

CSC662 Data Mining, Data Warehouse and Visualization

บทที่ 11 เมตริกซ์และการวิเคราะห์การเกากรกลุ่ม

เตรียมโดย พศ. ดร. กรุง สินอภิรมย์สารัญ
ภาควิชาคณิตศาสตร์ คณะวิทยาศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

โครงร่าง

- ข้อมูลและชนิดของข้อมูล
- เมตริกซ์
- รูปแบบการกำหนดเมตริกซ์
- การคำนวณเมตริกซ์ตามประเภทของตัวแปร
- นิยามการเกากรกลุ่ม
- การวิเคราะห์การเกากรกลุ่ม
- การประยุกต์

24/07/06

เมตริกซ์

2

ข้อมูลที่ผ่านขั้นตอนการเตรียมข้อมูลแล้ว

- ประกอบด้วยหลักและ Qaeda
 - หลักคือลักษณะประจำ หรือเรียกว่าตัวแปร ซึ่งมีทั้งตัวแปรจำนวนและตัวแปรที่มีค่าที่ไม่ต่อเนื่อง
 - แตกต่างกันที่หมายถึงข้อมูลที่มีค่าในแต่ละลักษณะประจำที่สนใจ
- ไม่มีข้อมูลที่ขาดหายไป หรือข้อมูลที่ผิดปกติ
- ในการทำเหมือนข้อมูล ลักษณะประจำและระเบียนต้องถูกเปลี่ยนเพื่อความเหมาะสมสำหรับแต่ละเทคนิคของการทำเหมือนข้อมูล

24/07/06

เมตริกซ์

3

ชนิดของลักษณะประจำ หรือตัวแปร

- ตัวแปรไม่มีลำดับที่มีค่าไม่ต่อเนื่อง Nominal เป็นลักษณะประจำที่มีค่าไม่ต่อเนื่องในแต่ละระเบียน และไม่มีนิยามของลำดับที่ชัดเจน เช่น เพศ สี แผนก
- ตัวแปรมีลำดับที่มีค่าไม่ต่อเนื่อง Ordinal เป็นลักษณะประจำที่มีลำดับและมีค่าไม่ต่อเนื่อง เช่น กลุ่มอายุ = เด็ก วัยรุ่น ผู้ใหญ่
- ตัวแปรจำนวน Numerical (Continuous) เป็นลักษณะประจำที่มีค่าต่อเนื่อง เช่น ส่วนสูง รากาน น้ำหนัก

24/07/06

เมตริกซ์

4

เมตริกซ์และการวัดระยะของข้อมูล

- การทำเหมือนข้อมูลแบบวิเคราะห์การเกากลุ่มของระเบียนข้อมูลใช้แนวคิดของระยะระหว่างระเบียน ตัววัดระยะระหว่างวัตถุเรียก เมตริกซ์ (Metric)
- สมบัติของเมตริกซ์ที่ลูกน้ำนำไป:
 - ระยะเมตริกซ์ที่สั้น สื่อถึงระเบียนที่คล้ายคลึงกัน (ไม่ต่างกันมาก)
 - ระยะเมตริกซ์ที่ไกล สื่อถึงระเบียนที่ต่างกันมาก
- การนิยามเมตริกซ์มักขึ้นกับชนิดของลักษณะประจำ Nominal, Ordinal, Numeric
- ผู้ใช้กำหนดค่าที่แยกว่าระเบียนคล้ายกันพอ (similar enough) หรือใกล้กันมากพอ (close enough) ได้

24/07/06

เมตริกซ์

5

การคำนวณเมตริกซ์ตามชนิดของตัวแปร

- ตัวแปรจำนวน (Numeric variable)
- ตัวแปรทวิภาค (Boolean variable)
- ตัวแปรไม่มีลำดับที่มีค่าไม่ต่อเนื่อง (Nominal variable)
- ตัวแปรมีลำดับที่มีค่าไม่ต่อเนื่อง (Ordinal variable)

24/07/06

เมตริกซ์

7

รูปแบบการกำหนดเมตริกซ์

- กำหนดจากเมตริกซ์ข้อมูล (Data matrix)

- แบบ two modes

$$\begin{bmatrix} x_{11} & \dots & x_{1f} & \dots & x_{1p} \\ \vdots & \dots & \dots & \dots & \vdots \\ x_{i1} & \dots & x_{if} & \dots & x_{ip} \\ \vdots & \dots & \dots & \dots & \vdots \\ x_{n1} & \dots & x_{nf} & \dots & x_{np} \end{bmatrix}$$

- กำหนดจากเมตริกซ์ความต่าง (Dissimilarity matrix)

- แบบ one mode

$$\begin{bmatrix} 0 & & & & \\ d(2,1) & 0 & & & \\ d(3,1) & d(3,2) & 0 & & \\ \vdots & \vdots & \vdots & \ddots & \\ d(n,1) & d(n,2) & \dots & \dots & 0 \end{bmatrix}$$

24/07/06

เมตริกซ์

6

ตัวแปรจำนวน (Numeric variable)

- ปรับให้อยู่ในรูปมาตรฐาน z-score
$$z_{if} = \frac{x_{if} - m_f}{s}$$

■ ใช้ mean absolute deviation:

$$m_f = \frac{1}{n}(x_{1f} + x_{2f} + \dots + x_{nf})$$

■ ใช้ standard deviation:

$$s_f = \sqrt{\frac{1}{n}(|x_{1f} - m_f| + |x_{2f} - m_f| + \dots + |x_{nf} - m_f|)}$$

- ในการวิเคราะห์การเกากลุ่ม การใช้ z-score ด้วย mean absolute deviation มักให้ผลที่แม่นยำกว่า standard deviation

$$s_d = \sqrt{\frac{1}{n-1}((x_{1f} - m_f)^2 + (x_{2f} - m_f)^2 + \dots + (x_{nf} - m_f)^2)}$$

24/07/06

เมตริกซ์

8

ความคล้ายคลึงและความแตกต่าง $d(i, j)$

- ระยะทาง มีความสัมพันธ์กับตัววัดความคล้ายคลึง (similarity) มาก ค่าระยะจะน้อย แต่ถ้า similarity ค่าระยะจะมาก)

- การคำนวณระยะที่ใช้ในปัจจุบันคือ *Minkowski distance*:

$$d(i, j) = \sqrt[q]{(|x_{i1} - x_{j1}|^q + |x_{i2} - x_{j2}|^q + \dots + |x_{ip} - x_{jp}|^q)}$$

เมื่อ $i = (x_{i1}, x_{i2}, \dots, x_{ip})$ และ $j = (x_{j1}, x_{j2}, \dots, x_{jp})$ เป็นระเบียบข้อมูลขนาด p มิติและ q เป็นจำนวนเต็มบวก

- ถ้า $q = 1$ แล้ว d คือ Manhattan distance

$$d(i, j) = |x_{i1} - x_{j1}| + |x_{i2} - x_{j2}| + \dots + |x_{ip} - x_{jp}|$$

24/07/06

เมตริกซ์

9

สมบัติของเมตริกซ์

- ถ้า $q = 2$ แล้ว d คือ Euclidean distance:

$$d(i, j) = \sqrt{(|x_{i1} - x_{j1}|^2 + |x_{i2} - x_{j2}|^2 + \dots + |x_{ip} - x_{jp}|^2)}$$

- สมบัติของเมตริกซ์

- $d(i, j) \geq 0$
- $d(i, i) = 0$
- $d(i, j) = d(j, i)$
- $d(i, j) \leq d(i, k) + d(k, j)$

- นอกจากนี้เราอาจใช้ระยะแบบถ่วงน้ำหนัก หรือ parametric Pearson product moment correlation หรือตัวแปรอื่น ๆ

24/07/06

เมตริกซ์

10

ตัวแปรทวิภาค (Binary variables)

- รวมตัวแปรทวิภาคทั้งหมด มาสร้างตารางการจزو (contingency table)

| | | Object <i>j</i> | | | |
|-----------------|---|-----------------|------------|------------|--|
| | | 1 | 0 | sum | |
| Object <i>i</i> | 1 | <i>a</i> | <i>b</i> | <i>a+b</i> | |
| | 0 | <i>c</i> | <i>d</i> | <i>c+d</i> | |
| sum | | <i>a+c</i> | <i>b+d</i> | <i>p</i> | |

- ระยะที่ได้จากสัมประสิทธิ์คิดแบบสมมาตร (symmetric coefficient)

ระหว่างระเบียน *i* กับระเบียน *j*
$$d(i, j) = \frac{b+c}{a+b+c+d}$$

- ระยะที่ได้จากสัมประสิทธิ์คิดแบบไม่สมมาตร (Jaccard coefficient)

$$d(i, j) = \frac{b+c}{a+b+c}$$

24/07/06

เมตริกซ์

11

ตัวอย่างการคำนวณเมตริกซ์ของตัวแปรทวิภาค

| Name | Gender | Fever | Cough | Test-1 | Test-2 | Test-3 | Test-4 |
|------|--------|-------|-------|--------|--------|--------|--------|
| Jack | M | Y | N | P | N | N | N |
| Mary | F | Y | N | P | N | P | N |
| Jim | M | Y | P | N | N | N | N |

- พิจารณาเฉพาะลักษณะประจำที่ไม่สมมาตรคือ Fever, Cough, Test-1, Test-2, Test-3, Test-4

- ให้ Y และ P มีค่าเป็น 1 และ N มีค่าเป็น 0

$$d(jack, mary) = \frac{0+1}{2+0+1} = 0.33$$

$$d(jack, jim) = \frac{1+1}{1+1+1} = 0.67$$

$$d(jim, mary) = \frac{1+2}{1+1+2} = 0.75$$

24/07/06

เมตริกซ์

12

ตัวแปรไม่มีลำดับที่มีค่าไม่ต่อเนื่อง (Nominals)

- ตัวแปรไม่มีลำดับที่มีค่าไม่ต่อเนื่องมักมีค่ามากกว่าสองค่า ตัวอย่างเช่น สีที่อาจมีค่า เป็นสีแดง (red) สีเหลือง (yellow) สีน้ำเงิน (blue) สีเขียว (green)
- วิธีการวัดแบบที่ 1: นับการเข้าคู่ทั้งหมดทุก Nominal คำนวนโดย
 - m : จำนวนที่เข้าคู่ และ p : จำนวนทั้งหมด
 - $d(i, j) = \frac{p - m}{p}$
- วิธีการวัดแบบที่ 2: แปลงเป็นตัวแปรทวิภาค (Dummy coding) สำหรับแต่ละค่าที่เป็นไปได้ แล้วใช้การวัดระยะสำหรับตัวแปรทวิภาคแบบสมมาตร เช่น ตัวแปรสี (color) ที่เป็นไปได้สีสีข้างต้น สร้างเป็นตัวแปรทวิภาคสีตัวคือ red, yellow, blue, green

24/07/06

เมตริกซ์

13

เมตริกซ์รวม

- การทำใหม่ของข้อมูลแบบวิเคราะห์การเกากลุ่มต้องพิจารณาตัวแปรทั้ง 5 รูปแบบ symmetric binary, asymmetric binary, nominal, ordinal, numeric
- ระยะระหว่างระเบียนคำนวนจากตัวแปรทั้งหมดที่เกี่ยวข้อง โดยอาจมีการทำหนดค่าต่ำกว่าหนักให้กับแต่ละตัวแปร
 - ตัวแปรทวิภาคหรือตัวแปรไม่มีลำดับที่มีค่าไม่ต่อเนื่อง $d_{ij}^{(t)} = 0$ ถ้า x_{ij} มีค่าที่ต้องการ, $d_{ij}^{(t)} = 1$ กรณีอื่น
 - ตัวแปรจำนวนให้แปลงให้อยู่ในสเกลมาตรฐานก่อนคำนวณ
 - ตัวแปรมีลำดับที่มีค่าไม่ต่อเนื่อง $d(i, j) = \sum_{t=1}^p \delta_{ij}^{(t)} d_{ij}^{(t)}$
 - คำนวนค่าลำดับที่ r_{if} (rank) $z_{if} = \frac{r_{if} - 1}{M_f - 1}$
 - แล้วหา z_{if} คล้ายกับการจัดการกับตัวแปรจำนวน

24/07/06

เมตริกซ์

14

การวิเคราะห์การเกากลุ่ม

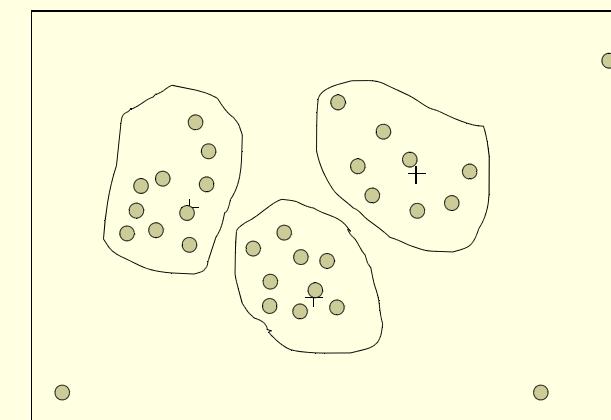
- ข้อมูลการเกากลุ่ม หมายถึงลักษณะของกลุ่มข้อมูลที่จับตัวอยู่ร่วมกัน โดย
 - ข้อมูลที่อยู่ในกลุ่มเดียวกันมีความคล้ายกัน (ระยะใกล้)
 - ข้อมูลที่อยู่ต่างกลุ่มมีความแตกต่างกัน (ระยะไกล)
- การวิเคราะห์การเกากลุ่มคือ การหาวิธีการแบ่งข้อมูลออกเป็นกลุ่มตามลักษณะประจำที่มีของแต่ละข้อมูล โดยไม่มีการกำหนดลักษณะกลุ่มหรือการจัดกลุ่ม
- การเกากลุ่มมีลักษณะ unsupervised classification กล่าวคือ ไม่มีการกำหนดคลาสที่ต้องการ การเรียนรู้ได้มาจากลักษณะประจำของข้อมูล
- นำไปประยุกต์ใช้กับการวิเคราะห์การกระจายข้อมูล และถูกใช้ในกระบวนการ เตรียมข้อมูล เพื่อนำไปใช้กับวิธีการอื่น

24/07/06

เมตริกซ์

15

การวิเคราะห์การเกากลุ่ม



24/07/06

เมตริกซ์

16

ตัวอย่างการนำไปประยุกต์

- ใช้สำหรับการรู้จำรูปแบบ (Pattern Recognition)
- ใช้สำหรับวิเคราะห์ข้อมูลที่เกี่ยวกับปริภูมิ (Spatial Data Analysis)
 - การสร้าง thematic maps ใน GIS โดยการเก็บ feature space
 - การตรวจสอบคุณภาพที่เกี่ยวข้องกับระยะ สิ่งรอบข้าง ความสูง ความลึก
- ใช้สำหรับการประมวลผลภาพ (Image Processing)
- ใช้ในวิทยาศาสตร์ธรรมชาติ (โดยเฉพาะการวิจัยคลาด)
- ใช้กับ WWW
 - การแบ่งกลุ่มเอกสาร (Document classification)
 - การเก็บกลุ่มข้อมูลใน Weblog เพื่อครุย์แบนการเข้าถึงข้อมูล

24/07/06

มติรักษ์

17

ศาสตร์ที่นำการวิเคราะห์การเก็บกลุ่มไปใช้

- ทางการตลาด: ช่วยนักการตลาดกันพัฒนาขั้นกุ่มของลูกค้าที่มีพฤติกรรมคล้ายกัน ซึ่งนำมาช่วยออกแบบการขายตามลักษณะกลุ่มเป้าหมายที่ต้องการ
- ทางพื้นที่: ช่วยค้นหาบริเวณที่มีการใช้สอยที่คล้ายกัน ตามลักษณะผู้คนในพื้นที่
- ทางการประกัน: ตรวจสอบกลุ่มผู้ถือประกันรายนั้นที่มีการเรียกร้องค่าประกันที่ผิดปกติ
- ทางการวางแผนเมือง: วิเคราะห์การจับตัวกันของบ้าน ตามชนิด ราคา สถานที่
- ทางการศึกษาผ่านดินไหว: การวิเคราะห์ศูนย์กลางการไหว้ที่นำไปตรวจจับผ่านดินไหวตามแนวแยกของขอบโลก

24/07/06

มติรักษ์

18

ลักษณะการเก็บกลุ่มที่ดี

- การเก็บกลุ่มที่ดี ต้องรวมข้อมูลที่คล้ายกันไว้ด้วยกัน และแยกข้อมูลที่ต่างกันออกเป็นกลุ่มย่อย
- ผู้ใช้มักสนใจคุณภาพของการเก็บกลุ่มซึ่งขึ้นกับตัวแปรความคล้ายคลึงและขั้นตอนวิธีที่ใช้ พร้อมกับลักษณะกลุ่ม (Clustering profiles)
- การเก็บกลุ่มที่นำเสนอให้กับผู้ใช้ แยกข้อมูลเป็นกลุ่ม และมีการบ่งบอกลักษณะที่ชัดเจน ไม่ซ้อนซ้ำในกลุ่มที่นำเสนอ
- วิธีการเก็บกลุ่มที่มีประสิทธิภาพควรใช้ได้กับข้อมูลขนาดใหญ่ และไม่ใช้เวลานานมากในการสร้างตัวแบบ

24/07/06

มติรักษ์

19

รายการสรุป การวิเคราะห์การเก็บกลุ่ม

- ใช้ได้กับข้อมูลปริมาณมาก
- จัดการกับลักษณะประจำแยกชนิด
- ไม่ควรถูกจำกัดการเก็บตัวในลักษณะทรงกลมหรือวงรีเท่านั้น
- พารามิเตอร์ที่มีการปรับแต่งโดยอัตโนมัติ
- การเก็บกลุ่มไม่ควรเปลี่ยนไปเมื่อเจอกลุ่มชนิดเดียวกัน
- ลำดับของข้อมูลเข้าไม่ควรมีผลต่อขั้นตอนวิธีที่ใช้
- ใช้กับข้อมูลที่มีมิติสูง คือมีลักษณะประจำจำนวนมากได้
- สามารถเพิ่มเงื่อนไขที่ผู้ใช้ต้องการได้
- มีการแปลความที่ง่ายและสะดวกในการนำไปใช้

24/07/06

มติรักษ์

20

ประเภทของขั้นตอนวิธีการวิเคราะห์การเก็บกลุ่ม

- ประเภทใช้วิธีแบ่งก้อน (Partitioning): ข้อมูลถูกแบ่งก้อนเป็นกลุ่มที่ไม่มีสมาชิกร่วมกันเลย แล้วใช้ตัววัดทดสอบว่ากลุ่มที่แบ่งเหมาสมหรือไม่
- ประเภทระดับชั้น (Hierarchy): สร้างกลุ่มโดยการใช้ระดับชั้น (hierarchical decomposition) ตามเงื่อนไขที่ต้องการ
- ประเภทความหนาแน่น (Density-based): เน้นการเชื่อมกันและความหนาแน่น ระหว่างระเบียนข้อมูล
- ประเภทแบ่งกริด (Grid-based): ใช้ความละเอียดโดยแบ่งกริด
- ประเภทตัวแบบ (Model-based): สร้างตัวแบบ แล้วเลือกตัวแบบที่ดีที่สุด

24/07/06

มติรักษ์

21

สรุป

- ชนิดของข้อมูลมีผลต่อการคำนวณระยะระหว่างระเบียน
- การคำนวณระยะใช้เมตริกซึ่งนิยามกับข้อมูลท้าชนิด Numeric variable, Symmetric boolean variable, Asymmetric boolean variable, Nominal variable, Ordinal variable
- ในการวิเคราะห์การเก็บกลุ่ม เราใช้ตัววัดระยะรวมซึ่งเกิดจากการใช้ค่าล่างน้ำหนักกูนกับระยะของการวัดข้อมูลทั้งท้าชนิด
- ขั้นตอนวิธีการเก็บกลุ่มคือการวิเคราะห์เพื่อแบ่งแยกข้อมูลออกเป็นส่วน ๆ โดยใช้ระยะที่กำหนดให้

24/07/06

มติรักษ์

22

เอกสารอ้างอิง ๑

- D. Pyle. Data Preparation for Data Mining. Morgan Kaufmann, 1999.
- Y. Wand and R. Wang. Anchoring data quality dimensions ontological foundations. Communications of ACM, 39:86-95, 1996.
- R. Wang, V. Storey, and C. Firth. A framework for analysis of data quality research. IEEE Trans. Knowledge and Data Engineering, 7:623-640, 1995.
- R. Agrawal, J. Gehrke, D. Gunopulos, and P. Raghavan. Automatic subspace clustering of high dimensional data for data mining applications. SIGMOD'98
- M. R. Anderberg. Cluster Analysis for Applications. Academic Press, 1973.
- M. Ankerst, M. Breunig, H.-P. Kriegel, and J. Sander. Optics: Ordering points to identify the clustering structure, SIGMOD'99.
- P. Arabie, L. J. Hubert, and G. De Soete. Clustering and Classification. World Scientific, 1996

24/07/06

มติรักษ์

23

เอกสารอ้างอิง ๒

- M. Ester, H.-P. Kriegel, and X. Xu. Knowledge discovery in large spatial databases: Focusing techniques for efficient class identification. SSD'95.
- D. Gibson, J. Kleinberg, and P. Raghavan. Clustering categorical data: An approach based on dynamic systems. In Proc. VLDB'98.
- A. K. Jain and R. C. Dubes. Algorithms for Clustering Data. Printice Hall, 1988.
- L. Kaufman and P. J. Rousseeuw. Finding Groups in Data: an Introduction to Cluster Analysis. John Wiley & Sons, 1990.
- G. J. McLachlan and K.E. Bkasford. Mixture Models: Inference and Applications to Clustering. John Wiley and Sons, 1988.
- P. Michaud. Clustering techniques. Future Generation Computer systems, 13, 1997.
- R. Ng and J. Han. Efficient and effective clustering method for spatial data mining. VLDB'94.

24/07/06

มติรักษ์

24