T).
```

เมื่อโปรแกรมที่ทำหน้าที่แปลงจากกฎการตัดสินใจ ให้เป็น กฎที่สามารถใช้งานได้กับระบบผู้เชี่ยวชาญ ทำการแปลงกฎทั้งหมดเดิมที่ก็ผลลัพธ์ที่ได้ลงในไฟล์ชื่อ '1.knb' ซึ่งจากตัวอย่างข้อมูล lens.pl เมื่อแปลงกฎเสร็จจะได้ข้อมูลดังรูปที่ 4 ซึ่งจะทำหน้าที่เป็นฐานความรู้ให้กับระบบผู้เชี่ยวชาญ ด้านล่างของการใช้งานระบบผู้เชี่ยวชาญแสดงได้ดังรูปที่ 5

```

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

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

type(no,0.5):-tear(reduced). % generated rule
type(yes,0.166667):-tear(normal),age(young). % generated rule
type(yes,0.00333333):-tear(normal),age(pre_presbyopic),spectacle(myope). % generated rule

age(X):-menuask(age,X,[young,pre_presbyopic,presbyopic]). %generated menu
spectacle(X):-menuask(spectacle,X,[myope,hypermetropic]). %generated menu
astigmatism(X):-menuask(astigmatism,X,[no,yes]). %generated menu
tear(X):-menuask(tear,X,[reduced,normal]). %generated menu
class(X):-menuask(class,X,[yes,no]). %generated menu

end of automatic post process

```

รูปที่ 4 ข้อมูลในไฟล์ที่ทำหน้าที่เป็นฐานความรู้ของระบบผู้เชี่ยวชาญ

```

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>

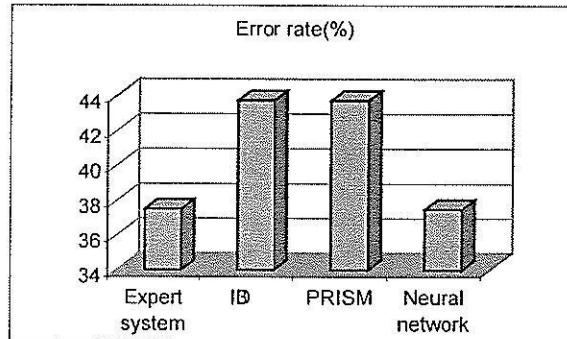
```

รูปที่ 5 ด้านล่างการใช้งานระบบผู้เชี่ยวชาญเพื่อขอคำแนะนำเกี่ยวกับการใช้ค่อนแท็กเลนส์

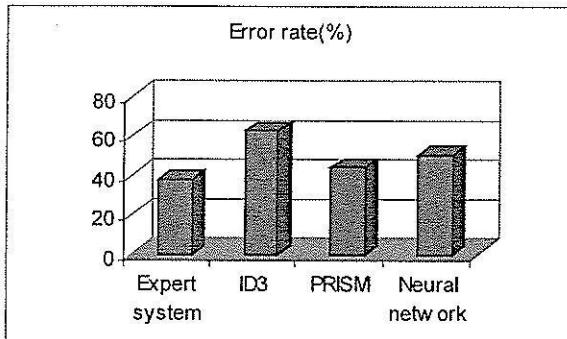
4. การทดสอบฐานความรู้

วิธีการทดสอบการสร้างโมเดลของโปรแกรมเพื่อการประมวลผลหลังการทำให้มีข้อมูล จะใช้วิธีแยกข้อมูลส่วนใหญ่เป็นข้อมูลฝึก เพื่อสร้างโมเดลข้อมูลและสร้างกฎการตัดสินใจที่จะถูกแปลงเป็นกฎในระบบผู้เชี่ยวชาญ จากนั้นจะทดสอบความถูกต้องในการให้คำแนะนำของระบบผู้เชี่ยวชาญ โดยข้อมูลที่ใช้ทดสอบเป็นข้อมูลขนาดเล็กมีจำนวน 16 รายการ ชุดข้อมูลที่ใช้เป็นข้อมูลมาตรฐานของ UCI (<http://archive.ics.uci.edu/ml/datasets.html>) โดยเลือกใช้ข้อมูล post-operative patients (จำนวนข้อมูลฝึก 70 เรคคอร์ด แต่ละเรคคอร์ดประกอบด้วย 8 แອทกริบิวต์) และข้อมูล breast-cancer recurrences (จำนวนข้อมูลฝึก 175 เรคคอร์ด แต่ละเรคคอร์ดประกอบด้วย 9 แອทกริบิวต์)

การทดสอบในประเด็นความถูกต้องในการให้คำแนะนำของระบบผู้เชี่ยวชาญที่พัฒนาขึ้น จะเปรียบเทียบกับผลการทดสอบใน การจำแนกข้อมูลด้วยอัลกอริทึม ID3 (decision-tree induction algorithm), PRISM (rule induction algorithm) และ neural network (multi-layer perceptron algorithm) ผลการเปรียบเทียบความผิดพลาดในการให้คำแนะนำ หรือการท่านายคลาสของข้อมูลทดสอบของโปรแกรม expert system, ID3, PRISM, Neural network กับข้อมูล post-operative patients และ breast-cancer recurrences แสดงดังภาพในรูปที่ 6 และ 7 ตามลำดับ



รูปที่ 6 กราฟเปรียบเทียบ error rate เมื่อทดสอบกับข้อมูล post-operative patients



รูปที่ 7 กราฟเปรียบเทียบ error rate เมื่อทดสอบกับข้อมูล breast-cancer recurrences

จากการทดสอบความถูกต้องของโปรแกรมประมวลผล หลังการทำให้มีข้อมูล หรือโปรแกรม automatic expert system ที่สร้างระบบผู้เชี่ยวชาญโดยอัลกอริทึมตัด ในการทดสอบชุดข้อมูลเมื่อเทียบ กับโปรแกรม ID3 พบว่าโปรแกรม automatic expert system ให้ผลลัพธ์ที่ถูกต้องมากกว่าทั้งๆที่โปรแกรม automatic expert system ใช้ไม้เลสข้อมูลเริ่มต้นเป็นต้นไม้ตัดสินใจเหมือนกับ โปรแกรม ID3 แต่ข้อแตกต่างอยู่ที่ โปรแกรม automatic expert system มีการจัดล้ำด้วยกฎการตัดสินใจตามค่าความไปจะเป็นและ คัดเลือกให้เฉพาะกฎที่มีความน่าจะเป็นสูง

เมื่อเปรียบเทียบความผิดพลาดในการให้คำแนะนำ หรือ ความผิดพลาดในการท่านาย (error rate) ของโปรแกรมทั้งสี่พบว่า โปรแกรม automatic expert system ให้ค่าความผิดพลาดที่ต่ำที่สุด (คือ 37.50% ในข้อมูลทั้งสองชุด) และเมื่อวิเคราะห์ความผิด

พลาดในลักษณะของ false negative พนว่าโปรแกรม automatic expert system ให้ความผิดพลาดชนิดนี้ได้ที่สุด ซึ่งในการวินิจฉัยทางด้านการแพทย์ความผิดพลาดประเภท false negative (เช่นคนไข้เป็นมะเร็ง แต่ได้วินิจฉัยว่าสุขภาพแข็งแรงเป็นปกติ) ถือว่ามีความร้ายแรงมากกว่าความผิดพลาดประเภท false positive (เช่นคนไข้ที่ไม่เป็นมะเร็ง แต่ได้วินิจฉัยว่าเป็นมะเร็งและจะต้องถูกส่งไปตรวจทางคลินิกเพิ่มเติม)

โปรแกรมทำเหมือนข้อมูลที่ใช้โมเดลข้อมูลในลักษณะของต้นไม้ตัดสินใจ (ID3) หรือในลักษณะของกฎ (automatic expert system และ PRISM) จะมีข้ออกพิร่องที่เห็นได้ชัดเจนจากผลการทดลองคือ โมเดลที่ได้ไม่สมบูรณ์ เนื่องจากจะมีบางกรณีที่ไม่สามารถให้คำแนะนำ หรือไม่สามารถทำนายผลลัพธ์ได้ ซึ่งจะต่างจากโปรแกรม Neural network ที่มีพื้นฐานการสร้างโมเดลจากการใช้พังก์ชันทางคณิตศาสตร์ (ในการทดลองนี้ใช้ sigmoid function) ทำให้สามารถทำนายผลลัพธ์ของข้อมูลได้ครอบคลุมหมดทุกกรณี

5. สรุป

โปรแกรมเพื่อการทำเหมือนข้อมูลในปัจจุบัน มักจะได้รับการพัฒนาโปรแกรมจนถึงขั้นให้สามารถแสดงผลลัพธ์เป็นโมเดลข้อมูล หรือแพทเทิร์นของกลุ่มข้อมูล ขั้นตอนต่อจากนั้นที่เป็นการนำโมเดลหรือแพทเทิร์นไปใช้ประยุกต์ แม้จะให้อยู่ในคุณภาพของนักวิเคราะห์ข้อมูล ซึ่งนักวิเคราะห์ข้อมูลที่ไม่คุ้นเคยกับกระบวนการการทำเหมือนข้อมูล แม้จะประสบกับอุปสรรคสำคัญของการคัดเลือกความรู้ในโมเดลไปใช้งานต่อไป เนื่องจากโปรแกรมทำเหมือนข้อมูล แม้จะแสดงผลลัพธ์เป็นโมเดลที่มีความซับซ้อนและมีขนาดใหญ่ทำให้แปลผลได้ยาก งานวิจัยเรื่องการประมวลผลหลังกระบวนการทำเหมือนข้อมูลนี้ จึงมีวัตถุประสงค์หลักเพื่อจะพัฒนาโปรแกรมเพื่อรับอิมพุทเป็นโมเดลข้อมูล จากนั้นแปลงโมเดลข้อมูลให้อยู่ในรูปแบบที่นักวิเคราะห์ข้อมูลโดยทั่วไปเข้าใจได้

นอกจากแปลงรูปแบบโมเดลข้อมูลให้เข้าใจได้ง่ายแล้ว งานวิจัยนี้ยังได้เพิ่มเทคนิคของการกลั่นกรองโมเดล ให้มีขนาดเล็กลง ทั้งนี้เพื่อความสะดวกในการแปลผลและนำไปใช้งาน โปรแกรมที่พัฒนาขึ้นมีพังก์ชันด้านการใช้งานโมเดลที่ได้รับการกลั่นกรองแล้ว ด้วยการจัดสร้างฐานความรู้โดยอัตโนมัติจากโมเดลข้อมูล และสร้าง expert system shell ที่ผู้ใช้สามารถสอนตามโมเดลข้อมูลที่อยู่ในฐานความรู้ได้อย่างสะดวก

กิตติกรรมประกาศ

งานวิจัยนี้ได้รับการสนับสนุนจากมหาวิทยาลัยเทคโนโลยีสุรนารี ผ่านการดำเนินงานของหน่วยวิจัยวิศวกรรมข้อมูลและการค้นหาความรู้ (DEKD Research Unit) และสำนักงานคณะกรรมการวิจัยแห่งชาติ (วช.) ผู้วิจัยรายชื่อที่สองได้รับการสนับสนุนทุนวิจัยจากสำนักงานกองทุนสนับสนุนการวิจัย (สกว. สัญญาเลขที่ RMU 5080026)

เอกสารอ้างอิง

- [1] Adomavicius, G. and Tuzhilin, A. 2001. Expert-driven validation of rule-based user models in personalization applications. *Journal of Data Mining and Knowledge Discovery*, 5(1/2): 33-58.
- [2] Bayardo, R.J., Agrawal, R. and Gunopulos, D. 1999. Constraint-based rule mining in large, dense databases. *Proc. of the 15th Int. Conf. on Data Engineering*, March.
- [3] Breiman, L., Friedman, J., Olshen, R. and Stone, C. 1984. *Classification and regression tree*. Belmont: Wadsworth.
- [4] Brin, S., Motwani, R., Ullman, J.D. and Tsur, S. 1997. Dynamic itemset counting and implication rules for market basket data. *Proc. of the ACM SIGMOD Conference*.
- [5] Clark, P. and Matwin, S. 1993. Using qualitative models to guide induction learning. *Proc. of Int. Conf. on Machine Learning*.
- [6] Klemettinen, M., Mannila, H., Ronkainen, P., Toivonen, H. and Verkamo, A.I. 1994. Finding interesting rules from large sets of discovered association rules. *Proc. of the Third Int. Conf. on Information and Knowledge Management*.
- [7] Major, J. and Mangano, J. 1993. Selecting among rules induced from a hurricane database. *Proc. of the AAAI-93 Workshop on KDD*.
- [8] Ortega, J. and Fisher, D. 1995. Flexibly exploiting prior knowledge in empirical learning. *IJCAI*.
- [9] Pazzani, M. and Kibler, D. 1992. The utility of knowledge in inductive learning. *Machine Learning*, 9.
- [10] Platetsky-Shapiro, G. and Matheus, C.J. 1994. The interestingness of deviations. *Proc. of the AAAI-94 Workshop on Knowledge Discovery in Databases*.
- [11] Quinlan, J.R. 1992. *C4.5: Program for Machine Learning*. Morgan Kaufmann.
- [12] Silberschatz, A. and Tuzhilin, A. 1996. What makes patterns interesting in knowledge discovery systems. *IEEE Transactions on Knowledge and Data Engineering*, 8(6), December.
- [13] Suzuki, E. 1997. Autonomous discovery of reliable exception rules. *Proc. of the Third Int. Conf. on Knowledge Discovery and Data Mining*.
- [14] Wang, K., Tay, S.H.W and Liu, B. 1998. Interestingness-based interval merger for numeric association rules. *Proc. of the Fourth Int. Conf. on Knowledge Discovery and Data Mining*.

Probabilistic Knowledge Discovery from Medical Databases

Nittaya Kerdprasop and Kittisak Kerdprasop

*Data Engineering and Knowledge Discovery (DEKD) Research Unit,
School of Computer Engineering, Suranaree University of Technology,
111 University Avenue, Nakhon Ratchasima 30000 Thailand
E-mail: nittaya@sut.ac.th; Fax: 044-224602; Tel. 044-224432*

ABSTRACT

Medical knowledge discovery is an emerging area within the data-mining field that attracts many new researchers from diverse disciplines. During the past decade numerous learning techniques had been employed to discover useful knowledge from health examination and clinical data. Unlike past efforts that simply concentrated on the deployment of well-known learning techniques on medical data sets, our new approach expands the learning algorithm to deal with uncertain knowledge. We devise an algorithm to generate probabilistic knowledge from the induced decision tree. The implementation of the proposed algorithm is demonstrated via second-order predicates and a meta-programming approach. Experimental results on several medical domains emphasize the simple form of knowledge representation and the potential of incorporating learning results as background knowledge in the knowledge-base system.

Keywords: Medical knowledge mining, Probabilistic knowledge induction.

1. INTRODUCTION

The automated learning of models from patient data and biomedical records has become more and more essential since the extensive computerization in healthcare industry and the significant advancement in genomic and proteomic technologies during the last decade. Medical and clinical databases have been created and constantly growing at an exponential rate. The development of an automatic and intelligent data analysis tool is an obvious solution to the data-flooding problem in medical domains [4], [12], [13].

Knowledge extraction from huge amount of health databases is expected to ease the medical decision-making process. The ultimate goal of knowledge extraction is to generate the most accurate and useful knowledge and represent it in an understandable format. Such goal is, however, difficult to accomplish due to the learning complexity of knowledge induction methods and the nonconformity of the database contents. Most of the time knowledge discovery from medical databases results in reporting large number of irrelevant knowledge [6], [9]. We thus focus our study on this issue and devise a technique to extract a limited number of knowledge that is most likely relevant to the specific domain.

In medical knowledge mining, interpretability of results is an important feature of the data analysis tool. Medical practitioners need a system that can produce accurate results in an understandable form. Therefore, knowledge represented as rules has been widely used for knowledge discovery in medical applications. Classification rule induction is an approach commonly used for building diagnosis models [2], [5], [7], [14]. Association rule mining is an induction method applied for exploring patterns that are frequently occur in medical data [3], [10]. Classification and association mining methods are two major techniques for rule generation that work successfully in many domains. Nevertheless, in medical applications these learning techniques tend to generate a lot of rules. Too many rules, some are redundant and uninteresting, cause problems to the medical practitioners because a truly relevant one can be easily overlooked.

We thus propose a rule induction method based on the decision-tree structure that adopts the probability concept to select the most probable applicable rules. The outline of this paper is as follows. After the introductory section, we present in Section 2 the general framework and the algorithms of our proposed method. The implementation and experimental results are illustrated in Sections 3. Section 4 concludes this paper with the discussion on further research direction.

2. FRAMEWORK AND METHOD FOR PROBABILISTIC KNOWLEDGE INDUCTION

Our knowledge induction system (Figure 1) is based on the decision-tree induction method [11]. Decision tree induction is a popular method for mining knowledge from data and representing the result as a classifier tree. Popularity is due to the fact that mining result in a form of decision tree is interpretability, which is more concern among casual users than a sophisticated method but lack of understandability. A decision tree is a hierarchical structure with each node contains decision attribute and node branches corresponding to different attribute values of the decision node. The goal of building decision tree is to partition data with mixing classes down the tree until each leaf node contains data with pure class.

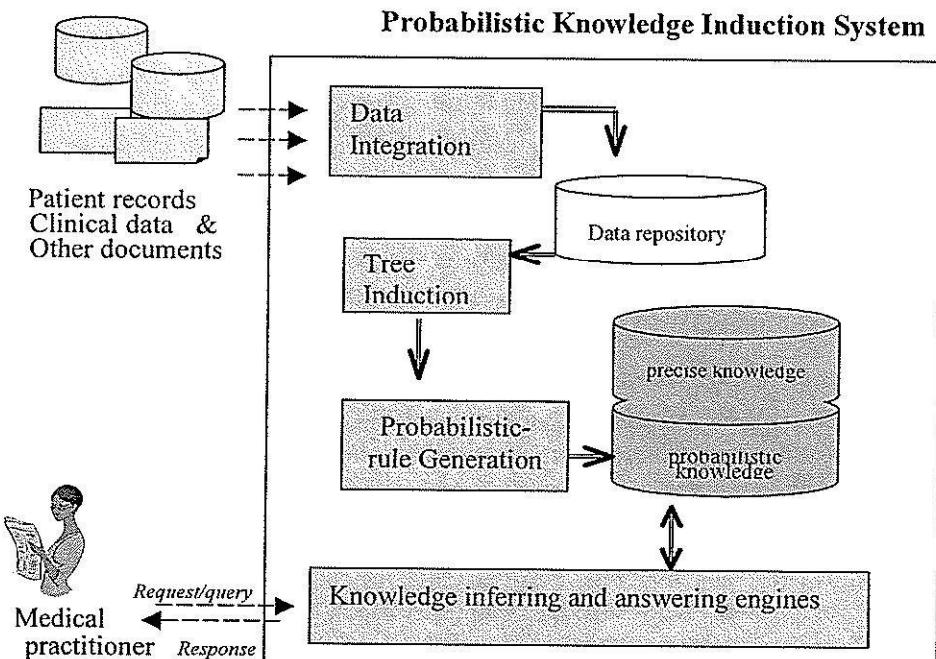


Figure 1. A general framework for the tree-based probabilistic knowledge induction.

In our system framework, we increase interpretability of the knowledge mining results by transforming the decision tree structure into a small set of decision rules. After a complete decision tree has been created, we calculate the probability of case occurrence augmented with each leaf node. In the phase of decision rule generation, these probability values will be sorted. Rules within the top ranking part will be displayed to assist medical practitioner for making decision. In the designed framework, probabilistic knowledge induction system is composed of four main components: data integration, tree induction, probabilistic-rule generation, and the knowledge inferring and answering engines. Data integration component is responsible for collecting data from different sources, cleaning and format transforming. These data are to be used by the tree induction component.

Given the induced tree, the probabilistic-rule generation component traverses each tree branch to calculate the likelihood of path occurrence. This likelihood is interpreted as the probability of event and associated to the rule generated from the path traversal. The generated probabilistic rules are then sorted. Rules at the top ranking (specified by the given minimum probability) are stored in the knowledge base as the probabilistic knowledge and could be used for recommendation or answering query to the medical practitioner. Algorithms for knowledge induction based on tree structure (Algorithm 1), probabilistic-rule generation from decision tree (Algorithm 2), and probabilistic knowledge inferring to answer the most probable class decision on new case (Algorithm 3) are given in the following.

Algorithm 1 Knowledge induction

Input: a data set formatted as Prolog clauses

Output: a decision tree with node and edge structures

- (1) Initialization
 - (1.1) Clear temporary knowledge base (KB) by removing all information regarding the predicates node, edge and current_node
 - (1.2) Set node counter = 0
 - (1.3) Scan data set to get information about data attributes, positive instances, negative instances, total data instances
- (2) Building tree
 - (2.1) Increment node counter
 - (2.2) Repeat steps 2.2.1-2.2.4 until there is no more attributes left for creating decision attributes
 - (2.2.1) Compute Info value of each candidate attribute
 - (2.2.2) Choose the attribute that yields minimum Info to be decision node
 - (2.2.3) Assert edge and node information into KB
 - (2.2.4) Split data instances along node branches
 - (2.3) Repeat steps 2.1 and 2.2 until the lists of positive and negative instances are empty
 - (2.4) Output tree structure containing node and edge predicates

Algorithm 2 Probabilistic knowledge generation

Input: a decision tree with node and edge structures, and a probability threshold

Output: a set of probabilistic rules ranking from the highest probability

- (1) Traverse tree from a root node to each leaf node
 - (1.1) Collect edge information and count number of data instances
 - (1.2) Compute probability as a proportion

$$(\text{number of instances at leaf node}) / (\text{total data instances in a data set})$$
 - (1.3) Assert a rule containing a triplet (attribute-value pair, class, probability value) into KB
- (2) Sort rules in the KB in descending order according to the rules' probability
- (3) Remove rules that have probability less than the specified threshold
- (4) Assert selected rules into the KB and return KB as an output

Algorithm 3 Probabilistic knowledge inferring

Input: a KB containing probabilistic knowledge, and a new case with unknown class value

Output: a decision on most likely class of the new case

- (1) Read all attribute-value pairs appeared in the given case
- (2) Compare the pairs with each relevant rule in the KB to get the decision class value
- (3) Compute the decision confidence as

$$(\text{number of matched attribute-value pair}) \times (\text{probability of the decision rule})$$
- (4) Output a final decision based on the voting scheme

3. IMPLEMENTATION AND EXPERIMENTAL RESULTS

In this section, we present the implementation technique of our proposed tree-based probabilistic-knowledge induction framework using logic programming paradigm. Prolog code is based on the syntax of SWI Prolog (www.swi-prolog.org).

Data format. In logic programming, program and data take the same format, i.e. all are in Prolog clausal form. For the purpose of demonstration, we use the health examination data of 86 patients after the operation. The general conditions such as blood pressure and temperature are observed to determine whether the patient is in good condition and should be sent home shortly (class=home), or the condition is quite moderate and should stay at the hospital ward for further follow up (class=ward). Even though binary classification is a typical task in medical domains, the code presented in this section can be easily modified to classify data with more than two classes. The post-operative data set (downloadable from the UCI repository [1]) in Prolog clausal form is shown some part as the following.

```
attribute( internalTemp,      [mid, high, low]).  
attribute( surfaceTemp,       [mid, high, low]).  
attribute( oxygenSaturation, [excellent, good, fair, poor]).  
attribute( bloodPressure,     [high, mid, low]).  
attribute( tempStability,    [stable, mod-stable, unstable]).  
attribute( coreTempStability, [stable, mod-stable, unstable]).  
attribute( bpStability,      [stable, mod-stable, unstable]).  
attribute( comfort,          [5,7,10,15]).  
attribute( class,             [home, ward]).  
instance(1,class=ward,[internalTemp=mid, surfaceTemp=low, oxygenSaturation=excellent,  
                      bloodPressure=mid, tempStability=stable, coreTempStability=stable,  
                      bpStability=stable, comfort=15]).
```

Main module. The three algorithms, explained in the previous section, are called by the main module, which is the top-level of our program implementation. The Prolog coding of main module is as follows:

```
main:- init(AllAttr,EdgeList), getnode(N),  
       create_edge_onelvel(N,AllAttr,EdgeList),  
       addKnowledge,  
       write(chooseMinProb), read(Min),  
       selectRule(Min,Res), maplist(writeln,Res).
```

The built-in predicate `maplist` is a second-order predicate [8] provided in the library of SWI Prolog. Its implementation is declared recursively as the following. The predicates `init` and `getnode` in main module invoke the following initialization process. The predicates `assert` and `retractall` are also second-order predicates responsible for asserting and removing, respectively, information in the knowledge base. Another second-order predicate `apply` repeatedly assert clauses into the knowledge base. The built-in second-order predicate `findall` searches for all solutions that satisfy the constrained predicates.

Probabilistic-rule generation. In main module, the predicates `addKnowledge` and `selectRule(Min,Res)` are invoked to compute probability along each tree branch to generate probabilistic rules and then select only rules that could occur at the probability level higher than the specified threshold. Prolog coding of this module is as follows:

```
addKnowledge:- findall([A],pathFromRootToLeaf(A,_),Res),  
              retractall(_>>_>>_), maplist(apply(assert),Res).
```

```

selectRule(V,Res) :- findall(N>>X>>Class, (X>>Class>>N, N>=V), Res1),
    sort(Res1,Res2), reverse(Res2,Res).
pathFromRootToLeaf(V>>Class>>Num,C) :- path(1,V,C),
    node(C,Value1-Value2), (Value1=[]; Value2=[]),
    (Value1=[] -> length(Value2, Numb); length(Value1, Numb)),
    total+Total, Num is Numb/Total,
    (Value1=[] -> Class=home; Class=ward).

```

Running results on probabilistic-rule induction. For the demonstration purpose, we show the final result of probabilistic rule induction with a specified minimum threshold 0.02. Each result has been formatted as probability >> rule's conditions (shown as attribute-value pairs) >> decision on class value (either home or ward).

```

0.0930233>>[comfort=10, bloodPressure=high, surfaceTemp=low]>>home
0.0581395>>[comfort=10, bloodPressure=mid, coreTempStability=stable,
internalTemp=mid, bpStability=stable, surfaceTemp=mid,
tempStability=unstable]>>home
0.0465116>>[comfort=10, bloodPressure=high, surfaceTemp=mid,
bpStability=mod_stable]>>home
0.0348837>>[comfort=15, bpStability=unstable, surfaceTemp=mid]>>home
0.0348837>>[comfort=15, bpStability=stable, internalTemp=mid,
tempStability=stable]>>home
0.0348837>>[comfort=10, bloodPressure=mid, coreTempStability=stable,
internalTemp=mid, bpStability=unstable, surfaceTemp=mid,
tempStability=stable]>>home
0.0348837>>[comfort=10, bloodPressure=low]>>home
0.0348837>>[comfort=10, bloodPressure=high, surfaceTemp=mid,
bpStability=stable, oxygenSaturation=excellent]>>home
0.0232558>>[comfort=15, bpStability=unstable, surfaceTemp=high]>>home
0.0232558>>[comfort=15, bpStability=mod_stable]>>home
0.0232558>>[comfort=10, bloodPressure=mid, coreTempStability=unstable,
tempStability=unstable, bpStability=stable]>>ward
0.0232558>>[comfort=10, bloodPressure=mid, coreTempStability=stable,
internalTemp=mid, bpStability=stable, surfaceTemp=low]>>home
0.0232558>>[comfort=10, bloodPressure=mid, coreTempStability=stable,
internalTemp=mid, bpStability=mod_stable,
surfaceTemp=high]>>home
0.0232558>>[comfort=10, bloodPressure=mid, coreTempStability=stable,
internalTemp=low, surfaceTemp=low,
tempStability=stable]>>home
0.0232558>>[comfort=10, bloodPressure=mid, coreTempStability=stable,
internalTemp=high]>>home

```

4. CONCLUSION

Modern healthcare organizations generate huge amount of electronic data stored in heterogeneous databases. Data collected by hospitals and clinics are not yet turned into useful knowledge due to the lack of efficient analysis tools. We thus propose a rapid prototyping of an automatic knowledge-mining tool to induce probabilistic knowledge from medical data. The induced knowledge is to be integrated into the knowledge base of a medical decision support system. Thus, in our design the knowledge base will be composed of precise knowledge as well as a minimal set of induced probabilistic knowledge. Discovered knowledge can also facilitate the reuse of knowledge base among decision-support applications within organizations that own heterogeneous clinical and health databases. Direct application of medical probabilistic knowledge base is for medical related decision-making. Other indirect but obvious application of such knowledge is to pre-process other data sets by grouping it into focused subset containing only relevant data instances.

The main contribution of this work is our implementation of knowledge mining engines based on the concept of higher-order Horn clauses using Prolog language. Higher-order programming has been originally appeared in functional languages in which functions can be passed as

arguments to other functions and can also be returned from other functions. This style of programming has soon been ubiquitous in several modern programming languages such as Perl, PHP, and JavaScript. Higher order style of programming has shown the outstanding benefits of code reuse and high level of abstraction. This paper illustrates higher order programming techniques in SWI-Prolog. The powerful feature of meta-level programming in Prolog facilitates the reuse of mining results represented as rules to be flexibly applied as conditional clauses in other applications.

The plausible extensions of our current work are to add constraints into the knowledge mining method in order to limit the search space and therefore yield the most relevant and timely knowledge, and due to the uniform representation of Prolog's statements as a clausal form, mining from the previously mined knowledge should be implemented naturally. The probabilistic knowledge induction and inferring techniques presented in this paper can be applied to the development of probabilistic databases. We also plan to extend our system to work with stream data that normally occur in modern medical organizations.

REFERENCES

1. Asuncion, A., Newman, D.J.: UCI Machine Learning Repository. University of California, Irvine, CA (2007) <http://archive.ics.uci.edu/ml/>
2. Bojarczuk, C.C. et al.: A Constrained-Syntax Genetic Programming System for Discovering Classification Rules: Application to Medical Data Sets. *Artificial Intelligence in Medicine* 30, 27–48 (2004)
3. He, Y., Tang, Y., Zhang, Y., Sunderraman, R.: Adaptive Fuzzy Association Rule Mining for Effective Decision Support in Biomedical Applications. *Int. J. Data Mining and Bioinformatics* 1, 1, 3–18 (2006)
4. Kononenko, I.: Machine Learning for Medical Diagnosis: History, State of the Art and Perspective. *Artificial Intelligence in Medicine* 1, 89–109 (2001)
5. Kretschmann, E. et al.: Automatic Rule Generation for Protein Annotation with the C4.5 Data Mining Algorithm Applied on SWISS-PROT. *Bioinformatics* 17, 10, 920–926 (2001)
6. Li, J., Fu, A., Fahey, P.: Efficient Discovery of Risk Patterns in Medical Data. *Artificial Intelligence in Medicine* (2008) doi:10.1016/j.artmed.2008.07.008
7. Mugambi, E. et al.: Polynomial-Fuzzy Decision Tree Structures for Classifying Medical Data. *Knowledge-Based System* 17, 2-4, 81–87 (2004)
8. Nadathur, G., Miller, D.: Higher-Order Horn Clauses. *J. ACM* 37, 777–814 (1990)
9. Ordonez, C.: Comparing Association Rules and Decision Trees for Disease Prediction. In: Proc. Int. Workshop on Healthcare Information and Knowledge Management, pp.17–24 (2006)
10. Ohsaki, M., Sato, Y., Yokoi, H., Yamaguchi, T.: A Rule Discovery Support System for Sequential Medical Data in the Case Study of a Chronic Hepatitis Dataset. In: Proc. ECML/PKDD-2003 Discovery Challenge Workshop, http://www.lisp.vse.cz/challenge/ecml_pkdd2003
11. Quinlan, J.R.: Induction of Decision Trees. *Machine Learning* 1, 81–106 (1986)
12. Roddick, J.F. et al.: Exploratory Medical Knowledge Discovery: Experiences and Issues. *ACM SIGKDD Explorations Newsletter* 5, 1, 94–99 (2003)
13. Shillabeer, A., Roddick, J.F.: Establishing a Lineage for Medical Knowledge Discovery. In: Proc. 6th Australasian Conf. on Data Mining and Analytics, pp.29–37 (2007)
14. Zhou, Z., Jiang, Y.: Medical Diagnosis with C4.5 Rule Preceded by Artificial Neural Network Ensemble. *IEEE Transactions on Information Technology in Biomedicine* 1, 37–42 (2003)

ACKNOWLEDGMENTS

This research has been funded by grants from the National Research Council of Thailand (NRCT) and the second author is supported by the Thailand Research Fund (TRF, grant number RMU5080026). DEKD has been fully supported by Suranaree University of Technology.

Knowledge Mining with a Higher-Order Logic Approach

Kittisak Kerdprasop and Nittaya Kerdprasop

Abstract. Knowledge mining is the process of deriving new and useful knowledge from vast volumes of data and patterns previously discovered and stored as background knowledge. We propose a knowledge-mining system as a repertoire of tools for discovering strong and useful patterns. A pattern is strong if it represents frequently occurring relationships. Usefulness is achieved through constraints guided by users. To be able to derive strong and useful patterns from underlying data and background knowledge we consider employing the concept of higher-order logic as a major approach of our implementation. Higher-order logic can greatly reduce the burden of programmers as it is a very high level programming scheme suitable for the development of knowledge-intensive tasks. We have shown in this paper frequent pattern mining implemented with higher-order logic. The implementation is applied to mine breast cancer data. Our design of a logic-based knowledge-mining system is intended to support higher-order and constraint mining which is the next step of our research direction.

1 Introduction

Knowledge is a valuable asset to most organizations as a substantial source to support better decisions and thus to enhance organizational competency. Researchers and practitioners in the area of knowledge management view knowledge in a broad sense as a state of mind, an object, a process, an access to information, or a capability [2, 11]. The term *knowledge assets* [17, 19] is used to refer to any organizational intangible assets related to knowledge such as know-how, expertise, intellectual property. In clinical companies and computerized healthcare applications knowledge assets include order sets, drug-drug interaction rules, guidelines for practitioners, and clinical protocols [10].

Knowledge assets can be stored in data repositories either in implicit or explicit form. Explicit knowledge can be managed through the existing tools available in the current database technology. Implicit knowledge, on the contrary, is harder to

Kittisak Kerdprasop and Nittaya Kerdprasop
Data Engineering and Knowledge Discovery Research Unit,
School of Computer Engineering, Suanaree University of Technology,
Nakhon Ratchasima 30000, Thailand

achieve and retrieve. Specific tools and suitable environments are needed to extract such knowledge.

Implicit knowledge acquisition can be achieved through the availability of the knowledge-mining system. *Knowledge mining* is the discovery of hidden knowledge stored possibly in various forms and places in large data repositories. In health and medical domains, knowledge has been discovered in different forms such as association rules, classification, clustering, trend or temporal pattern analysis [20]. The discovered knowledge facilitates expert decision support, diagnosis and prediction.

In this paper we present the design of a complete knowledge-mining system to support a high-level decision not only in medical domains but also in any domain that requires a knowledge-based decision support. A rapid prototyping of the proposed system is also provided to highlight the fact that higher-order logic is an appropriate approach to the implementation of a complex knowledge-mining system. The intuitive idea of our design and implementation is that for such a complicated knowledge-based system program coding should be done declaratively at a high level to alleviate the burden of programmers. The declarative style of programming also eases the future extension of our system to cover the concepts of higher-order mining [16] and constraint programming [6] that should naturally applied to the task of knowledge mining.

The rest of this paper is organized as follows. Section 2 reviews related works. Section 3 is the architecture of SUT-Miner, the proposed knowledge-mining system. Section 4 shows the implementation of association mining [1] using higher-order logic programming scheme with some running examples. Section 5 concludes the paper and discusses our future research directions.

2 Related Works

In recent years we have witnessed increasing number of applications devising database technology and machine learning techniques to mine knowledge from biomedicine, clinical and health data. Roddick et al [15] discussed the two categories of mining techniques applied over medical data: explanatory and exploratory. Explanatory mining refers to techniques that are used for the purpose of confirmation or making decisions. Exploratory mining is data investigation normally done at an early stage of data analysis in which an exact mining objective has not yet been set.

Explanatory mining in medical data has been extensively studied in the past decade employing various learning techniques. Bojarczuk et al [3] applied genetic programming method with constrained syntax to discover classification rules from medical data sets. Thongkam et al [21] studied breast cancer survivability using AdaBoost algorithms. Ghazavi and Liao [7] proposed the idea of fuzzy modeling on selected features medical data. Huang et al [9] introduced a system to apply mining techniques to discover rules from health examination data. Then they employed a case-based reasoning to support the chronic disease diagnosis and treatments. The recent work of Zhuang et al [25] also combined mining with case-based reasoning, but applied a different mining method. They performed data clustering based on self-organizing maps in order to facilitate decision support on solving new cases of pathology test ordering problem. Biomedical discovery

support systems are recently proposed by a number of researchers [4, 5, 8, 23, 24]. Some works [14, 18] extended medical databases to the level of data warehouses.

Exploratory, as oppose to explanatory, is rarely applied to medical domains. Among the rare cases, Nguyen and Kawasaki [13] introduced knowledge visualization in the study of hepatitis patients. Palaniappan and Ling [14] applied the functionality of OLAP tools to improve visualization.

It can be seen from the literature that most medical knowledge discovery systems have applied only some mining techniques such as classification rules mining, association mining, data clustering to discover hidden patterns and knowledge. We, on the contrary, design a knowledge-mining system aiming at providing a suite of tools to facilitate users and medical practitioners on discovering different kinds of knowledge from their data and background knowledge repositories.

3 SUT-Miner: A Knowledge-Mining system

Knowledge mining is a complex and possibly iterative process that involves many different steps. The main input to the process is data from heterogeneous sources, and the final output is the useful information desired by the users. For the medical domains, we design the system to be composed of two main phases as shown in figure 1. Knowledge induction phase is the back-end of the system responsible for acquiring and discovering new and useful knowledge. Usefulness is to be validated at the final step by human experts. Discovered knowledge is stored in the knowledge base to be applied to solve new cases in knowledge inferring phase which is the front-end of the proposed system.

SUT-Miner in a knowledge induction phase is comprised of three main modules: pre-DM, DM, post-DM. The term data mining (DM) means automatic learning of patterns or models from specific data. *Pattern* is an expression describing a subset of the data, e.g. $f(x) = 3x^2 + 3$ is a pattern induced from a given dataset $\{(0,3), (1,6), (2,15), (3,30)\}$, whereas the term *model* refers to a representation of the source generating the data, e.g. $f(x) = ax^2 + b$. In this paper we refer to both patterns and models as new knowledge discovered from data sources.

The pre-DM module performs data preparation tasks such as to locate and access relevant data sets, transform the data format, clean the data if there exists noise and missing values, reduce the data to a reasonable and sufficient size with only relevant attributes. The DM module performs mining tasks including classification, prediction, clustering, and association. We adopt the ontology concept at this step to guide the mining methodology selection. A simple form of mining method ontology is shown in figure 2. The post-DM module is composed of two main components: knowledge evaluator and knowledge integrator. These components perform major functionalities aiming at a feasible knowledge deployment which is important for the applications in medical diagnosis and predicting. Knowledge evaluator involves evaluation, based on corresponding measurement metrics, of the mining results. Knowledge integrator examines the induced patterns to remove redundant knowledge. Ontology has also been applied at this step to provide essential semantics regarding the domain problems.