

# CSC662 ปฏิบัติการ ๓

กฎเชื่อมโยงในซอฟต์แวร์ Weka

เขียนโดย พศ. ดร. กรุง สินอภิรมย์สราญ

ภาควิชาคณิตศาสตร์ คณะวิทยาศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

## เนื้อหาที่ครอบคลุม

- เก็บข้อมูลเชื่อมโยงในซอฟต์แวร์ Weka
- การเตรียมแฟ้มข้อมูล
- ขั้นตอนวิธี Apriori
- การแปลผล
- การใช้ขั้นตอนวิธี Apriori กับข้อมูลที่ไม่ใช่ Transaction

2

คุณรุ่นใจ

06/18/07

## การทำเหมือนข้อมูลแบบกฎเชื่อมโยง

- ใช้กับ Market Basket analysis
- กฎบ่งบอกพฤติกรรมการซื้อของลูกค้า
- ปกติใช้กับฐานข้อมูลเชิงสัมพันธ์ที่บันทึกเป็น Transaction โดยที่แต่ละระเบียนคือการซื้อสินค้าในหนึ่งครั้ง
- ผลลัพธ์ที่ต้องการได้คือ กฎแสดงความสัมพันธ์ของการซื้อสินค้าต่างชนิดกันโดยไม่ขึ้นกับลูกค้าคนใดคนหนึ่ง

## ข้อมูลที่นำมาใช้

รหัสการซื้อ	รายการสินค้า
T100	I1, I2, I5
T200	I2, I4
T300	I2, I3
T400	I1, I2, I4
T500	I1, I3
T600	I2, I3
T700	I1, I3
T800	I1, I2, I3, I5
T900	I1, I2, I3

3

คุณรุ่นใจ

06/18/07

4

คุณรุ่นใจ

06/18/07

## การเตรียมแฟ้มข้อมูล

- ลักษณะประจำของสินค้าคือชื่อสินค้าที่พิจารณา
  - ลักษณะประจำตัวแรกคือรหัสการซื้อสินค้า TID ที่ไม่นำมาใช้ในการวิเคราะห์ใช้เพื่อการเชื่อมโยงกลับไปยังฐานข้อมูลเริ่มต้นเท่านั้น
  - ค่าในลักษณะประจำเป็น boolean เช่นกำหนดค่าที่เป็นไปได้คือ y แทนการใช้ตัวเลข 1
    - ตัวอย่าง การซื้อ T100, I1, I2 เปลี่ยนเป็น T100, 1, 1, ?, ?, ?
- ในซอฟต์แวร์ Weka ลักษณะ ? แทนค่าที่หายไป (missing value)

5

คุณชื่นใจ

06/18/07

## แฟ้ม market.arff


```
@relation market
@attribute tid {T100, T200, T300, T400, T500, T600, T700, T800, T900}
@attribute I1 {y}
@attribute I2 {y}
@attribute I3 {y}
@attribute I4 {y}
@attribute I5 {y}
@data
T100,y,y,?,?
T200,?,y,?,?
T300,?,y,y,?
T400,y,y,?,y
T500,y,?,y,?
T600,?,y,y,?
T700,y,?,y,?
T800,y,y,y,?
T900,y,y,?,?
```

6

คุณชื่นใจ

06/18/07


## การเปิดแฟ้ม Market.arff



## การเลือกขั้นตอนวิธี Apriori

- เลือกແນວ Associate
- ภายใต้ Associator เลือก Apriori

กดปุ่มในกล่อง Associator เพื่อปรับเปลี่ยนค่าพารามิเตอร์สำหรับ Apriori




8

คุณชื่นใจ

06/18/07


## ตัวเลือกในขั้นตอนวิธี Apriori



- ปรับค่า min support ในกล่อง lowerBoundMinSupport เช่น 0.2 (หมายถึงค่าสนับสนุนต่ำสุด 20%)
- ปรับค่า min confidence ในกล่อง minMetric โดย metricType เป็น Confidence เช่น 0.5 (หมายถึงค่าความเชื่อมั่นต่ำสุด 50%)
- ปรับจำนวนกฎที่แสดงผลในกล่อง numRules เช่น 100

06/18/07

## การประมวลผลของขั้นตอนวิธี Apriori



## 16 กฎที่ได้จาก market.arff

- |                                    |                                       |
|------------------------------------|---------------------------------------|
| 1. I5=y 2 ==> I1=y 2 conf:(1)      | 9. I1=y 6 ==> I3=y 4 conf:(0.67)      |
| 2. I4=y 2 ==> I2=y 2 conf:(1)      | 10. I3=y 6 ==> I2=y 4 conf:(0.67)     |
| 3. I5=y 2 ==> I2=y 2 conf:(1)      | 11. I2=y 7 ==> I1=y 4 conf:(0.57)     |
| 4. I2=y I5=y 2 ==> I1=y 2 conf:(1) | 12. I2=y 7 ==> I3=y 4 conf:(0.57)     |
| 5. I1=y I5=y 2 ==> I2=y 2 conf:(1) | 13. I2=y I3=y 4 ==> I1=y 2 conf:(0.5) |
| 6. I5=y 2 ==> I1=y I2=y 2 conf:(1) | 14. I1=y I3=y 4 ==> I2=y 2 conf:(0.5) |
| 7. I1=y 6 ==> I2=y 4 conf:(0.67)   | 15. I1=y I2=y 4 ==> I3=y 2 conf:(0.5) |
| 8. I3=y 6 ==> I1=y 4 conf:(0.67)   | 16. I1=y I2=y 4 ==> I5=y 2 conf:(0.5) |

ความหมายของกฎที่ 1: การซื้อสินค้าของลูกค้าที่มีสินค้า I5 และจะมีสินค้า I1 เสมอ  
ความหมายของกฎที่ 2: การซื้อสินค้าของลูกค้าที่มีสินค้า I4 และจะมีสินค้า I2 เสมอ

11

06/18/07

## ลักษณะข้อมูลที่ไม่ใช่ตระกร้าชื่อ

- การทำเหมืองข้อมูลแบบกฎเชื่อมโยงสามารถนำไปใช้กับข้อมูลที่ไม่ใช่ transaction ได้ โดยใช้การเข้ารหัส dummy coding คือซอฟต์แวร์จะแปลงค่าของ Nominal หรือ Ordinal หนึ่งค่าแทนด้วยตัวแปรทวิภาคหนึ่งตัว เช่น
- ลักษณะประจำ outlook มีค่าที่เป็นไปได้คือ overcast, sunny, rainy แล้วตัวแปรทวิภาคเดียวกันจะเป็น outlook = overcast, outlook = sunny, outlook = rainy

06/18/07

## ไฟล์ weather.nominal.arff


```
@relation weather.symbolic
@attribute outlook {sunny, overcast, rainy}
@attribute temperature {hot, mild, cool}
@attribute humidity {high, normal}
@attribute windy {TRUE, FALSE}
@attribute play {yes, no}
@data
sunny,hot,high,FALSE,no
sunny,hot,high,TRUE,no
overcast,hot,high,FALSE,yes
rainy,mild,high,FALSE,yes
rainy,cool,normal,FALSE,yes
rainy,cool,normal,TRUE,no
overcast,cool,normal,TRUE,yes
sunny,mild,high,FALSE,no
sunny,cool,normal,FALSE,yes
rainy,mild,normal,FALSE,yes
sunny,mild,normal,TRUE,yes
overcast,mild,high,TRUE,yes
overcast,hot,normal,FALSE,yes
rainy,mild,high,TRUE,no
```

13

คุณชื่นใจ

06/18/07

## ผลลัพธ์ที่ได้จาก weather.nominal.arff



## 8 กฎที่ได้จาก weather.nominal.arff

- outlook=overcast 4 => play=yes 4 conf:(1)
- temperature=cool 4 => humidity=normal 4 conf:(1)
- humidity=normal windy=FALSE 4 => play=yes 4 conf:(1)
- outlook=sunny play=no 3 => humidity=high 3 conf:(1)
- outlook=sunny humidity=high 3 => play=no 3 conf:(1)
- outlook=rainy play=yes 3 => windy=FALSE 3 conf:(1)
- outlook=rainy windy=FALSE 3 => play=yes 3 conf:(1)
- temperature=cool play=yes 3 => humidity=normal 3 conf:(1)

ความหมายของกฎที่ 1:ถ้าสภาพอากาศเป็น overcast แล้ว play=yes เสมอ

ความหมายของกฎที่ 2:ถ้าอุณหภูมิเป็น cool และความชื้นจะปกติ (normal) เสมอ

ความหมายของกฎที่ 3:ถ้าความชื้นปกติและไม่มีลม windy=FALSE แล้ว

play=yes เสมอ

15

คุณชื่นใจ

06/18/07

## สรุป

- ไฟล์ข้อมูลที่ถูกนำมาใช้ในการวิเคราะห์ต้องประกอบด้วยลักษณะประจำที่เป็น Nominal หรือ Ordinal เท่านั้น
- ข้อมูลในลักษณะ transaction เป็นข้อมูล Nominal และการไม่ซื้อใช้? (missing value) แทน TID, attri\_1, attri\_2, ..., attri\_n
  - เมื่อ TID แทนรหัสการซื้อและแต่ละ attri\_i มีค่า y หรือ ?
- เลือก Associate และใช้ Apriori ให้ Associator
- ปรับค่าพารามิเตอร์ min support กับ min confidence และ numRules ที่ต้องการแล้วสั่งให้ประมวลผล

16

คุณชื่นใจ

06/18/07