

CSC662 ปฏิบัติการ ๙

ต้นไม้การตัดสินใจในซอฟต์แวร์ Weka

เขียนโดย พศ. ดร. กรุง สินอภิรัมย์สราญ

ภาควิชาคณิตศาสตร์ คณะวิทยาศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

เนื้อหาที่ครอบคลุม

- การทำเหมืองข้อมูลการจัดจำแนกประเภท Classification
- การเตรียมข้อมูลสำหรับการจัดจำแนกประเภท
- การเลือกใช้ต้นไม้การตัดสินใจ
- ผลลัพธ์ที่ได้โดยใช้ ID3 ซึ่งไม่ใช้ลักษณะประจำที่เป็นค่าต่อเนื่อง
- ผลลัพธ์ที่ได้โดยใช้ J48 ซึ่งใช้ได้กับลักษณะประจำที่ต่อเนื่องและไม่ต่อเนื่อง

2

ซอฟต์แวร์ Weka

การทำเหมืองข้อมูลการจัดจำแนกประเภท

- เป็นการสร้างตัวแบบ Classifier ที่สามารถแบ่งแยกข้อมูล (ตัวอย่าง) ออกตาม คลาสหรือลักษณะประจำเป้าหมายที่กำหนด
- ตัวแบบที่ต้องการอาจเป็น
 - bayes ใช้หลักของเบย์หรือตัวแบบเชิงความน่าจะเป็น
 - functions ตัวแบบในรูปของฟังก์ชัน
 - lazy ตัวแบบที่เก็บตัวอย่าง การตัดสินใจเกิดเมื่อตัวอย่างใหม่ถูกนำเข้าเท่านั้น
 - meta การทำตัวแบบให้ดีขึ้นโดยการเรียนข้อมูลเดา
 - misc วิธีการสร้างตัวแบบวิธีอื่น
 - trees การสร้างตัวแบบโดยใช้ต้นไม้
 - rules การสร้างตัวแบบโดยใช้กฎ

3

ซอฟต์แวร์ Weka

แฟ้มตัวอย่าง Weather.nominal.arff

No.	outlook	temperature	humidity	windy	play
1	sunny	hot	high	FALSE	no
2	sunny	hot	high	TRUE	no
3	overcast	hot	high	FALSE	yes
4	rainy	mild	high	FALSE	yes
5	rainy	cool	normal	FALSE	yes
6	rainy	cool	normal	TRUE	no
7	overcast	cool	normal	TRUE	yes
8	sunny	mild	high	FALSE	no
9	sunny	cool	normal	FALSE	yes
10	rainy	mild	normal	FALSE	yes
11	rainy	mild	normal	TRUE	yes
12	overcast	mild	high	TRUE	yes
13	overcast	hot	normal	FALSE	yes
14	rainy	mild	high	TRUE	no

ลักษณะประจำเป้าหมาย
เป็นลักษณะประจำสำคัญที่อยู่ในตาราง

ตัวอย่างมีทั้งหมด 14 ตัวอย่าง
และมีลักษณะประจำที่ไม่ใช่
ลักษณะประจำเป้าหมาย 4 ตัว

4

ซอฟต์แวร์ Weka



การเตรียมเพิ่มข้อมูล

- กำหนดลักษณะประจำเป้าหมายให้เป็นลักษณะประจำสำคัญที่ต้องการ
- บางขั้นตอนวิธีที่ใช้สร้างดันไม่การตัดสินใจต้องการลักษณะประจำที่มีค่าไม่ต่อเนื่องเท่านั้น ดังนั้นเราจำเป็นต้องเปลี่ยนลักษณะประจำที่มีค่าต่อเนื่องให้เป็นลักษณะประจำที่มีค่าไม่ต่อเนื่อง
- ในกรณีที่มีระเบียนน้อย เราอาจใช้ k-fold cross validation หรือ leave-one-out
- ในการพิจารณาที่มีระเบียนมากเพียงพอ เราควรแบ่งกันระเบียนบางส่วน เป็น validation, test data และที่เหลือนำมายังเป็น training data สัดส่วนที่ใช้อาจเป็น 3/10, 3/10 กับ 4/10

5


การใช้งานซอฟต์แวร์ Weka explorer

- เริ่มการทำงานของซอฟต์แวร์ Weka เปิดโมดูล Explorer
- เปิดแฟ้ม weather.nominal.arff
- แปลงลักษณะประจำที่มีค่าต่อเนื่องเป็นลักษณะประจำที่มีค่าไม่ต่อเนื่องโดยใช้ filter ก่อนเดือดแบบ Classify




7

ซอฟต์แวร์ Weka



8


ซอฟต์แวร์ Weka




9




10



11



12



13

ซอฟต์แวร์ Weka

ไฟล์ weather.arff

```
@data
sunny,85,85,TRUE,no
sunny,80,90,TRUE,no
overcast,83,86,TRUE,no
rainy,70,96,TRUE,no
rainy,68,80,TRUE,no
rainy,65,70,TRUE,no
overcast,64,65,TRUE,no
sunny,72,95,TRUE,no
sunny,69,70,TRUE,no
rainy,75,80,TRUE,no
sunny,75,70,TRUE,no
overcast,72,90,TRUE,no
overcast,81,75,TRUE,no
rainy,71,91,TRUE,no
```


14

ซอฟต์แวร์ Weka

การเปลี่ยนลักษณะประจำให้เป็นค่าไม่ต่อเนื่อง


- เลือก Discretize ในกล่อง Filter โดยเลือก filters → unsupervised → attribute
- ปรับค่าในกล่อง bins ให้เหมาะสม เช่นกำหนดให้เป็น 3 กล่อง
- กดปุ่ม OK
- แล้วกด Apply

ซอฟต์แวร์ Weka



15

ผลที่ได้
จากการ
แปลงเป็น
ค่าไม่ต่อ
เนื่อง



16

ซอฟต์แวร์ Weka

การทำเหมือนข้อมูลแบบจัดจำแนกประเภท ID3

```

Classifier output
Correctly Classified Instances      14          100    %
Incorrectly Classified Instances   0           0     %
Kappa statistic                   1
Mean absolute error               0
Root mean squared error          0
Relative absolute error          0
Root relative squared error     0
Total Number of Instances        14

*** Detailed Accuracy By Class ***

TP Rate   FP Rate   Precision   Recall   F-Measure   ROC Area   Class
1         0         1           1         1           1           yes
1         0         1           1         1           1           no

*** Confusion Matrix ***

a b <-- classified as
9 0 | a = yes
0 5 | b = no


```

17

จากการที่ใช้ Weka

- เลือก Id3 ในกล่อง Classifier ให้แบบ Classify โดย classifiers → trees → Id3
- เลือก Use training set ในกล่อง Test options
- กดปุ่ม Start
- จะได้ผลลัพธ์ดังรูปด้านซ้าย

ต้นไม้ที่ได้จาก ID3



ต้นไม้มีการตัดสินใจดังกล่าวสามารถจำแนก play ถูกต้อง 100%

==== Confusion Matrix ===

```

a b <-- classified as
9 0 | a = yes
0 5 | b = no

```

18

จากการที่ใช้ Weka

การทำเหมือนข้อมูลแบบจัดจำแนกประเภท J48

```

Classifier output
Correctly Classified Instances      14          100    %
Incorrectly Classified Instances   0           0     %
Kappa statistic                   1
Mean absolute error               0
Root mean squared error          0
Relative absolute error          0
Root relative squared error     0
Total Number of Instances        14

*** Detailed Accuracy By Class ***

TP Rate   FP Rate   Precision   Recall   F-Measure   ROC Area   Class
1         0         1           1         1           1           yes
1         0         1           1         1           1           no

*** Confusion Matrix ***


a b <-- classified as
9 0 | a = yes
0 5 | b = no

```

19

จากการที่ใช้ Weka


- เลือก J48 ในกล่อง Classifier ให้แบบ Classify โดย classifiers → trees → J48
- เราไม่จำเป็นต้องเปลี่ยนลักษณะประจำให้เป็นชนิดที่มีค่าไม่ต่อเนื่อง
- เลือก Use training set ในกล่อง Test options
- กดปุ่ม Start
- จะได้ผลลัพธ์ดังรูปด้านซ้าย



20

จากการที่ใช้ Weka

ต้นไม้ที่ได้จาก J48



ต้นไม้การตัดสินใจดังกล่าวสามารถจำแนก play ถูกต้อง 100%

==== Confusion Matrix ====
a b <- classified as
9 0 | a = yes
0 5 | b = no

21

สรุป

- การทำหนึ่งข้อมูลแบบจัดจำแนกประเภท มีขั้นตอนวิธีในการสร้างตัวแบบหมาย
- การใช้ต้นไม้ในการบ่งบอกตัวแบบก็เป็นหนึ่งในวิธีดังกล่าว
- สำหรับขั้นตอนวิธี Id3 ลักษณะประจำทุกตัวต้องมีค่าไม่ต่อเนื่อง
- แต่ขั้นตอนวิธี J48 ลักษณะประจำไม่จำเป็นต้องมีค่าไม่ต่อเนื่อง

22

จากการ Weka