


บทที่ 2

วิธีการเตรียมข้อมูลอัตโนมัติก่อนการทำเหมืองข้อมูล (โครงการวิจัยที่ 1)

2.1 วิธีดำเนินการวิจัยโครงการวิจัยที่ 1

2.1.1 กรอบแนวคิดของงานวิจัย

โครงการวิจัยนี้มีวัตถุประสงค์หลักในการออกแบบและพัฒนาซอฟต์แวร์ ที่ทำหน้าที่ เตรียมข้อมูล ให้โปรแกรมทำเหมืองข้อมูลสามารถประมวลผลได้อย่างมีประสิทธิภาพ กรอบแนวคิดเชิงโครงสร้างของซอฟต์แวร์แสดงได้ดังแผนภาพด้านล่าง



รูปที่ 2.1 โครงสร้างซอฟต์แวร์เตรียมข้อมูลก่อนการทำเหมืองข้อมูล

กระบวนการเตรียมข้อมูลจะประกอบด้วยการแปลงข้อมูล (data transformation) การปรับปรุงข้อมูล (data cleaning) และการคัดเลือกข้อมูล (data selection/reduction) ขั้นตอนต่างๆ ใน การดำเนินงานเพื่อพัฒนาซอฟต์แวร์ มีดังต่อไปนี้

ขั้นตอนที่ 1 รวมรวมเอกสารอ้างอิงที่เกี่ยวข้อง และคัดเลือกข้อมูล

รวมรวมเอกสารเกี่ยวกับเทคนิคการจัดการกรณี missing values และเทคนิคการสุ่มข้อมูล (sampling techniques) รวมถึงคัดเลือกข้อมูลเพื่อใช้ทดสอบซอฟต์แวร์ที่ สร้างขึ้น ข้อมูลที่ใช้จะต้องมีขนาดใหญ่เพียงพอที่จะเอื้อให้สามารถทดสอบ ประสิทธิภาพของส่วน reduction ได้ และเป็นข้อมูลที่มีบางส่วนขาดหายไปเพื่อให้ สามารถทดสอบส่วน cleaning ได้ ข้อมูลที่จะคัดเลือกเพื่อใช้ในงานวิจัยนี้ส่วน

หนึ่งจะค้นหามาจาก UCI Repository (<http://archive.ics.uci.edu/ml/datasets.html>)
ซึ่งเป็นแหล่งรวมข้อมูลที่นิยมใช้ในการทำ machine learning

ขั้นตอนที่ 2 ออกรูปแบบโปรแกรม

วางแผนและออกแบบโปรแกรมทั้งสามส่วนของซอฟต์แวร์ และส่วนเชื่อมต่อที่จะประสานการทำงานของทุกส่วน รวมทั้งออกแบบและพัฒนาส่วนที่จะติดต่อกับผู้ใช้ (graphical user interface, GUI)

ขั้นตอนที่ 3 ออกรูปแบบ พัฒนา และทดสอบโปรแกรมส่วน *data transformation*

โปรแกรมแปลงข้อมูลหรือ data transformation ทำหน้าที่แปลงไฟล์ข้อมูลให้ใช้ได้กับระบบการทำเหมืองข้อมูล ข้อมูลเริ่มต้นที่จะเข้ามาสู่ซอฟต์แวร์ทำเหมือง ข้อมูลเป็นข้อมูลที่ประกอบด้วยสองไฟล์อย่างคือ names file และ data file รูปแบบนี้มักจะปรากฏกับข้อมูลใน UCI repository โปรแกรมแปลงข้อมูลที่พัฒนาขึ้นจะสามารถรับ names file และ data file จากนั้นเปลี่ยนรูปแบบข้อมูลแต่ละรายการให้เป็น Horn clauses ที่ภาษาโปรแกรมสามารถประมวลผลได้

ขั้นตอนที่ 4 ออกรูปแบบ พัฒนา และทดสอบโปรแกรมส่วน *data cleaning*

อัลกอริทึมสังเคราะห์ความรู้ (learning or mining algorithm) จำนวนมากไม่สามารถทำงานได้ถ้า input file มีข้อมูลไม่ครบ โปรแกรม data cleaning จึงชูกสร้างขึ้นเพื่อทำหน้าที่เติมข้อมูลที่ขาดหายไปเพื่อให้ input file สมบูรณ์ ดังนั้น โปรแกรม data cleaning จะต้องมีความสามารถตรวจสอบ missing values ใน input file ได้โดยอัตโนมัติ และบรรจุค่าทดแทนส่วนที่ขาดหายไป แนวทางที่ใช้ในงานวิจัยนี้มีได้ 3 แนวทางคือ

- (1) ทดแทนด้วยค่าคงที่ที่สร้างขึ้นมาใหม่, หรือ
- (2) ทดแทนด้วยค่าส่วนใหญ่ของเขตที่นิยมที่สุด, หรือ
- (3) ผู้ใช้อำนวยโภคต์และทรัพยากรที่มี missing values ออกรูปแบบ

ขั้นตอนที่ 5 ออกรูปแบบ พัฒนา และทดสอบโปรแกรมส่วน *data selection / reduction*

โปรแกรม data reduction จะทำหน้าที่ลดขนาดข้อมูลให้สามารถประมวลผลได้ในขั้น mining การลดขนาดจะใช้เทคนิคการสุ่มข้อมูล (sampling) เป็นหลัก โดยผู้ใช้สามารถกำหนดวิธีการสุ่มข้อมูลได้หลายลักษณะ ได้แก่

- การสุ่มจากข้อมูลเดิมโดยไม่ใส่ข้อมูลกลับคืน (random sampling without replacement)

- การสุ่มจากข้อมูลดินโดยได้ข้อมูลกลับคืน (random sampling with replacement) ซึ่งวิธีการนี้จะทำให้ข้อมูลที่ถูกสุ่มปราศจากซ้ำได้
- การสุ่มตามความหนาแน่นของข้อมูล (density-biased sampling) วิธีการนี้จะพิจารณาความหนาแน่นของกลุ่มข้อมูลประกอบการสุ่ม

ขั้นตอนที่ 6 เรียนรู้โปรแกรมทั้งสามส่วนของซอฟต์แวร์เครื่ยมข้อมูล

เมื่อโปรแกรมทั้งสามส่วนเสร็จสมบูรณ์ จะทดสอบความถูกต้องด้วยข้อมูลที่คัดเลือกไว้ในขั้นตอนแรก โดยใช้ข้อมูลจาก UCI repository เมื่อได้ข้อมูลที่ผ่านกระบวนการตรวจสอบแล้ว ข้อมูลนั้นจะถูกส่งไปทดสอบการใช้งานได้จริง ด้วยการรันบนระบบเหมือนข้อมูล

2.1.2 การออกแบบและพัฒนาวิธีการแปลงและปรับปรุงข้อมูล

การแปลงรูปแบบไฟล์ข้อมูล (data transformation) จำแนกเป็นสองงานย่อยคือ การรวมสองไฟล์คือ names file และ data file ให้เป็นข้อมูลไฟล์เดียว จากนั้นแปลงข้อมูลให้อยู่ในรูปแบบ Horn clauses ซึ่งเป็นรูปแบบข้อความในภาษาโปรแกรม

ตัวอย่างของข้อมูลในรูปแบบของ UCI repository แสดง names file และ data file ได้ดังรูปที่ 2.2 รายการข้อมูลจะปรากฏใน data file ข้อมูลหนึ่งบรรทัดคือหนึ่งเรคอร์ด แต่ละบรรทัดหรือบิวต์คั่นด้วยเครื่องหมาย ‘;’ หรือเรียกว่ารูปแบบ CSV (comma separated value) ส่วนที่เป็นคำอธิบายโครงสร้างข้อมูลจะปรากฏใน names file บรรทัดแรกของ names file จะเป็นค่าที่เป็นไปได้ทั้งหมดของคลาส บรรทัดอื่นต่อจากนั้นจะเป็นคำอธิบายชื่อแอฟท์บิวต์และค่าที่เป็นไปได้ทั้งหมดของแอฟท์บิวต์นั้น เมื่อข้อมูลเดียวกันนี้ถูกเปลี่ยนให้อยู่ในรูปแบบ Horn clauses จะมีลักษณะดังรูปที่ 2.3

yes, no.

outlook: sunny, overcast, rain.
 temperature: hot, mild, cool.
 humidity: high, normal.
 windy: true, false.

names file

sunny, hot, high, false, no
 sunny, hot, high, true, no
 overcast, hot, high, false, yes
 rain, mild, high, false, yes
 rain, cool, normal, false, yes
 rain, cool, normal, true, no
 overcast, cool, normal, true, yes
 sunny, mild, high, false, no
 sunny, cool, normal, false, yes
 rain, mild, normal, false, yes
 sunny, mild, normal, true, yes
 overcast, mild, high, true, yes
 overcast, hot, normal, false, yes
 rain, mild, high, true, no

data file

รูปที่ 2.2 ตัวอย่างไฟล์ข้อมูลในรูปแบบ UCI repository

```
% Golf data set
%
% Header file for attribute declaration
attribute(outlook, [sunny, overcast, rainy]).  

attribute(temperature, [hot, mild, cool]).  

attribute(humidity, [high, normal]).  

attribute(windy, [true, false]).  

attribute(class, [yes, no]).  

%
% Data instances
instance(1, class=no, [outlook=sunny, temperature=hot, humidity=high, windy=false]).  

instance(2, class=no, [outlook=sunny, temperature=hot, humidity=high, windy=true]).  

instance(3, class=yes, [outlook=overcast, temperature=hot, humidity=high, windy=false]).  

instance(4, class=yes, [outlook=rainy, temperature=mild, humidity=high, windy=false]).  

instance(5, class=yes, [outlook=rainy, temperature=cool, humidity=normal, windy=false]).  

instance(6, class=no, [outlook=rainy, temperature=cool, humidity=normal, windy=true]).  

instance(7, class=yes, [outlook=overcast, temperature=cool, humidity=normal, windy=true]).  

instance(8, class=no, [outlook=sunny, temperature=mild, humidity=high, windy=false]).  

instance(9, class=yes, [outlook=sunny, temperature=cool, humidity=normal, windy=false]).  

instance(10, class=yes, [outlook=rainy, temperature=mild, humidity=normal, windy=false]).  

instance(11, class=yes, [outlook=sunny, temperature=mild, humidity=normal, windy=true]).  

instance(12, class=yes, [outlook=overcast, temperature=mild, humidity=high, windy=true]).  

instance(13, class=yes, [outlook=overcast, temperature=hot, humidity=normal, windy=false]).  

instance(14, class=no, [outlook=rainy, temperature=mild, humidity=high, windy=true]).
```

รูปที่ 2.3 ตัวอย่างไฟล์ข้อมูลในรูปแบบ Horn clauses

ข้อมูลในรูปแบบ Horn clauses จะยังคงรักษาโครงสร้างของไฟล์ข้อมูลที่ประกอบด้วย ส่วนอธิบายแอ็ททริบิวต์ และส่วนรายละเอียดข้อมูล เพียงแต่ข้อมูลจะถูกเปลี่ยนจากข้อความปกติ เป็นข้อความที่เรียกว่า clause ในภาษาโปรแกรมที่มีข้อกำหนดว่าแต่ละ clause จะสิ้นสุดด้วย เครื่องหมาย ‘.’ และข้อมูลหนึ่งรายการจะถูกแปลงเป็น Horn clause หนึ่งคลอส ขั้นตอนในการ แปลงรูปแบบข้อมูลจาก UCI repository เป็น Horn clauses จะเริ่มจากการแปลงโครงสร้างข้อมูลใน names file ให้เป็นคลอส attribute(Attribute Name, [List-of-Attribute Values]) เมื่อแปลงส่วน โครงสร้างเสร็จแล้ว จึงจะเริ่มอ่าน data file และแปลงข้อมูลแต่ละรายการเป็นคลอส instance(ID, Class= Value, [Attribute Name=Value]) รายละเอียดการทำงานแสดงได้ดังอัลกอริทึมที่ 2.1

Algorithm 2.1 Data transformation

Input: names file and data file

Output: a data file as Horn clauses

- (1) Open names file and read the value list in the first line
- (2) Write to the output file the clause ‘attribute(class, [value list]).’
- (3) While not end-of-file do
 - (3.1) Read attribute name
 - (3.2) Read attribute-value list
 - (3.3) Write to the output file the clause ‘attribute(attribute name, [value list]).’
- (4) Close names file
- (5) Open data file
- (6) Set instance counter I = 1
- (7) While not end-of-file do
 - (7.1) Read each value that appears in CSV format
 - (7.2) Match attribute name with corresponding attribute value
 - (7.3) Construct attribute-value pair format (i.e. attributeName=value)
 - (7.4) Remove last attribute-value pair to be class-value
 - (7.5) Write a clause ‘instance(I, class-value, [attribute-value list]).’ to output file
 - (7.6) Increment I
- (8) Close data file
- (9) Return the output file

ข้อมูลที่ผ่านขั้นตอนการแปลงไฟล์ข้อมูลแล้ว จะถูกส่งต่อมายังส่วนปรับปรุงข้อมูล (data cleaning) การปรับปรุงข้อมูลจะเกิดขึ้นเมื่อข้อมูลประกอบ missing values ซึ่งในรูปแบบของข้อมูล UCI repository เมื่อข้อมูลบางแอฟทรีบิวต์หายไปหรือไม่ปรากฏค่า จะปรากฏสัญลักษณ์ ‘?’ ในตำแหน่งของข้อมูลที่แอฟทรีบิวต์นั้น ตัวอย่างของข้อมูลที่มี missing values แสดงได้ดังรูปที่ 2.4

```

attribute( outlook, [sunny, overcast, rainy] ).  

attribute( temperature, [hot, mild, cool] ).  

attribute( humidity, [high, normal] ).  

attribute( windy, [true, false] ).  

attribute( class, [yes, no] ).  

% Data instances  

instance(1, class=no, [outlook=sunny, temperature=hot, humidity=?], windy=?]).  

instance(2, class=no, [outlook=sunny, temperature=hot, humidity=high, windy=true]).  

instance(3, class=yes, [outlook=overcast, temperature=hot, humidity=high, windy=?]).  

instance(4, class=yes, [outlook=rainy, temperature=mild, humidity=high, windy=false]).  

...

```

รูปที่ 2.4 ตัวอย่างไฟล์ข้อมูลที่ปราบกู้ missing values

การปราบกู้ missing values จะมีผลเสียต่อกระบวนการการทำเหมือนข้อมูล ทำให้ไม่โมเดลที่ความเชื่อมั่นลดลง ข้อมูลที่เป็นตัวแทนที่ดีจึงไม่ควรมีค่า missing วิธีจัดการกับกรณีข้อมูลหายไปในงานวิจัยนี้จะสร้างทางเลือกให้ผู้ใช้เลือกได้สามแนวทางคือ (1) ทดสอบค่าที่หายไปด้วยข้อความ ‘missing’ และเมื่อในโมเดลที่เป็นเข้าที่พุทธากรการทำเหมือนข้อมูล ปราบกู้คำว่า ‘missing’ ผู้ใช้จะสามารถเปลี่ยนความหมายได้ว่าหมายถึงการไม่ปราบกู้ค่าในแอฟทรีบิวต์, (2) ทดสอบค่าที่หายไปด้วยค่าส่วนใหญ่ของแอฟทรีบิวต์ ในกรณีนี้เมื่อผู้ใช้แปดผลโมเดลจะไม่ทราบว่าโมเดลนั้นได้จากการวิเคราะห์ข้อมูลที่มี missing values, และ (3) ผู้ใช้สามารถเลือกตัดทิ้งแอฟทรีบิวต์ที่มี missing values ปราบกู้อยู่มาก รายละเอียดการทำงานในส่วนปรับปรุงข้อมูลแสดงได้ดังอัลกอริทึมที่ 2.2

Algorithm 2.2 Data cleaning

Input: a data file containing Horn clauses with some missing values

Output: a data file that its contents had been cleaned

-
- (1) Show the GUI of data cleaning component
 - (2) Get the response from user's choice
 - (3) If choice = ‘replace with missing’, then
 - (3.1) Read each data instance
 - (3.2) Replace attributeName=? with attributeName=missing
 - (4) If choice = ‘replace with majority’, then
 - (4.1) Scan the whole data set
 - (4.2) Count the majority value of each attribute
 - (4.3) Read each data instance
 - (4.3) Replace attributeName=? with attributeName=majority
 - (5) If choice = ‘remove attribute with missing values’, then
 - Call feature selection module to remove unwanted attributes
 - (6) Return the output file that all the missing cases have been cleaned
-

2.1.3 การออกแบบและพัฒนาวิธีการคัดเลือกข้อมูล

การคัดเลือกข้อมูลในงานวิจัยนี้หมายถึง การคัดเลือกแอกซอฟท์แวร์บิวต์ (feature selection) และการคัดเลือกข้อมูลบางรายการด้วยวิธีการสุ่ม (random sampling) การคัดเลือกแอกซอฟท์แวร์บิวต์จะมีประโยชน์ในการลดขนาดของโมเดล และการสุ่มจะช่วยลดขนาดของข้อมูล และอาจช่วยให้ได้ข้อมูลที่เป็นคุณภาพที่ดีเพื่อการสังเคราะห์โมเดลที่มีความแม่นยำลงขั้น

การคัดเลือกแอกซอฟท์แวร์จะใช้วิธีวิเคราะห์การกระจายของข้อมูล แล้วแสดงเป็นภาพในตัวอย่างของฮิสโตแกรม (histogram) จากนั้นจะให้ผู้ใช้ระบุชื่อแอกซอฟท์แวร์ที่ต้องการคัดเลือกไว้ ขั้นตอนการคัดเลือกแอกซอฟท์แสดงได้ดังขั้นตอนที่ 2.3

Algorithm 2.3 Feature selection

Input: a data file that contains complete Horn clauses

Output: a data file with reduced features

- (1) Show the GUI of feature selection component
- (2) Get the user's response to obtain the desired attribute names
- (3) Scan the input data file
 - (3.1) Remove unwanted attribute clauses from the header file
 - (3.2) Remove unwanted 'attributeName=value' from every instance clauses
 - (3.3) Write the new clauses to the output file
- (4) Return the output file

ในส่วนของการคัดเลือกรายการข้อมูลด้วยวิธีการสุ่ม (random sampling) ผู้ใช้สามารถเลือกวิธีการสุ่มได้ว่าจะใช้การสุ่มแบบมีการไส้ข้อมูลคืนกลับ (random sampling with replacement) หรือการสุ่มแบบไม่ไส้ข้อมูลคืนกลับ (random sampling without replacement) การสุ่มแบบไส้ข้อมูลคืนกลับนั้นจะใช้ในกรณีที่ข้อมูลที่จะถูกสุ่มนั้นมีปริมาณไม่มากนัก และการไส้ข้อมูลคืนกลับนี้ผลให้ข้อมูลบางรายการถูกสุ่มซ้ำๆ ได้มากกว่าหนึ่งครั้ง ส่วนการสุ่มแบบไม่ไส้ข้อมูลคืนกลับจะใช้เมื่อชุดข้อมูลที่จะถูกสุ่มนั้นมีปริมาณมาก การสุ่มทั้งสองแบบนี้เป็นการสุ่มแบบอิสระนั่นคือข้อมูลทุกตัวมีโอกาสเท่ากันที่จะถูกเลือก วิธีการสุ่มข้อมูลแสดงได้ดังขั้นตอนที่ 2.4


Algorithm 2.4 Data sampling**Input:** a data file**Output:** a data file with reduced instances

-
- (1) Show the GUI of random sampling component
 - (2) Get the user's response to obtain the desired random sampling methods and the percentage of sample size
 - (3) Set the instance counter, I = 0
 - (4) Compute the number of instances to be sampled, S
 - (5) If choice = 'random sampling with replacement', then
 - (5.1) Generate random number, N, $N \in [1..TotalInstances]$
 - (5.2) Write the instance N to the output file
 - (5.3) Increment I
 - (5.4) If $I < S$, then repeat step (5)
 - (6) If choice = 'random sampling without replacement', then
 - (6.1) Generate random number, N, $N \in [1..TotalInstances]$
 - (6.2) If instance N does not appear in the input file,
 - (6.2.1) Then re-generate the random number N
 - (6.2.2) Otherwise write the instance N to the output file
 - (6.3) Delete instance N from the input file
 - (6.4) Increment I
 - (6.5) If $I < S$, then repeat step (6)
 - (7) Assert header (attribute clauses) to the output file
 - (8) Return the output file
-

2.1.3 การคัดเลือกข้อมูลตามความหนาแน่น

การคัดเลือกข้อมูลด้วยการสุ่มในแบบ random sampling จะใช้คตขนาดข้อมูลได้ดีในกรณีที่ข้อมูลมีการกระจายอย่างสม่ำเสมอ แต่ในกรณีที่ข้อมูลมีการกระจายไม่สม่ำเสมอ เช่นเมื่อข้อมูลหนาแน่นในบางช่วง แต่ในช่วงอื่นๆ มีข้อมูลเบาบางมาก ถ้าให้ใช้วิธี random sampling (ที่สุ่มในแบบ with replacement และ without replacement) ที่ข้อมูลแต่ละตัวมีโอกาสถูกคัดเลือกเท่าๆ กัน ข้อมูลที่ถูกสุ่มน้ำอาจจะไม่คงลักษณะการกระจายตัวเหมือนข้อมูลดั้งเดิมก่อนที่จะถูกสุ่ม ในงานวิจัยนี้จึงเสนอแนวทางการสุ่มข้อมูลแบบที่เรียกว่า การสุ่มตามความหนาแน่น (density-biased sampling) เพื่อประโยชน์ในการคงลักษณะการกระจายตัวของข้อมูล และจะทำให้ได้โมเดลที่สอดคล้องกับรูปแบบข้อมูล

การสุ่มข้อมูลตามความหนาแน่นมีแนวคิดที่แสดงเป็นแผนภาพได้ดังรูปที่ 2.5 ในรูปแสดงข้อมูลแต่ละรายการด้วยสัญลักษณ์ ‘•’ จากรูปจะเห็นได้ว่าข้อมูลมีการเกาะกลุ่มเป็นสองกลุ่มใหญ่ (ตีกรอบกลุ่มข้อมูลด้วยเส้นประ) ในขณะที่ข้อมูลที่อยู่นอกกรอบกระจายตัวอย่างเป็นระเบียบ ดังนั้นถ้าต้องการสุ่มข้อมูลตัวแทนจากข้อมูลทุคนี้ ข้อมูลที่ถูกเลือกเป็นตัวแทน ควรจะเป็นข้อมูลจากสองกลุ่มใหญ่นี้ การสุ่มข้อมูลจากกลุ่มที่มีความหนาแน่นสูงจะมีประโยชน์ในการกำจัดข้อมูลที่ไม่เข้ากลุ่ม หรือ outliers และในบางครั้งสามารถกำจัดข้อมูลที่เป็นข้อมูลที่ผิดพลาด หรือ noisy data การกำจัด noisy data และ outliers จะช่วยให้ได้โมเดลที่มีความถูกต้องสูงและลดปัญหา overfitting



รูปที่ 2.5 แนวคิดของการสุ่มข้อมูลตามความหนาแน่น

วิธีการสุ่มข้อมูลตามความหนาแน่น จะให้ผู้ใช้กำหนดเกณฑ์ขึ้นต่อว่าจะพิจารณาความหนาแน่นด้วยค่าในกําลังทริบิวต์ (M , Minimum number of attributes) และจะต้องการสุ่มข้อมูลที่มีความหนาแน่นขึ้นต่ำเท่าไร (D , Density) โดยที่ $D \in [0..1]$ จากนั้นเริ่มต้นทำงานด้วยการเปิดไฟล์ และอ่านข้อมูลที่จะรายการเพื่อตรวจสอบข้อมูลที่อยู่ใกล้เคียง การวัดความใกล้เคียงใช้การเปรียบเทียบค่าในแต่ละแท่งทริบิวต์ ถ้ามีค่าคล้ายกันอย่างน้อย M แหล่งทริบิวต์ถือว่าเป็นข้อมูลที่เกาะกลุ่มอยู่ใกล้กัน ตรวจสอบข้อมูลใกล้เคียงเช่นนี้กับข้อมูลทุกรายการ จากนั้นนับจำนวนว่ามีข้อมูลที่รายการที่จัดว่าอยู่ใกล้เคียง คำนวณค่าข้อมูลใกล้เคียงให้เป็นค่าสัดส่วนโดยหารด้วยจำนวนข้อมูลทั้งหมดในไฟล์ ทำการตรวจสอบเช่นนี้กับข้อมูลทุกรายการ จากนั้นคัดเลือกไว้เฉพาะข้อมูลที่มีค่า D ถึงเกณฑ์ที่ระบุ แล้วสุ่มจากข้อมูลในกลุ่มนี้ให้ได้จำนวนข้อมูลตามที่ต้องการ ขั้นตอนเหล่านี้แสดงในอัลกอริทึมที่ 2.5

Algorithm 2.5 Density-biased sampling

Input: a data file, sample size S,
minimum number of matched attributes M, minimum density D

Output: a data file with reduced instances

- (1) Show the GUI of density-biased sampling component
- (2) Get the user's response to obtain the sample size S,
minimum number of matched attributes M, density threshold D
- (3) Set the instance counter, I = 0
- (4) Compute the number of instances to be sampled, SS
- /* Compute similar instances and their density values */
- (5) Open data file and read data instance
- (6) For each data instance do
 - (6.1) Scan data file to collect instances, Ins, with matched attributes $\geq M$
 - (6.2) Compute density, Den, as proportion of Ins to total instances in data file
 - (6.3) If $Den \geq D$, then record this instance in temporary file F
- /* Sampling from the dense area */
- (7) If instances in F $\leq SS$, then output file is F
- (8) Otherwise,
 - (8.1) Generate random number, N, $N \in [1..TotalInstancesInF]$
 - (8.2) Write the instance N to the output file
 - (8.3) Increment I
 - (8.4) If $I < SS$, then repeat step (8.1)
- (9) Assert header (attribute clauses) to the output file
- (10) Return the output file

2.2 การทดสอบโปรแกรมเตรียมข้อมูลอัตโนมัติก่อนการทำเหมืองข้อมูล**2.2.1 การทดสอบ Data transformation**


การทดสอบความถูกต้องของโปรแกรมในการแปลงรูปแบบเพิ่มข้อมูล ได้ทดสอบกับข้อมูลจาก UCI repository จำนวนหลายชุดข้อมูล แต่ในรายงานนี้จะนำเสนอผลการทดสอบกับข้อมูลเพียงชุดเดียวเท่านั้นเนื่องจากผลการทดสอบเป็นเรื่องเดียวกันทั้งหมด ชุดข้อมูลที่ใช้เป็นตัวอย่างคือข้อมูล golf (Quinlan, 1993) ที่เป็นข้อมูลการตัดสินใจของนักกอล์ฟว่าจะออกไปเล่น/ไม่ออกไปเล่นกอล์ฟ การตัดสินใจพิจารณาจากสภาพท้องฟ้า อุณหภูมิ ความชื้นในบรรยากาศ และ

ความแรงของคุณ ข้อมูลที่ใช้มีจำนวน 14 รายการ เป็นข้อมูลที่เป็นชื่อความ (categorical, nominal) ทั้งหมด และเพื่อให้สามารถทดสอบการจัดการกับข้อมูลสูญหายได้ กำหนดให้ข้อมูลสองรายการมี ข้อมูลไม่ครบถ้วน (แทนด้วยสัญลักษณ์ "?") ได้แก่ ข้อมูลรายการที่สองที่มีค่าในแอ็ฟทริบิวต์ที่สอง หายไป และข้อมูลรายการที่สี่ที่มีค่าในแอ็ฟทริบิวต์ที่สามหายไป ข้อมูลในส่วน names file (golf.names) และ data file (golf.data) แสดงดังรูปที่ 2.6

File	Edit	Format	View	Help
golf - Notepad yes, no. outlook: sunny, overcast, rain. temperature: hot, mild, cool. humidity: high, normal. windy: true, false.				
E:\golf - Notepad File Edit Format View Help sunny, hot, high, false, no sunny, ?, high, true, no overcast, hot, high, false, yes rain, mild, ?, false, yes rain, cool, normal, false, yes rain, cool, normal, true, no overcast, cool, normal, true, yes sunny, mild, high, false, no sunny, cool, normal, false, yes rain, mild, normal, false, yes sunny, mild, normal, true, yes overcast, mild, high, true, yes overcast, hot, normal, false, yes rain, mild, high, true, no				
golf.names		golf.data		

รูปที่ 2.6 ข้อมูลที่ใช้ทดสอบการทำงานของโปรแกรมเตรียมข้อมูล

การเตรียมข้อมูลเริ่มต้นจากการเรียกใช้โปรแกรม data transformation ที่จะปรากฏหน้าจอ ให้ตอบกับผู้ใช้ดังแสดงในรูปที่ 2.7 ผู้ใช้จะใส่ชื่อไฟล์โดยไม่ต้องระบุส่วนขยาย พร้อมกันนี้จะสามารถ เลือกวิธีการจัดการกับกรณีข้อมูลสูญหายได้สามรูปแบบ คือ แทนด้วย "?" หรือแทนด้วยข้อความ 'missing' หรือแทนด้วยค่าส่วนใหญ่ของข้อมูล (mode)



รูปที่ 2.7 ซอฟต์แวร์ Data transformation

2.2.2 การทดสอบ Data cleaning

จากจอภาพเรื่มนั้นค้างรูปที่ 2.7 ที่ผู้ใช้เลือกที่จะแทนค่าที่หายไปด้วยข้อความ ‘missing’ เมื่อคลิกที่ปุ่ม Enter ในหน้าต่างของ SWI Prolog จะแสดงการทำงานในระหว่างการแปลงข้อมูลดังรูปที่ 2.8 และเมื่อการแปลงข้อมูลเสร็จสิ้น จะปรากฏไฟล์ข้อมูลชื่อ ‘golf_out’ ในไดเรกทอรีเดียวกับข้อมูล golf.names และ golf.data

```

?- transmenu.
true.

?- [121, 101, 115, 44, 32, 110, 111, 46][yes, no]
[111, 117, 116, 108, 111, 111, 107, 58, 32, 115, 117, 110, 110, 121, 44, 32, 111, 118,
114, 99, 97, 115, 116, 44, 32, 114, 97, 105, 110, 46][outlook, sunny, overcast, rain]

assertCN=c1[116, 101, 109, 112, 101, 114, 97, 116, 117, 114, 101, 58, 32, 104, 111, 11
, 32, 109, 105, 108, 100, 44, 32, 99, 111, 111, 108, 46][temperature, hot, mild, cool]

assertCN=c2[104, 117, 109, 105, 1
, 111, 114, 109, 97, 108, 46][hum]

assertCN=c3[119, 105, 110, 100, 1
, 111, 114, 109, 97, 108, 46][outlook, sunny, overcast, rain]

?- [golf, golf, golf_out]

```

Name	Size	Type
golf	1 KB	NAMES File
golf	1 KB	DATA File
golf_out	2 KB	File

รูปที่ 2.8 จอภาพของ SWI Prolog ขณะแปลงข้อมูล และไฟล์ golf_out ที่ได้

ข้อมูลในไฟล์ golf_out ที่ได้จากการรวมไฟล์ golf.names และ golf.data รวมทั้งได้มีการแทนที่ค่าสูญหายในข้อมูลรายการที่สองและรายการที่สี่ด้วยข้อความ ‘missing’ แสดงได้ดังรูปที่ 2.9 แต่ถ้าเปลี่ยนวิธีการจัดการกับข้อมูลสูญหายให้แทนที่ด้วยค่าส่วนใหญ่ (นั่นคือผู้ใช้เลือก mode) จะปรากฏข้อมูลใน golf_out ดังรูปที่ 2.10 ที่นำค่าส่วนใหญ่ในแอ็พทริบิวต์นั้นมาแทนที่

```
% file golf_out
name(golf).
missingT(missing).
attribute(class, [yes, no]).
attribute(outlook, [missing, sunny, overcast, rain]).
attribute(temperature, [missing, hot, mild, cool]).
attribute(humidity, [missing, high, normal]).
attribute(windy, [missing, true, false]).

instance(1, class=no, [outlook=sunny, temperature=hot, humidity=high, windy=false]).
instance(2, class=no, [outlook=sunny, temperature=missing, humidity=high, windy=true]).
instance(3, class=yes,[outlook=overcast, temperature=hot, humidity=high, windy=false]).
instance(4, class=yes,[outlook=rain, temperature=mild, humidity=missing, windy=false]).
instance(5, class=yes,[outlook=rain, temperature=cool, humidity=normal, windy=false]).
instance(6, class=no, [outlook=rain, temperature=cool, humidity=normal, windy=true]).
instance(7, class=yes,[outlook=overcast, temperature=cool, humidity=normal, windy=true]).
instance(8, class=no, [outlook=sunny, temperature=mild, humidity=high, windy=false]).
instance(9, class=yes,[outlook=sunny, temperature=cool, humidity=normal, windy=false]).
instance(10,class=yes,[outlook=rain, temperature=mild, humidity=normal, windy=false]).
instance(11, class=yes,[outlook=sunny, temperature=mild, humidity=normal, windy=true]).
instance(12, class=yes,[outlook=overcast, temperature=mild, humidity=high, windy=true]).
instance(13, class=yes,[outlook=overcast, temperature=hot, humidity=normal, windy=false]).
instance(14, class=no, [outlook=rain, temperature=mild, humidity=high, windy=true]).
```

รูปที่ 2.9 ข้อมูลในไฟล์ golf_out ที่ค่าที่สูญหายถูกแทนที่ด้วยข้อความ ‘missing’


```
% file golf_out
name(golf).
missingT(missing).
attribute(class, [yes, no]).
attribute(outlook, [missing, sunny, overcast, rain]).
attribute(temperature, [missing, hot, mild, cool]).
attribute(humidity, [missing, high, normal]).
attribute(windy, [missing, true, false]).

instance(1, class=no, [outlook=sunny, temperature=hot, humidity=high, windy=false]).
instance(2, class=no, [outlook=sunny, temperature=mild, humidity=high, windy=true]).
instance(3, class=yes,[outlook=overcast, temperature=hot, humidity=high, windy=false]).
instance(4, class=yes,[outlook=rain, temperature=mild, humidity=normal, windy=false]).
instance(5, class=yes,[outlook=rain, temperature=cool, humidity=normal, windy=false]).
instance(6, class=no, [outlook=rain, temperature=cool, humidity=normal, windy=true]).
instance(7, class=yes,[outlook=overcast, temperature=cool, humidity=normal, windy=true]).
instance(8, class=no, [outlook=sunny, temperature=mild, humidity=high, windy=false]).
instance(9, class=yes,[outlook=sunny, temperature=cool, humidity=normal, windy=false]).
instance(10,class=yes,[outlook=rain, temperature=mild, humidity=normal, windy=false]).
instance(11, class=yes,[outlook=sunny, temperature=mild, humidity=normal, windy=true]).
instance(12, class=yes,[outlook=overcast, temperature=mild, humidity=high, windy=true]).
instance(13, class=yes,[outlook=overcast, temperature=hot, humidity=normal, windy=false]).
instance(14, class=no, [outlook=rain, temperature=mild, humidity=high, windy=true]).
```

รูปที่ 2.10 ข้อมูลในไฟล์ golf_out ที่ค่าที่สูญหายถูกแทนที่ด้วยค่าส่วนใหญ่

2.2.3 การทดสอบ Feature selection

เมื่อมีการเรียกใช้ฟังก์ชัน feature selection ในโมดูล preprocess ที่เป็นโมดูลสำหรับคัดเลือกข้อมูล จะปรากฏหน้าจอดังรูปที่ 2.11 ในหน้าจอโดยอัตโนมัติจะปรากฏกรอบข้อความให้ผู้ใช้พิมพ์ชื่อไฟล์ที่มีรูปแบบข้อมูลเป็น Horn clauses ซึ่งจากตัวอย่างก่อนหน้าไฟล์ที่ใช้จะเป็นชื่อ golf_out ในบรรทัดต่อมาจะเป็นส่วนที่ให้ผู้ใช้ระบุชื่อแอ็ททริบิวต์ที่ต้องการ รายชื่อแอ็ททริบิวต์จะพิมพ้อยู่ภายในวงเล็บ [] ซึ่งแทนโครงสร้างลิสต์ในภาษาโปรแกรม จากภาระนุ่มนวลชื่อแอ็ททริบิวต์ [outlook, humidity, windy] โดยตัดทึ่งแอ็ททริบิวต์ temperature ในบรรทัดที่สามและสี่เป็นภาระนุ่มนวลและปริมาณข้อมูลที่ต้องการ ถ้าผู้ใช้ต้องการทำ feature selection อย่างเดียวสามารถระบุค่าเบอร์เซนต์เป็น 100 ข้อมูลที่ได้หลังจากทำ feature selection และคงไว้ดังรูปที่ 2.12



รูปที่ 2.11 จากการส่วน Feature selection และ Data sampling

```

File Edit Format View Help

%Density Parameter=[1.0,0.1] Sampling[Percent,Type]=[100,1]


%Want 14 records, but has 14 records
attribute(outlook, [missing, sunny, overcast, rain]).
attribute(humidity, [missing, high, normal]).
attribute(windy, [missing, true, false]).
attribute(class, [yes, no]).

instance(1, class=yes, [outlook=overcast,
humidity=high,      windy=true]),
instance(2, class=yes, [outlook=rain,
humidity=missing,   windy=false]),
instance(3, class=no, [outlook=sunny,
humidity=high,      windy=true]),
instance(4, class=yes, [outlook=sunny,
humidity=normal,    windy=true]),
instance(5, class=yes, [outlook=overcast,
humidity=normal,    windy=false]),
instance(6, class=yes, [outlook=overcast,
humidity=normal,    windy=true]),
instance(7, class=no, [outlook=sunny,
humidity=high,      windy=false]),
instance(8, class=yes, [outlook=rain,
humidity=normal,    windy=false]),
instance(9, class=no, [outlook=sunny,
humidity=high,      windy=false]),
instance(10, class=yes, [outlook=sunny,
humidity=normal,    windy=false]),
instance(11, class=yes, [outlook=rain,
humidity=normal,    windy=false]),
instance(12, class=yes, [outlook=overcast,
humidity=high,      windy=false]),
instance(13, class=no, [outlook=rain,
humidity=normal,    windy=true]),
instance(14, class=no, [outlook=rain,
humidity=mild,      windy=true]).
```

รูปที่ 2.12 ผลลัพธ์ของ Feature selection โดยระบุแอ็ททริบิวต์ [outlook, humidity, windy]

2.2.4 การทดสอบ Sampling with replacement

จากข้อมูลเริ่มต้นในรูปแบบ Horn clauses จำนวน 14 รายการที่มีการแทนค่าที่สูญหายในรายการที่สองและตี่ด้วยข้อความ ‘missing’ เมื่อนำมาทดสอบโปรแกรมสุ่มข้อมูลในรูปแบบการสุ่มแบบไส้ค่ากลับคืนด้วยเปลี่ยนต่อการสุ่ม 50% ให้ผลลัพธ์เป็นข้อมูลที่ลดจำนวนลงเหลือ 7 รายการ (นั่นคือจะเหลือข้อมูลเพียง 7 รายการ) ดังรูปที่ 2.13 และเนื่องจากการสุ่มเป็นแบบที่มีการไส้ค่ากลับคืนในผลลัพธ์จึงปรากฏข้อมูลซ้ำกันข้อมูลในรายการที่ 1 และรายการที่ 5



The Preprocess dialog box shows the following settings:

- Datafile: golf_out
- Choose attribute: [outlook, humidity, windy]
- Sampling 1WithOut 2With Replacement: 2
- Percent: 50
- Density parameter: [1,0.01]

Below the dialog box, the generated code is as follows:

```

File Edit Format View Help

%Density Parameter=[1,0.01] Sampling[Percent,Type]=[50,2]

%Want 7 records, but has 14 records
attribute(outlook, [missing, sunny, overcast, rain]).
attribute(humidity, [missing, high, normal]).
attribute(windy, [missing, true, false]).
attribute(class, [yes, no]).

instance(7, class=yes, [outlook=overcast, humidity=normal, windy=true]).
instance(5, class=yes, [outlook=rain, humidity=normal, windy=false]).
instance(11, class=yes, [outlook=sunny, humidity=normal, windy=true]).
instance(3, class=yes, [outlook=overcast, humidity=high, windy=false]).
instance(1, class=no, [outlook=sunny, humidity=high, windy=false]).
instance(1, class=no, [outlook=sunny, humidity=high, windy=false]).
instance(5, class=yes, [outlook=rain, humidity=normal, windy=false]).
```

รูปที่ 2.13 ผลลัพธ์ของการสุ่มข้อมูลแบบมีการไส้ค่ากลับคืน

2.2.5 การทดสอบ Sampling without replacement

การทดสอบขนาดของข้อมูลด้วยการสุ่มแบบไม่ไส่ค่ากลับคืน ทดสอบกับข้อมูล golf_out และระบุขนาดของข้อมูลที่ต้องการสุ่มเป็น 50% แสดงผลทดสอบความถูกต้องของโปรแกรมได้ดังรูปที่ 2.14 จากรูปจะเห็นว่าข้อมูลที่ปรากฏในผลลัพธ์มีจำนวน 7 รายการซึ่งคิดเป็น 50% ของข้อมูลตั้งต้น และรายการข้อมูลที่ปรากฏจะไม่ซ้ำกัน

The screenshot shows the 'Preprocess' dialog box with the following settings:

- Datafile: golf_out
- Choose attribute: [outlook, humidity, windy]
- Sampling 1WithOut 2With Replacement: 1 2
- Percent: 50
- Density parameter: [1,0.01]
- Buttons: Cancel, Enter

Below the dialog box, the command-line output is displayed:

```

File Edit Format View Help


%Density Parameter=[1,0.01] Sampling[Percent,Type]=[50,1]

%Want 7 records, but has 14 records
attribute(outlook, [missing, sunny, overcast, rain]).
attribute(humidity, [missing, high, normal]).
attribute(windy, [missing, true, false]).
attribute(class, [yes, no]).
instance(3, class=yes, [outlook=overcast, humidity=high, windy=false]).
instance(2, class=no, [outlook=sunny, humidity=high, windy=true]).
instance(5, class=yes, [outlook=rain, humidity=normal, windy=false]).
instance(11, class=yes, [outlook=sunny, humidity=normal, windy=true]).
instance(1, class=no, [outlook=sunny, humidity=high, windy=false]).
instance(12, class=yes, [outlook=overcast, humidity=high, windy=true]).
instance(8, class=no, [outlook=sunny, humidity=high, windy=false]).
```

รูปที่ 2.14 การสุ่มข้อมูลที่ขนาด 50% และไม่มีการไส่ค่ากลับคืน


2.2.6 การทดสอบ Density-biased sampling

การสุ่มตามความหนาแน่นเป็นวิธีการสุ่มที่จะต้องมีเกณฑ์กำหนดสองอย่างคือ จำนวน แอพทริบิวต์ที่จะใช้เปรียบเทียบข้อมูลแต่ละรายการกับข้อมูลอื่นๆ เพื่อกำหนดค่าความหนาแน่น ของข้อมูลใกล้เคียง เกณฑ์ที่สองคือสัดส่วนขั้นต่ำของจำนวนข้อมูลที่อยู่ใกล้เคียง ก่อตัวสัดส่วนนี้จะอยู่ระหว่าง [0.0-1.0] เช่นถ้าข้อมูลทั้งหมดมีจำนวน 10 รายการ สัดส่วนขั้นต่ำที่ 0.2 จะหมายถึงต้องมีจำนวนข้อมูลใกล้เคียงมากถึงอย่างน้อยสองรายการ การทดสอบความถูกต้องของโปรแกรมสุ่มข้อมูลตามความหนาแน่นตามที่ปรากฏในรูปที่ 2.15 เป็นการสุ่มข้อมูลด้วยปริมาณ 20% นั่นคือจะต้องสุ่มข้อมูลมา 3 รายการ มีการกำหนดเกณฑ์ความหนาแน่นเป็น [3, 0.23] หมายถึงพิจารณาสุ่มข้อมูลที่มีความหนาแน่นหรือมีข้อมูลอยู่ใกล้เคียงอยู่ในสัดส่วนขั้นต่ำ 0.23 หรือคิดเป็นข้อมูล 3 รายการจากทั้งหมด 14 รายการ เกณฑ์ความใกล้เคียงพิจารณาจากค่าที่เหมือนกันอย่างน้อย 3 แอพทริบิวต์ จากเกณฑ์ความหนาแน่นที่กำหนดทำให้มีข้อมูลที่สุ่มได้เพียงหนึ่งรายการ จากที่ต้องการทั้งหมดสามรายการ ทั้งนี้เนื่องจากระบุเกณฑ์ความหนาแน่นสูงเกินไป



รูปที่ 2.15 การสุ่มตามความหนาแน่นด้วยเกณฑ์ขั้นต่ำ [3, 0.23]

จากข้อมูล golf_out เมื่อเปลี่ยนค่าความหนาแน่นในการสุ่มข้อมูล โดยกำหนดให้พิจารณาค่าที่เหมือนกันจากจำนวนแอ็ฟทรีบิต่อป่างน้อยหนึ่งแอ็ฟทรีบิวต์ ความหนาแน่นขั้นต่ำของข้อมูลคือ 0.14 หรือคิดเป็นจำนวนข้อมูลอย่างน้อยสองรายการ ขนาดของข้อมูลสุ่มที่ต้องการคือ 60% จะได้ผลลัพธ์ดังรูปที่ 2.16



```

File Edit Format View Help

%Density Parameter=[1,0.14] Sampling[Percent,Type]=[60,1]

%Want 8 records, but has 14 records
attribute(outlook, [missing, sunny, overcast, rain]).
attribute(humidity, [missing, high, normal]).
attribute(windy, [missing, true, false]).
attribute(class, [yes, no]).

instance(4, class=yes, [outlook=rain, humidity=missing, windy=false]).
instance(5, class=yes, [outlook=rain, humidity=normal, windy=false]).
instance(11, class=yes, [outlook=sunny, humidity=normal, windy=true]).
instance(10, class=yes, [outlook=rain, humidity=normal, windy=false]).
instance(7, class=yes, [outlook=overcast, humidity=normal, windy=true]).
instance(13, class=yes, [outlook=overcast, humidity=normal, windy=false]).
instance(12, class=yes, [outlook=overcast, humidity=high, windy=true]).
instance(1, class=no, [outlook=sunny, humidity=high, windy=false]).
```


รูปที่ 2.16 ผลลัพธ์ของการสุ่มตามความหนาแน่นด้วยเกณฑ์ขั้นต่ำ [1, 0.14]

2.3 สรุปผลการวิจัยที่ 1

การทำเหมือนข้อมูลเป็นวิัฒนาการของเทคโนโลยีฐานข้อมูล ที่ต้องการใช้ประโยชน์จากข้อมูลให้มากที่สุด การประมวลผลข้อมูลทำให้ทราบสารสนเทศที่ช่วยสร้างความเข้าใจเกี่ยวกับรายละเอียดข้อมูลได้มากขึ้น การทำเหมือนข้อมูลเป็นพัฒนาการของการประมวลผลอีกขั้นหนึ่งที่ช่วยให้ทราบรูปแบบหรือแพทเทิร์นของข้อมูลและสารสนเทศ การทราบรูปแบบจะช่วยให้เราคาดหมายหรือทำนายแนวโน้มการเปลี่ยนแปลงของข้อมูลที่จะเกิดขึ้นในอนาคตได้ วิัฒนาการจากข้อมูลไปเป็นสารสนเทศและจากสารสนเทศไปเป็นความรู้แสดงได้ดังรูปที่ 2.17

(<http://www.outsights.com/systems/dikw/dikw.htm>)


สารสนเทศ (information) เกิดจากการรวบรวมและประมวลข้อมูลเพื่อให้ข้อมูลที่อาจจะถูกเก็บสะสมไว้ แต่ข้อมูลเหล่านี้มีความเกี่ยวข้องเชื่อมโยงกันจึงถูกนำมารวมเป็นกลุ่มเดียวกันและแสดงให้อยู่ในรูปแบบที่ง่ายต่อการทำความเข้าใจ ส่วนความรู้ (knowledge) เกิดจากนำข้อมูลที่มีการเชื่อมโยงนั้นมาวิเคราะห์หารูปแบบของการเชื่อมโยงหรือหาปัจจัยหลักที่ก่อให้เกิดการเชื่อมโยง เมื่อวิเคราะห์ทราบเหตุและปัจจัยแล้วประโยชน์สูงสุดของการประมวลข้อมูลคือช่วยให้เรามีความฉลาด (wisdom) เหตุแห่งความฉลาดคือการวิเคราะห์จากข้อมูลจนกระทั่งสามารถสร้างความเข้าใจในเชิงหลักการเกี่ยวกับข้อมูลนั้นได้



รูปที่ 2.17 พัฒนาการของข้อมูลที่ถูกเปลี่ยนเป็นสารสนเทศและความรู้

กิจกรรมวิเคราะห์ข้อมูลในลักษณะของการทำเหมือนข้อมูล จัดเป็นกระบวนการใหญ่ที่ประกอบด้วยขั้นตอนย่อยๆ หลายขั้นตอน (แสดงดังรูปที่ 2.18) โดยทั่วไปขั้นตอนเหล่านี้จะประกอบด้วย การรวบรวมข้อมูลที่อาจจะกระจายอยู่ในหลายแหล่ง หรือถูกบันทึกไว้ในหลายฐานข้อมูล ข้อมูลที่รวบรวมมานี้อาจจะบันทึกไว้ในคลังข้อมูลเพื่อความสะดวกในการเรียกใช้โดย

โปรแกรมทำเหมืองข้อมูล หรืออาจจะบันทึกไว้ในลักษณะของไฟล์ข้อมูลไฟล์เดียวก็ได้ โดยปกติแล้วข้อมูลเหล่านี้ยังไม่สามารถใช้ในการทำเหมืองข้อมูลได้โดยตรงเนื่องจากรูปแบบ คุณภาพ และขนาดของข้อมูลยังไม่เหมาะสม จึงต้องมีกระบวนการตรียนข้อมูลก่อนการทำเหมืองข้อมูล



รูปที่ 2.18 ขั้นตอนต่างๆ ในกระบวนการทำเหมืองข้อมูล

การเตรียมข้อมูลเป็นขั้นตอนที่สำคัญและมักจะใช้เวลามาก เนื่องจากต้องมีการเปลี่ยนรูปแบบเพื่อข้อมูล (data transformation) มีการตรวจสอบรายการข้อมูลว่ามีความครบถ้วนสมบูรณ์ (data cleaning) เพราะถ้าข้อมูลไม่ครบถ้วน โปรแกรมทำเหมืองข้อมูลจะไม่สามารถประมวลผลได้ นอกจากนี้ยังต้องมีการคัดเลือกข้อมูล (data selection) โดยการเลือกเฉพาะทริบิวต์ หรือ feature ที่แสดงลักษณะเด่นของข้อมูลได้ค่อนข้างดี การคัดเลือกเฉพาะทริบิวต์ (feature selection) อย่างเหมาะสมจะช่วยให้โปรแกรมทำเหมืองข้อมูลสามารถแสดงโมเดลที่มีความถูกต้องสูง และมีขนาดไม่ใหญ่จนเกินไป การคัดเลือกข้อมูลบางรุ่นถึงการคัดเลือกรายการข้อมูล (data instances) ที่เป็นตัวแทนที่ดีของข้อมูลกลุ่มใหญ่

การมีข้อมูลตัวแทนที่ดีจะช่วยให้การทำเหมืองข้อมูลแสดงผลลัพธ์เป็นโมเดลที่ถูกต้อง มีโครงสร้างไม่ซับซ้อนและได้ผลลัพธ์ในเวลาที่รวดเร็ว การคัดเลือกรายการข้อมูลนี้จะมีความสำคัญมากในกรณีที่ข้อมูลเก็บข้อมูลสดเรื่ม เนื่องจากข้อมูลประเภทนี้จะเกิดขึ้นอย่างต่อเนื่อง และมีปริมาณข้อมูลมาก การคัดเลือกเฉพาะข้อมูลตัวแทนมาวิเคราะห์มาโมเดลจึงมีความสำคัญต่อประสิทธิภาพการประมวลผลของโปรแกรมทำเหมืองข้อมูล