

# CSC662 Data Mining, Data Warehouse and Visualization

บทที่ 9 การทำเหมืองข้อมูลแบบจัดจำแนกประเพณีแบบเบย์ส  
เดรียม โอดิ พศ. ดร. กรุง สินอภิรมย์สารุจ  
ภาควิชาคณิตศาสตร์ คณะวิทยาศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

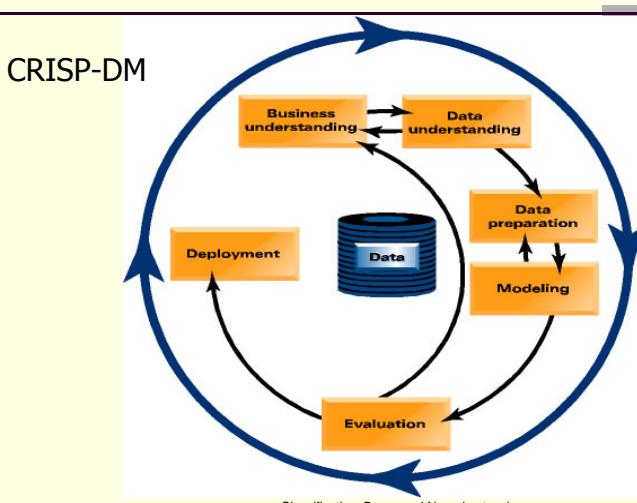
## โครงสร้าง

- การจำแนกประเพณีโดยใช้ความน่าจะเป็น
- การจำแนกประเพณีโดยใช้กฎของเบย์ส
- กฎผู้เชื่อเบย์ส
- การแก้ปัญหาโดยใช้ Laplace estimator
- สมมติฐานการเป็นอิสระต่อกัน
- การจำแนกประเพณีโดยใช้เครือข่ายของเบย์ส
- การประเมินความถูกต้องของผลลัพธ์

Classification: Bayes and Neural network

2

## กระบวนการค้นหาความรู้



Classification: Bayes and Neural network

3

## สถิติกับการจัดจำแนกประเพณี

- ปัญหการจัดจำแนกประเพณีปัญหาที่นักสถิติสนใจนานในรูปที่ตัวแปรตาม (Response variable) มีค่าที่ไม่ต่อเนื่อง
- แนวคิดในการจัดการกับตัวแปรตามหรือคลาสเป้าหมายที่มีค่าไม่ต่อเนื่อง ทำได้โดยใช้การแจกแจง กล่าวคือสำหรับตัวอย่างที่ไม่ทราบค่าคลาสเป้าหมาย จะให้ผลลัพธ์เป็นความน่าจะเป็นที่ตัวอย่างดังกล่าวจะอยู่ในกลุ่มของคลาสเป้าหมายกกลุ่มใด กลุ่มหนึ่ง ซึ่งการประมาณค่าความน่าจะเป็นของการเกิดเหตุการณ์สามารถใช้ความถี่สัมพัทธ์ได้ในกรณีที่ข้อมูลมีปริมาณมากพอ
- วิธีการนี้ก็ถูกใช้เป็นมาตรฐานสำหรับเปรียบเทียบกับวิธีการอื่น

Classification: Bayes and Neural network

4

## การจัดจำแนกประเภทโดยใช้กฎของเบย์

- เป็นการเรียนรู้โดยใช้ความน่าจะเป็น: คำนวณการแจกแจงค่าความน่าจะเป็นตามสมมติฐานที่ตั้งให้กับข้อมูล
- เป็นการเรียนรู้เพิ่ม ได้: ตัวอย่างใหม่ที่ได้มาลูกน้ำมาปรับเปลี่ยนการแจกแจงซึ่งมีผลต่อการเพิ่ม/ลดความน่าจะเป็น ทำให้มีการเรียนรู้ที่เปลี่ยนไป วิธีการนี้ ตัวแบบจะถูกปรับเปลี่ยนไปตามตัวอย่างใหม่ที่ได้โดยผนวกกับความรู้เดิมที่มี
- การทำนายค่าคลาสเป้าหมายของตัวอย่างใหม่ใช้ความน่าจะเป็นที่มากที่สุดของทุกสมมติฐาน
- เป็นตัวกลางในการเปรียบเทียบกับขั้นตอนวิธีอื่น: วิธีการของเบย์ (Bayes) ถูกใช้เป็นมาตรฐานในการเปรียบเทียบกับวิธีการอื่น

Classification: Bayes and Neural network

5

## ทฤษฎีของเบย์ (Bayesian theorem)

- ให้  $D$  แทนข้อมูลที่นำมาใช้ในการคำนวณการแจกแจงความน่าจะเป็น posteriori probability ของสมมติฐาน  $h$  คือ  $\Pr(h|D)$  ตามทฤษฎีของเบย์

$$\Pr(h|D) = \frac{\Pr(D|h)\Pr(h)}{\Pr(D)}$$

- ใช้หลักการ MAP (maximum posteriori) hypothesis

$$h_{MAP} \equiv \arg \max_{h \in H} \Pr(h|D) = \arg \max_{h \in H} \Pr(D|h)\Pr(h).$$

- สังเกตว่าการทำนายได้จากการคำนวณความน่าจะเป็นแบบมีเงื่อนไขในทุกสมมติฐาน ซึ่งขึ้นกับจำนวนค่าที่เป็นไปได้ทั้งหมดของตัวแปรตาม

Classification: Bayes and Neural network

6

## ตัวอย่างการคำนวณค่าความน่าจะเป็นจาก weather

- จากข้อมูลใน weather.arff คลาสเป้าหมายคือ play ซึ่งมีค่าเป็น yes หรือ no การแจกแจงความน่าจะเป็นสำหรับค่าคลาสเป้าหมายตามตัวแบบจริงๆ คือ

Outlook	yes	no	Humidity	yes	no
sunny	2/9	3/5	high	3/9	4/5
overcast	4/9	0	normal	6/9	1/5
rain	3/9	2/5			
Temperature	yes	no	Windy	yes	no
hot	2/9	2/5	true	3/9	3/5
mild	4/9	2/5	false	6/9	2/5
cool	3/9	1/5			

Classification: Bayes and Neural network

7

## Bayesian classification

- Bayesian classification คือปัญหาการจำแนกข้อมูลตาม **a-posteriori probabilities:**

$$\Pr(\text{class} = c_i | X) = \text{ความน่าจะเป็นที่ } X = (x_1, \dots, x_k) \text{ จะเป็น } c_i \text{ เช่น}$$

$$\Pr(\text{class} = N | \text{outlook} = \text{sunny}, \text{windy} = \text{true}, \dots)$$

- วิธีคิด: เรากล่าวว่าตัวอย่าง  $X$  เป็น  $c_i$  ถ้าค่า  $\Pr(\text{class} = c_i | X)$  มีค่าสูงสุดเมื่อเทียบกับค่า  $c_j$  อื่น ๆ

Classification: Bayes and Neural network

8

## การประมาณ a-posteriori probability

### ■ ทฤษฎีของ Bayes:

$$\Pr(\text{class} = c|X) = \Pr(X|\text{class} = c) \cdot \Pr(\text{class} = c)/\Pr(X)$$

ข้อสังเกตว่า  $\Pr(X)$  ไม่เปลี่ยนสำหรับค่าคลาส  $c$  ที่เปลี่ยนไป

■  $\Pr(\text{class} = c) \approx$  ความถี่สัมพัทธ์ของตัวอย่างในคลาส  $c$

$$\Pr(\text{class}=c|X) \text{ สูงสุดก็ต่ำเมื่อ } \Pr(X|\text{class}=c) \cdot \Pr(\text{class}=c) \text{ สูงสุด}$$

■ ดังนั้น เราต้องการประมาณ  $\Pr(X | \text{class} = c)$  ที่เหมาะสมที่สุด เพื่อตัดสิน การทำนายค่าคลาสของตัวอย่าง  $X$

Classification: Bayes and Neural network

9

### ตัวอย่าง $\Pr(x_i|\text{play=yes})$ , $\Pr(x_i|\text{play=no})$

Outlook	Temperature	Humidity	Windy	Class
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

$$\Pr(\text{yes}) = 9/14$$

$$\Pr(\text{no}) = 5/14$$

outlook	
$\Pr(\text{sunny yes}) = 2/9$	$\Pr(\text{sunny no}) = 3/5$
$\Pr(\text{overcast yes}) = 4/9$	$\Pr(\text{overcast no}) = 0$
$\Pr(\text{rain yes}) = 3/9$	$\Pr(\text{rain no}) = 2/5$
Temperature	
$\Pr(\text{hot yes}) = 2/9$	$\Pr(\text{hot no}) = 2/5$
$\Pr(\text{mild yes}) = 4/9$	$\Pr(\text{mild no}) = 2/5$
$\Pr(\text{cool yes}) = 3/9$	$\Pr(\text{cool no}) = 1/5$
Humidity	
$\Pr(\text{high yes}) = 3/9$	$\Pr(\text{high no}) = 4/5$
$\Pr(\text{normal yes}) = 6/9$	$\Pr(\text{normal no}) = 2/5$
Windy	
$\Pr(\text{true yes}) = 3/9$	$\Pr(\text{true no}) = 3/5$
$\Pr(\text{false yes}) = 6/9$	$\Pr(\text{false no}) = 2/5$

14

13

Classification: Bayes and Neural network

11

## Naïve Bayesian Classification

■ วิธีการของ Naïve Bayesian คือการใช้วิธีการของเบย์พร้อมสมมติฐานของการเป็นอิสระต่อ กันของตัวแปรอิสระทุกด้วย

$$\Pr(x_1, \dots, x_k | \text{class} = c) = \Pr(x_1 | \text{class} = c) \cdot \dots \cdot \Pr(x_k | \text{class} = c)$$

■ ถ้าลักษณะประจำ  $i$  เป็น categorical:  $\Pr(x_i | \text{class} = c)$  ประมาณด้วย ความถี่สัมพัทธ์ของตัวอย่างที่มีค่า  $x_i$  ในคลาส  $c$

■ ถ้าลักษณะประจำ  $i$  เป็น continuous:  $\Pr(x_i | \text{class} = c)$  ประมาณด้วย พิมพ์ชั้นความหนาแน่น Gaussian

■ การคำนวณทั้งสองลักษณะจากข้อมูลปริมาณมาก ไม่มีความซับซ้อนและทำงานได้เร็ว

Classification: Bayes and Neural network

10

### วิธีการจำแนกตัวอย่างโดยใช้ Naïve Bayes

■ ตัวอย่างใหม่ที่ไม่ทราบมาก่อน  $X = (\text{outlook} = \text{rain}, \text{temperature} = \text{hot}, \text{humidity} = \text{high}, \text{windy} = \text{false})$

$$\Pr(X|\text{play=yes}) \cdot \Pr(\text{play=yes}) = \Pr(\text{outlook=rain|play=yes}) \cdot \Pr(\text{temperature=hot|play=yes}) \cdot \Pr(\text{humidity=high|play=yes}) \cdot \Pr(\text{windy=false|play=yes}) \cdot \Pr(\text{play=yes}) = 3/9 \cdot 2/9 \cdot 3/9 \cdot 6/9 \cdot 14/14 = 0.010582$$

$$\Pr(X|\text{play=no}) \cdot \Pr(\text{play=no}) = \Pr(\text{outlook=rain|play=no}) \cdot \Pr(\text{temperature=hot|play=no}) \cdot \Pr(\text{humidity=high|play=no}) \cdot \Pr(\text{windy=false|play=no}) \cdot \Pr(\text{play=no}) = 2/5 \cdot 2/5 \cdot 4/5 \cdot 2/5 \cdot 14/14 = 0.018286$$

■ ตัวอย่าง  $X$  ถูกจัดอยู่ใน play = no (ไม่เล่น) เพราะมีค่าความน่าจะเป็นใน play = no มากที่สุด

Classification: Bayes and Neural network

12

## ปัญหาของค่าความน่าจะเป็นที่เป็นศูนย์

- วิธีการประมาณค่าความน่าจะเป็นโดยใช้การคำนวนจากตารางความถี่ ทราบว่า ถ้าเราสุ่มตัวอย่างมาไม่มีดี เราอาจไม่พบตัวอย่างที่สอดคล้องกับเงื่อนไขที่สนใจ เช่นในตาราง  $\Pr(\text{outlook}=\text{overcast} | \text{no}) = 0$  ค่าดังกล่าวทำให้การคำนวนค่าความน่าจะเป็นแบบนี้เป็นศูนย์เสมอ ซึ่งอาจไม่ใช่สิ่งที่เราต้องการ
- กล่าวคือค่าความน่าจะเป็นที่เป็นศูนย์ทำให้วิธีการดังกล่าว ทำให้ค่าความน่าจะเป็นรวมเป็นศูนย์เสมอ
- กลยุทธ์ในการแก้ปัญหานี้คือ การใช้ตัวประมาณค่าใหม่ที่เรียกว่า Laplace estimator กล่าวคือการบวกหนึ่งหน่วยเข้ากับตารางความถี่ก่อนรีมคำนวน

11

Classification: Bayes and Neural network

## การเป็นอิสระต่อ กันของลักษณะประจำ

- สมมติฐานการเป็นอิสระต่อ กันของลักษณะประจำหรือตัวแปรอิสระ ทำให้ การคำนวนเป็นไปได้ง่ายและสะดวก
- ผลลัพธ์ที่ได้จะเชื่อถือได้ถ้าสมมติฐานของความเป็นอิสระเป็นจริง
- ในทางปฏิบัติสมมติฐานดังกล่าวยอมรับได้ยาก กล่าวคือลักษณะประจำมักไม่เป็นอิสระต่อกัน
- หลักการแก้คือ
  - ใช้เครือข่าย Bayesian, รวมการให้เหตุผลแบบ Bayesian กับการใช้ลักษณะประจำที่มีความน่าจะเป็นที่ไม่เป็นอิสระต่อกัน
  - ใช้ต้นไม้มการตัดสินใจ, เลือกลักษณะประจำที่พิจารณาตามความสำคัญ

15

## ตัวอย่าง $\Pr(x_i|\text{play=yes}), \Pr(x_i|\text{play=no})$

outlook	$\Pr(\text{sunny yes}) = 3/12$	$\Pr(\text{sunny no}) = 4/8$
Temperature	$\Pr(\text{hot yes}) = 3/12$	$\Pr(\text{hot no}) = 3/8$
Humidity	$\Pr(\text{high yes}) = 4/11$	$\Pr(\text{high no}) = 5/7$
Windy	$\Pr(\text{true yes}) = 4/11$	$\Pr(\text{true no}) = 4/7$
	$\Pr(\text{false yes}) = 7/11$	$\Pr(\text{false no}) = 3/7$

$\Pr(\text{yes}) = 10/16$

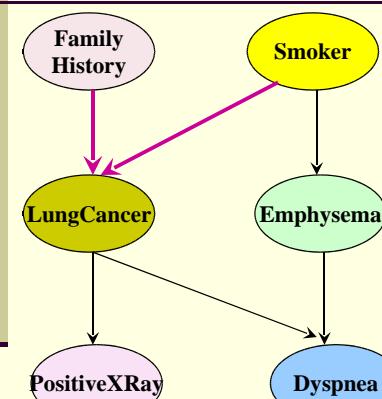
$\Pr(\text{no}) = 6/16$

11

Classification: Bayes and Neural network

14

## Bayesian Networks



(FH, S) (FH, ~S)(~FH, S) (~FH, ~S)

LC	0.8	0.5	0.7	0.1
~LC	0.2	0.5	0.3	0.9

ตารางความน่าจะเป็นแบบมีเงื่อนไขของตัวแปร LungCancer

## Bayesian Networks

Classification: Bayes and Neural network

16

# หลักการ Bayesian Networks

- Bayesian network ขอมให้สับเซตของตัวแปรเป็นอิสระต่อกันอย่างมีเงื่อนไข
- ใช้รูปกราฟแสดงความเกี่ยวพันระหว่างตัวแปร โดยที่จุดยอดคือตัวแปร และเส้นเชื่อมระหว่างจุดยอดคือการไม่เป็นอิสระต่อกันของตัวแปรเหล่านั้น
- การกำหนดเครือข่าย Bayesian จะมีผลต่อการคำนวณกล่าวถึง
  - ถ้าผู้ใช้กำหนดเครือข่ายทั้งหมด โปรแกรมเพียงคำนวณค่าเดียวในเครือข่าย
  - ถ้าผู้ใช้กำหนดเครือข่ายบางส่วน โปรแกรมต้องมีการทดสอบการเป็นอิสระ ต่อกันของแต่ละส่วนในเครือข่าย
  - ถ้าผู้ใช้ไม่กำหนดโครงสร้างเครือข่ายเลย โปรแกรมต้องทดลองทุกการจัดหมู่ที่เป็นไปได้ซึ่งใช้เวลาคำนวณนาน

Classification: Bayes and Neural network

17

## Quadratic loss function

- สมมติว่าตัวอย่างหนึ่งตัวให้ค่าคลาสเป้าหมายได้  $k$  แบบ
- จากข้อมูล ตัวแบบอาจประมาณค่าความน่าจะเป็นของคลาสเป้าหมายเป็น ( $p_1, p_2, \dots, p_k$ )
- แต่ค่าที่แท้จริงของแต่ละตัวอย่างจะเป็น 1 หรือ 0 เที่ยวนแทนด้วย ( $a_1, a_2, \dots, a_k$ )
- ค่าของ quadratic loss function คำนวณได้จาก

$$\sum_j (p_j - a_j)^2$$

- ค่าน้อยแสดงถึงความถูกต้องที่สูงกว่า

Classification: Bayes and Neural network

19

## ความน่าเชื่อถือของผลลัพธ์การจัดจำแนกประเภท

- ปกติผู้ใช้ต้องการตัวแบบที่ทำนายตัวอย่างที่ไม่เคยพบได้ถูกต้องมากที่สุด
- กล่าวคือผลลัพธ์ที่ได้จากตัวแบบจะมีสองค่าตอบ
  - ทำนายได้ถูกต้องตรงกับค่าคลาสเป้าหมาย
  - หรือทำนายได้ไม่ถูกต้องกับค่าคลาสเป้าหมายที่สนใจ
- เราเรียกตัววัดดังกล่าวว่า 0-1 loss function
- แต่ในกรณีที่ตัวแบบให้ค่าเป็นความน่าจะเป็น เรายินยอมใช้ quadratic loss function แทนการประเมิน

Classification: Bayes and Neural network

18

## ค่าประเมินความถูกต้อง TP, TN, FP, FN

- ค่าสี่ตัววัดสำหรับคลาสเป้าหมายสองค่า yes กับ no คือ
  - TP (True positive) คือจำนวนตัวอย่างที่ตัวแบบทำนายว่า yes และค่าคลาสเป้าหมายเป็น yes
  - TN (True negative) คือจำนวนตัวอย่างที่ตัวแบบทำนายว่า no และค่าคลาสเป้าหมายเป็น no
  - FP (False positive) คือจำนวนตัวอย่างที่ตัวแบบทำนายว่า yes และค่าคลาสเป้าหมายเป็น no
  - FN (False negative) คือจำนวนตัวอย่างที่ตัวแบบทำนายว่า no และค่าคลาสเป้าหมายเป็น yes

Classification: Bayes and Neural network

20

## True positive rate, False negative rate

- ค่าประเมินความถูกต้องอีกสองตัวสำหรับคลาสเป้าหมาย yes กับ no คือ
  - True positive rate =  $TP/(TP + FN)$  คือสัดส่วนของจำนวนตัวอย่างที่ตัวแบบทำนายว่า yes และค่าคลาสเป้าหมายเป็น yes เทียบกับค่าคลาสเป้าหมายที่เป็น yes ทั้งหมด
  - False negative rate =  $FP/(FP + TN)$  คือสัดส่วนของจำนวนตัวอย่างที่ตัวแบบทำนายว่า yes และค่าคลาสเป้าหมายเป็น no เทียบกับค่าคลาสเป้าหมายที่เป็น no ทั้งหมด

Classification: Bayes and Neural network

21

## Success rate and error rate

- ค่าอัตราการวัดความสำเร็จอีกสองตัวสำหรับคลาสเป้าหมาย yes กับ no คือ
  - Overall success rate คือสัดส่วนของจำนวนตัวอย่างที่ตัวแบบทำนายถูกทั้งหมดหารด้วยจำนวนตัวอย่างทั้งหมด
- $$\frac{TP + TN}{TP + TN + FP + FN}$$
- Error rate =  $1 - \text{Success rate}$  คือสัดส่วนของจำนวนตัวอย่างที่ตัวแบบทำนายผิดทั้งหมดหารด้วยตัวอย่างทั้งหมด
- สำหรับการวัดความถูกต้องเมื่อค่าคลาสเป้าหมายมีมากกว่าสองค่า เราใช้เมตริกซ์สับสน (Confusion matrix) ในการแสดงผล

Classification: Bayes and Neural network

22

## Confusion matrix

- เมตริกซ์สับสน คือเมตริกซ์ที่แต่ละเซลล์เป็นจำนวนตัวอย่างที่สอดคล้องกับสีเงื่อนไขคือ TP, FP, TN, FN
- ในซอฟต์แวร์ Weka แนวแ嘎มแสดงถึงค่าคลาสเป้าหมายจริงจากตัวอย่าง ในขณะที่แนวหลักแสดงถึงค่าคลาสเป้าหมายที่ทำนายจากตัวแบบ
- ความน่าเชื่อถือของตัวแบบได้จาก จำนวนที่ปราภูณ์ในแนวทางเดียว กล่าวคือตัวแบบมีความน่าเชื่อถือสูงถ้าค่าในแนวทางเดียวมีค่าสูง ในค่านอกแนวทางเดียวมีค่าต่ำ

```
== Confusion Matrix ==  
  
a b  <-- classified as  
9 0 | a = yes  
1 4 | b = no
```

Classification: Bayes and Neural network

23

## ตัวอย่างเมตริกซ์สับสน

Correctly Classified Instances	13	92.8571 %
Incorrectly Classified Instances	1	7.1429 %
Kappa statistic	0.8372	
Mean absolute error	0.2917	
Root mean squared error	0.3392	
Relative absolute error	62.8233 %	
Root relative squared error	70.7422 %	
Total Number of Instances	14	
== Detailed Accuracy By Class ==		
TP Rate	FP Rate	Precision
1	0.2	0.9
0.8	0	1
		0.947
		0.889
		0.922
ROC Area		
		Class
		yes
		no
== Confusion Matrix ==		
a b	<-- classified as	
9 0	a = yes	
1 4	b = no	

จากเมตริกซ์สับสน เราได้ว่า  
ตัวอย่างที่เป็น a มีความถูก  
ต้องทั้งหมด แต่ตัวอย่างที่  
เป็น b มีการทำนายผิด 1  
ตัวอย่าง  
ดังนั้น Overall success  
rate คือ  $13/14 = 92.8571\%$

Classification: Bayes and Neural network

24

## สรุป

- การจำแนกประเภทเป็น การศึกษาการแบ่งกลุ่มข้อมูล พนในสาขาวิชาทั้งทางด้านสติติ เทคโนโลยีสารสนเทศ และการเรียนรู้ด้วยเครื่อง
- การใช้ความน่าจะเป็นในการจำแนกประเภทจะใช้ทฤษฎีของเบย์ ซึ่งถ้าตัวแปรเป็นอิสระต่อกัน เราใช้วิธีการ naïve bayesian
- แต่ถ้าตัวแปรไม่เป็นอิสระต่อกัน เราใช้ bayesian network
- สำหรับการประเมินความถูกต้องของตัวแบบ เรากำหนดตัววัดหลายชนิดได้แก่ TP, TN, FP, FN, true positive rate, false negative rate เป็นต้น

Classification: Bayes and Neural network

25

## เอกสารอ้างอิง

- R. O. Duda, P. E. Hart and D. G. Stork. Pattern Classification, second edition. John Wiley, New York, 2001.
- P. Langley, W. Iba and K. Thompson. An analysis of Bayesian classifiers. Proceedings of the Tenth National Conference on Artificial Intelligence, San Jose, CA. Menlo Park, CA: AAAI Press, pp. 223-228, 1992.
- P. Langley and S. Sage. Induction of selective Bayesian classifiers. Proceedings of the Tenth Conference on Uncertainty in Artificial Intelligence, Seattle, pp. 399-406, 1994.
- D. Heckerman, D. Geiger and D. M. Chickering. Learning Bayesian networks: The combination of knowledge and statistical data. Machine Learning 20(3):197-243, 1995.
- J. Shafer, R. Agrawal, and M. Mehta. SPRINT : A scalable parallel classifier for data mining. In Proc. 1996 Int. Conf. Very Large Data Bases, 544-555, Bombay, India, Sept. 1996.
- S. M. Weiss and C. A. Kulikowski. Computer Systems that Learn: Classification and Prediction Methods from Statistics, Neural Nets, Machine Learning, and Expert Systems. Morgan Kaufman, 1991.

Classification: Bayes and Neural network

26