

# การวิเคราะห์เชิงพรรณา และการวิเคราะห์เชิงวินิจฉัย

การสำรวจข้อมูลที่ได้ถูกรวบรวมไว้ นับเป็นก้าวแรกของการวิเคราะห์ข้อมูล ทั้งนี้เพื่อทำให้เกิดความเข้าใจในลักษณะของข้อมูลที่มีอยู่ โดยส่วนใหญ่มัก เป็นการสังเกตลักษณะการกระจายของค่าข้อมูลในแต่ละตัวแปร ซึ่งจัดเป็นการวิเคราะห์ข้อมูลในระดับ การวิเคราะห์เชิงพรรณา รวมไปถึงการอธิบายความสัมพันธ์ระหว่างตัวแปรในชุดข้อมูล ซึ่งจัดเป็นการวิเคราะห์เชิงวินิจฉัย แม้ว่า ทั้งการวิเคราะห์เชิงพรรณาและการวิเคราะห์เชิงวินิจฉัย จะเป็นการวิเคราะห์ข้อมูลเบื้องต้นที่มีวิธีการวิเคราะห์ข้อมูลที่ซับซ้อนไม่มากนัก แต่สามารถนำไปสู่ คำตอบของปัญหาธุรกิจบางปัญหาได้ อีกทั้งผลลัพธ์จากการวิเคราะห์ข้อมูลในระดับขั้นนี้ยังสามารถนำไปใช้เป็นแนวทางในการตั้งสมมติฐานและการดำเนิน การในการวิเคราะห์ข้อมูลในระดับขั้นที่สูงขึ้นไป ในบทนี้จะกล่าวถึงเครื่องมือ ทางคณิตศาสตร์และสถิติอย่างง่าย สำหรับใช้ในการวิเคราะห์เชิงพรรณา และ การวิเคราะห์เชิงวินิจฉัย เพื่อเป็นแนวทางในการดำเนินการวิเคราะห์ข้อมูลและ นำไปต่อยอดความรู้ของผู้อ่านต่อไปในอนาคต

## 3.1 สถิติศาสตร์เชิงพรรณาด้วยตารางตัวหลัก

พิจารณาตารางข้อมูล ซึ่งประกอบด้วยคอลัมน์และแถวข้อมูล โดยแต่ละแถว ข้อมูลบันทึก คุณลักษณะ ที่สนใจ ตาม คอลัมน์ ของ ข้อมูล แต่ละ ข้อมูล (แสดง ตัวอย่าง ตารางข้อมูล ดังตาราง 2.1) เมื่อนำเอาคอลัมน์ใดคอลัมน์หนึ่งของ ตารางข้อมูล ซึ่งหมายถึง ค่าของตัวแปรใดตัวแปรหนึ่ง ของทุกๆ ข้อมูล มา พิจารณาแล้ว เราสามารถอธิบายลักษณะการกระจายของค่าตัวแปรนั้นๆ ได้ หลายวิธี วิธีหนึ่งในนั้นคือการอธิบายโดยใช้ค่าสถิติเชิงพรรณา

### ค่ากลางของข้อมูล

ค่ากลางของข้อมูล เป็นค่าสถิติที่ใช้ในการบ่งบอกถึงแนวโน้มของค่าข้อมูลส่วนใหญ่ ซึ่งสามารถใช้เป็นตัวแทนค่าข้อมูลได้ เราสามารถหาค่ากลางของข้อมูลได้ 3 แบบ คือ

**ค่าเฉลี่ยเลขคณิต (Arithmetic Mean)** เรียกอย่างอื่นว่า ค่าเฉลี่ย (Mean หรือ Average) คือ ค่าผลบวกของค่าข้อมูลทั้งหมดหารด้วยจำนวนข้อมูล กำหนดให้  $X_j = (x_{1,j}, x_{2,j}, \dots, x_{n,j})$  เป็นชุดของค่าตัวแปร  $X_j$  ของทุกๆ ข้อมูล ในตารางข้อมูล เราสามารถคำนวณค่าเฉลี่ยของตัวแปร  $X_j$  (แทนด้วยสัญลักษณ์  $\bar{x}_j$  เมื่อค่าตัวแปร  $X_j$  มาจากกลุ่มตัวอย่าง หรือ  $\mu_j$  เมื่อค่าตัวแปร  $X_j$  มาจากประชากร) ได้จากสูตร

$$\bar{x}_j = \frac{1}{n} \sum_{i=1}^n x_{i,j} \quad (3.1)$$

เนื่องจากการคำนวณค่าเฉลี่ยอยู่บนพื้นฐานการดำเนินการเชิงตัวเลข ดังนั้น ตัวแปรที่มีชนิดข้อมูลเป็นข้อมูลเชิงปริมาณเท่านั้น ที่จะสามารถคำนวณหาค่าเฉลี่ยได้

### ตัวอย่าง 3.1

พิจารณา ชุดค่าของตัวแปรประสิทธิภาพของงาน (Job Performance: JP)

$X_{JP} = (7, 10, 11, 15, 10, 10, 12, 14, 16, 12)$  จากกลุ่มตัวอย่างพนักงานบริษัทจำนวน 10 คน จะสามารถหาค่าเฉลี่ย ได้ดังนี้

$$\begin{aligned} \bar{x}_{JP} &= \frac{1}{n} \sum_{i=1}^n x_{i,JP} \\ &= \frac{7 + 10 + 11 + 15 + 10 + 10 + 12 + 14 + 16 + 12}{10} \\ &= \frac{117}{10} = 11.7 \end{aligned}$$

ดังนั้น ค่าเฉลี่ยของตัวแปรประสิทธิภาพของงาน ( $\bar{x}_{JP}$ ) มีค่าเท่ากับ 11.7

**มัธยฐาน (Median)** คือ ค่าข้อมูลตรงกลางของข้อมูลทั้งหมดซึ่งถูกเรียงลำดับจากค่าน้อยไปมาก หรือจากค่ามากไปค่าน้อยแล้ว การหาค่ามัธยฐานจะต้องทำการเรียงลำดับของข้อมูลก่อนเสมอ ต่อมาจึงหาตำแหน่งตรงกลาง ซึ่งสามารถแบ่งได้ 2 กรณี ดังนี้

กรณีที่ 1 จำนวนข้อมูล  $n$  เป็นเลขคู่ สามารถหาค่ามัธยฐานของตัวแปร  $X_j$  แทนด้วยสัญลักษณ์  $\tilde{x}_j$  ได้โดย

$$\tilde{x}_j = x_{\frac{(n+1)}{2}, j} \quad (3.2)$$

กรณีที่ 2 จำนวนข้อมูล  $n$  เป็นเลขคี่ สามารถหาค่ามัธยฐานของตัวแปร  $X_j$  ได้โดย

$$\tilde{x}_j = \frac{x_{\frac{n}{2}, j} + x_{\frac{n}{2}+1, j}}{2} \quad (3.3)$$

### อภิธานศัพท์

#### ประชากร (Population)

หมายถึง กลุ่มสมาชิก ทั้งหมด ของสิ่งต่างๆ ที่ต้องการศึกษาหรือต้องการสรุป ถ้าอ้างอิงเป็น คน สัตว์ สิ่งของ เหตุการณ์ ปรากฏการณ์ หรือ พฤติกรรมใดๆ ก็ได้ ซึ่งอยู่ภายใต้ขอบเขตที่กำหนด

#### ตัวอย่าง (Sample)

หมายถึง กลุ่มสมาชิก ของ ประชากร ที่ถูกเลือกมาด้วยวิธีการต่างๆ เพื่อทำการศึกษาวิเคราะห์ และนำผลหรือข้อมูลที่ได้ไปใช้อ้างอิงถึงประชากร ถ้า กลุ่มสมาชิกที่ถูกเลือกมานั้นเป็นตัวแทนที่ดีของประชากร และมีจำนวนมากพอแล้วค่าที่ใช้สรุป อ้างอิงถึง ประชากร จะ มี ความถูกต้อง หรือ ใกล้เคียง กับ ลักษณะ หรือคุณสมบัติของประชากรมาก

เนื่องจากการหาค่ามัธยฐานจะต้องทำการเรียงลำดับข้อมูล ดังนั้น ตัวแปรที่มีชนิดข้อมูลเป็นข้อมูลเชิงลำดับ หรือ ข้อมูลเชิงปริมาณ เท่านั้น ที่จะสามารถคำนวณค่ามัธยฐานได้

### ตัวอย่าง 3.2

พิจารณา ชุดค่าของตัวแปรประสิทธิภาพของงาน (Job Performance: JP)

$X_{JP} = (7, 10, 11, 15, 10, 10, 12, 14, 16, 12)$  จากกลุ่มตัวอย่างพนักงานบริษัทจำนวน 10 คน จะสามารถหาค่ามัธยฐานได้โดยเรียงลำดับข้อมูลจากค่าน้อยไปค่ามาก ได้ดังนี้  $(7, 10, 10, 10, 11, 12, 12, 14, 15, 16)$  ชุดค่าข้อมูลนี้มีจำนวนข้อมูล  $n$  เท่ากับ 10 ซึ่งเป็นเลขคู่ ดังนั้น ค่ามัธยฐาน สามารถคำนวณได้โดยใช้สมการ (3.3) ดังนี้

$$\begin{aligned}\tilde{x}_{JP} &= \frac{x_{\frac{n}{2}},JP + x_{\frac{n}{2}+1},JP}{2} \\ &= \frac{x_{\frac{10}{2}},JP + x_{\frac{10}{2}+1},JP}{2} \\ &= \frac{x_5,JP + x_6,JP}{2} \\ &= \frac{11 + 12}{2} \\ &= \frac{23}{2} = 11.5\end{aligned}$$


ดังนั้น ค่ามัธยฐานของตัวแปรประสิทธิภาพงาน ( $\tilde{x}_{JP}$ ) เท่ากับ 11.5

### ตัวอย่าง 3.3

พิจารณา ชุดค่าของตัวแปรคะแนนสอบ TOEFL  $X_{TOEFL} = (118, 107, 104, 110, 109, 101, 105, 108, 110, 106, 110, 102, 104, 101, 108)$  จากกลุ่มตัวอย่างผู้เข้าสอบ TOEFL จำนวน 15 คน จะสามารถหาค่ามัธยฐานได้โดยเรียงลำดับข้อมูลจากค่าน้อยไปค่ามาก ได้ดังนี้  $(101, 101, 102, 104, 104, 105, 106, 107, 108, 108, 109, 110, 110, 110, 118)$  ชุดค่าข้อมูลนี้มีจำนวนข้อมูล  $n$  เท่ากับ 15 ซึ่งเป็นเลขคี่ ดังนั้น ค่ามัธยฐาน สามารถคำนวณได้โดยใช้สมการ (3.2) ดังนี้

$$\begin{aligned}\tilde{x}_{TOEFL} &= x_{\frac{(n+1)}{2},TOEFL} \\ &= x_{\frac{(15+1)}{2},TOEFL} \\ &= x_{\frac{(16)}{2},TOEFL} \\ &= x_{8,TOEFL} = 107\end{aligned}$$

ดังนั้น ค่ามัธยฐานของตัวแปรคะแนนสอบ TOEFL ( $\tilde{x}_{TOEFL}$ ) เท่ากับ 107



ภาพ 3.1: ค่าเฉลี่ย มัธยฐาน และฐานนิยม ของลักษณะการกระจายของข้อมูลที่มีการแจกแจงแบบปกติ การแจกแจงแบบเบ้ขวา และการแจกแจงแบบเบ้ซ้าย

**ฐานนิยม (Mode)** คือ ค่าข้อมูลที่มีความถี่สูงที่สุด การหาค่าฐานนิยมของตัวแปร  $X_j$  แทนด้วยสัญลักษณ์  $Mo_j$  สามารถหาได้โดยการนับความถี่ของค่าข้อมูลแต่ละค่าในชุดของค่าตัวแปร  $X_j$  และค่าข้อมูลที่มีความถี่สูงสุดจะเป็นค่าฐานนิยมของค่าตัวแปร  $X_j$  ทั้งนี้ตัวแปรที่มีชนิดข้อมูลเป็นข้อมูลนามบัญญัติข้อมูลเชิงลำดับ ข้อมูลระดับอัตราภาค หรือข้อมูลระดับอัตราส่วน สามารถคำนวณค่าฐานนิยมได้

#### ตัวอย่าง 3.4


พิจารณา ชุดค่าของตัวแปรประสิทธิภาพของงาน (Job Performance: JP)

$X_{JP} = (7, 10, 11, 15, 10, 10, 12, 14, 16, 12)$  จากกลุ่มตัวอย่างพนักงานบริษัทจำนวน 10 คน สามารถนับความถี่ของค่าข้อมูล ได้ดังนี้

ค่าข้อมูล	7	10	11	12	14	15	16
ความถี่	1	3	1	2	1	1	1

จะเห็นว่า ค่าข้อมูล 10 มีความถี่สูงที่สุด นั่นคือ ค่าความถี่เท่ากับ 3 ดังนั้น ค่าฐานนิยมของตัวแปรประสิทธิภาพของงาน ( $Mo_{JP}$ ) จึงเท่ากับ 10

สำหรับชุดค่าตัวแปรหนึ่งๆ ค่ากลางของข้อมูลทั้ง 3 แบบนี้อาจจะมีค่าเท่ากันหรือแตกต่างกันได้ ทั้งนี้ขึ้นอยู่กับลักษณะการแจกแจงของค่าตัวแปรนั้นด้วย ดังแสดงในภาพ 3.1 ค่ากลางของข้อมูลทั้ง 3 แบบจะมีค่าเท่ากันก็ต่อเมื่อค่าข้อมูลมีการแจกแจงแบบปกติ หากค่าข้อมูลมีลักษณะการแจกแจงแบบเบ้ซ้ายแล้ว ค่าเฉลี่ยจะมีค่าน้อยกว่าค่ามัธยฐาน และค่ามัธยฐานจะมีค่าน้อยกว่าค่าฐานนิยม ในทางกลับกันหากค่าข้อมูลมีลักษณะการแจกแจงแบบเบ้ขวาแล้ว ค่าเฉลี่ยจะมีค่ามากกว่าค่ามัธยฐาน และค่ามัธยฐานจะมีค่ามากกว่าค่าฐานนิยม



ภาพ 3.2: แผนภาพ การแจกแจง ปกติ แสดง สัดส่วน พื้นที่ ให้ โค้ง ที่ ขนาด 1 เท่า 2 เท่า และ 3 เท่า ของ ส่วน เปี่ยง บน มาตรฐาน ของ ประชากร ( $\sigma$ ) ทั้ง ด้าน ซ้าย และ ขวา ของ ค่า เฉลี่ย ประชากร ( $\mu$ ) (ที่มา: [https://en.wikipedia.org/wiki/Standard\\_deviation](https://en.wikipedia.org/wiki/Standard_deviation))

## ส่วนเบี่ยงเบนมาตรฐานและความแปรปรวน

ส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation: SD) เป็นค่าวัดทางสถิติที่บ่งบอกถึงการกระจายของค่าข้อมูลจากค่าเฉลี่ยไปทางด้านซ้ายหรือขวา ซึ่งเป็นระยะห่างเฉลี่ยกำลังสองของค่าข้อมูลทุกค่าจากค่าเฉลี่ย แสดงตำแหน่งของส่วนเบี่ยงเบนมาตรฐานของค่าตัวแปร  $X_j$  ของประชากร แทนด้วยสัญลักษณ์  $\sigma_{X_j}$  สามารถคำนวณได้โดย

$$\sigma_{X_j} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_{i,j} - \mu_j)^2} \quad (3.4)$$

และส่วนเบี่ยงเบนมาตรฐานของค่าตัวแปร  $X_j$  ของตัวอย่าง แทนด้วยสัญลักษณ์  $s_{X_j}$  สามารถหาได้จากสูตร

$$s_{X_j} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_{i,j} - \bar{x}_j)^2} \quad (3.5)$$

ส่วนเบี่ยงเบนมาตรฐานนั้นมีหน่วยเช่นเดียวกับหน่วยของตัวแปร การกระจายของค่าข้อมูลจากค่าเฉลี่ยแปรผันตรงกับค่าส่วนเบี่ยงเบนมาตรฐาน กล่าวคือ ส่วนเบี่ยงเบนมาตรฐานที่มีค่ามากบ่งบอกถึงค่าข้อมูลมีการกระจายตัวมาก ในทางกลับกันส่วนเบี่ยงเบนมาตรฐานมีค่าน้อยแสดงถึงการกระจายของค่าข้อมูลมีน้อยตาม


ค่าสถิติที่แสดงลักษณะการกระจายของข้อมูลที่มีความเกี่ยวเนื่องกับส่วนเบี่ยงเบนมาตรฐาน คือ ความแปรปรวน (Variance) ซึ่งเป็นค่ากำลังสองของส่วนเบี่ยงเบนมาตรฐาน ความแปรปรวนของค่าตัวแปร  $X_j$  ของประชากร แทนด้วยสัญลักษณ์  $\sigma_{X_j}^2$  คำนวณได้โดย

$$\sigma_{X_j}^2 = \frac{1}{n} \sum_{i=1}^n (x_{i,j} - \mu_j)^2 \quad (3.6)$$

และความแปรปรวนของค่าตัวแปร  $X_j$  ของตัวอย่าง แทนด้วยสัญลักษณ์  $s_{X_j}^2$  สามารถหาได้จากสูตร

$$s_{X_j}^2 = \frac{1}{n-1} \sum_{i=1}^n (x_{i,j} - \bar{x}_j)^2 \quad (3.7)$$

ค่าความแปรปรวนของข้อมูลมาก แสดงถึงการกระจายของข้อมูลมีมาก ในทางกลับกันค่าความแปรปรวนของข้อมูลน้อย บ่งบอกถึงการกระจายของข้อมูลมีน้อยด้วย ภาพ 3.3 แสดงลักษณะการกระจายของข้อมูลแบบแจกแจงปกติ 3 ลักษณะ ซึ่งมีค่าส่วนเบี่ยงเบนมาตรฐานและค่าความแปรปรวนต่างกัน ในขณะ



ภาพ 3.3: แผนภาพ การ แจกแจง ปกติ 3 ลักษณะ ที่มี ค่า ส่วน เปียง เบน มาตรฐาน ( $\sigma$ ) เท่ากับ 50 25 และ 10 และค่าเฉลี่ยประชากร ( $\mu$ ) เท่ากับ 0

ที่ค่าเฉลี่ยเลขคณิตมีค่าเท่ากัน

### ตัวอย่าง 3.5

พิจารณา ชุดค่าของตัวแปรประสิทธิภาพของงาน (Job Performance: JP)

$X_{JP} = (7, 10, 11, 15, 10, 10, 12, 14, 16, 12)$  จากกลุ่มตัวอย่างพนักงานบริษัท จำนวน 10 คน ซึ่งมีค่าเฉลี่ย ( $\bar{x}_{JP}$ ) เท่ากับ 11.7 (จากตัวอย่าง 3.1) จะสามารถหาค่าส่วนเบี่ยงเบนมาตรฐานและค่าความแปรปรวน ได้ดังนี้

$x_{i,JP}$	$x_{i,JP} - \bar{x}_{JP}$	$(x_{i,JP} - \bar{x}_{JP})^2$
7	$7-11.7 = -4.7$	22.09
10	$10-11.7 = -1.7$	2.89
11	$11-11.7 = -0.7$	0.49
15	$15-11.7 = 3.3$	10.89
10	$10-11.7 = -1.7$	2.89
10	$10-11.7 = -1.7$	2.89
12	$12-11.7 = 0.3$	0.09
14	$14-11.7 = 2.3$	5.29
16	$16-11.7 = 4.3$	18.49
12	$12-11.7 = 0.3$	0.09
รวม		66.10

จากสูตรการหาค่าความแปรปรวน

$$s_{X_{JP}}^2 = \frac{1}{n-1} \sum_{i=1}^n (x_{i,JP} - \bar{x}_{JP})^2$$

แทนค่าในสูตร จะได้

$$\begin{aligned}s_{X_{JP}}^2 &= \frac{1}{10 - 1} \times 66.10 \\&= \frac{1}{9} \times 66.10 = 7.34\end{aligned}$$

และจากสูตรการหาค่าส่วนเบี่ยงเบนมาตรฐาน

$$s_{X_{JP}} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_{i,JP} - \bar{x}_{JP})^2}$$

แทนค่าในสูตรจะได้

$$\begin{aligned}s_{X_{JP}} &= \sqrt{\frac{1}{10 - 1} \times 66.10} \\&= \sqrt{\frac{1}{9} \times 66.10} = \sqrt{7.34} = 2.71\end{aligned}$$

ดังนั้น ค่าส่วนเบี่ยงเบนมาตรฐานของตัวแปรประสิทธิภาพของงาน ( $s_{X_{JP}}$ ) เท่ากับ 2.71 และค่าความแปรปรวนของตัวแปรประสิทธิภาพของงาน ( $s_{X_{JP}}^2$ ) เท่ากับ 7.34 แสดงให้เห็นว่า ค่าข้อมูลประสิทธิภาพของงานส่วนใหญ่กระจายจากค่าเฉลี่ย  $\pm 2.71$  หน่วย

## ความเบี้ยวและความโด่ง

**ความเบี้ยว (Skewness)** คือ ความไม่สมมาตรของลักษณะการแจกแจงค่าตัวแปรสามารถแบ่งออกได้ 2 ลักษณะ ได้แก่ การแจกแจงแบบเบี้ยวขวา (Positive Skewness) และ การแจกแจงแบบเบี้ยวซ้าย (Negative Skewness) แสดงลักษณะเด่นโดยการแจกแจงแบบเบี้ยว และเบี้ยวซ้าย ดังภาพ 3.1 นอกจากเราจะสามารถรับ��ความเบี้ยวของลักษณะการแจกแจงของค่าตัวแปรได้การสังเกตจากค่ากลางข้อมูลแล้ว เรา yang สามารถระบุได้จากการวัดค่าสัมประสิทธิ์ความเบี้ยว (Skewness coefficient) ในที่นี้จะกล่าวเฉพาะการวัดค่าสัมประสิทธิ์ความเบี้ยนเบี้ยววิธีการคำนวณหลายวิธี ในที่นี้จะกล่าวเฉพาะการวัดค่าสัมประสิทธิ์ความเบี้ยนเบี้ยววิธีโมเมนต์ Joanes and Gill 1998 ค่าสัมประสิทธิ์ความเบี้ยวของค่าตัวแปร  $X_j$  แทนด้วยสัญลักษณ์  $g_1$  สามารถคำนวณ โดยใช้สูตรต่อไปนี้

$$g_1 = \frac{\frac{1}{n} \sum_{i=1}^n (x_{i,j} - \bar{x}_j)^3}{\left[ \frac{1}{n} \sum_{i=1}^n (x_{i,j} - \bar{x}_j)^2 \right]^{\frac{3}{2}}} \quad (3.8)$$

เมื่อ  $m_3 = \frac{1}{n} \sum_{i=1}^n (x_{i,j} - \bar{x}_j)^3$  คือ โมเมนต์ศูนย์กลาง ที่ 3 ของตัวแปร  $X_j$  และ  $m_2 = \frac{1}{n} \sum_{i=1}^n (x_{i,j} - \bar{x}_j)^2$  คือ โมเมนต์ศูนย์กลาง ที่ 2 ของตัวแปร  $X_j$  ถ้าค่า

(Joanes and Gill 1998) D. N. Joanes and C. A. Gill (1998). "Comparing measures of sample skewness and kurtosis." In: *Journal of the Royal Statistical Society: Series D (The Statistician)* 47.1. url: <https://rss.onlinelibrary.wiley.com/doi/abs/10.1111/1467-9884.00122>

สัมประสิทธิ์ความเบ้ เท่ากับ 0 แสดงว่าค่าตัวแปรมีลักษณะการแจกแจงปกติ ถ้าค่าสัมประสิทธิ์ความเบ้ น้อยกว่า 0 แสดงว่าค่าตัวแปรมีลักษณะการแจกแจงแบบเบี้ยวซ้าย ในขณะที่ถ้าสัมประสิทธิ์ความเบ้มีค่ามากกว่า 0 แสดงว่าค่าตัวแปรมีลักษณะการแจกแจงแบบเบี้ยวขวา

### ตัวอย่าง 3.6

พิจารณา ชุดค่าของตัวแปรประสิทธิภาพของงาน (Job Performance: JP)

$X_{JP} = (7, 10, 11, 15, 10, 10, 12, 14, 16, 12)$  จากกลุ่มตัวอย่างพนักงานบริษัทจำนวน 10 คน ซึ่งมีค่าเฉลี่ย ( $\bar{x}_{JP}$ ) เท่ากับ 11.7 (จากตัวอย่าง 3.1) จะสามารถหาค่าสัมประสิทธิ์ความเบ้ด้วยวิธีเมเนต์ ได้ดังนี้


$x_{i,JP}$	$x_{i,JP} - \bar{x}_{JP}$	$(x_{i,JP} - \bar{x}_{JP})^2$	$(x_{i,JP} - \bar{x}_{JP})^3$
7	7-11.7 = -4.7	22.09	-103.82
10	10-11.7 = -1.7	2.89	-4.91
11	11-11.7 = -0.7	0.49	-0.34
15	15-11.7 = 3.3	10.89	35.94
10	10-11.7 = -1.7	2.89	-4.91
10	10-11.7 = -1.7	2.89	-4.91
12	12-11.7 = 0.3	0.09	0.03
14	14-11.7 = 2.3	5.29	12.17
16	16-11.7 = 4.3	18.49	79.51
12	12-11.7 = 0.3	0.09	0.03
รวม		66.10	8.79

จากสูตรการหาค่าสัมประสิทธิ์ความเบ้

$$g_1 = \frac{\frac{1}{n} \sum_{i=1}^n (x_{i,j} - \bar{x}_j)^3}{\left[ \frac{1}{n} \sum_{i=1}^n (x_{i,j} - \bar{x}_j)^2 \right]^{\frac{3}{2}}}$$

แทนค่าในสูตร จะได้

$$\begin{aligned} g_1 &= \frac{\frac{1}{10} \times 8.79}{\left[ \frac{1}{10} \times 66.10 \right]^{\frac{3}{2}}} \\ &= \frac{0.879}{6.610^{\frac{3}{2}}} \\ &= \frac{0.879}{3.52} = 0.25 \end{aligned}$$



ภาพ 3.4: แผนภาพการแจกแจง 3 ลักษณะตามค่า ค่าอิคเซส-คอร์โทชิส

ดังนั้น ค่าสัมประสิทธิ์ความเบี้ยวของตัวแปรประสิทธิภาพของงาน เท่ากับ 0.25 เนื่องจากค่าสัมประสิทธิ์ความเบี้ยมากกว่า 0 จึงกล่าวได้ว่า ค่าตัวแปรประสิทธิภาพของงานมีลักษณะการแจกแจงแบบเบี้ยว สอดคล้องกับการพิจารณาค่ากลางข้อมูล ซึ่งมีค่าเฉลี่ยเท่ากับ 11.7 ค่ามัธยฐานเท่ากับ 11.5 และค่าฐานนิยมเท่ากับ 10 จะเห็นว่าค่าเฉลี่ยมีค่ามากกว่าค่ามัธยฐาน และค่ามัธยฐานมีค่ามากกว่าค่าฐานนิยม ซึ่งบ่งบอกถึงการแจกแจงของค่าตัวแปรประสิทธิภาพของงานมีลักษณะเบี้ยว เช่นกัน

**ความโด่ง (Kurtosis)** เป็นค่าสถิติที่อธิบายรูปร่างของลักษณะการแจกแจงอีกค่าหนึ่ง ที่แสดงถึงความหนาของปลายทางทั้ง 2 ข้างของโค้งการแจกแจงข้อมูล Westfall 2014 เราสามารถหาค่าความโด่งของตัวแปร  $X_j$  แทนด้วยสัญลักษณ์  $g_2$  ด้วยวิธีโนเมนต์ ได้จากสูตรต่อไปนี้

$$g_2 = \frac{\frac{1}{n} \sum_{i=1}^n (x_{i,j} - \bar{x}_j)^4}{\left[ \frac{1}{n} \sum_{i=1}^n (x_{i,j} - \bar{x}_j)^2 \right]^2} - 3 \quad (3.9)$$

เมื่อ  $m_4 = \frac{1}{n} \sum_{i=1}^n (x_{i,j} - \bar{x}_j)^4$  คือ โมเมนต์ศูนย์กลาง ที่ 4 ของตัวแปร  $X_j$  และ  $m_2 = \frac{1}{n} \sum_{i=1}^n (x_{i,j} - \bar{x}_j)^2$  คือ โมเมนต์ศูนย์กลาง ที่ 2 ของตัวแปร  $X_j$  ค่าความโด่งที่คำนวณได้จากการ (3.9) เรียกว่า ค่าอิคเซส-คอร์โทชิส (Excess Kurtosis) ลักษณะความโด่งของโค้งการแจกแจงแบ่งออกได้ 3 ลักษณะ ตามค่าอิคเซส-คอร์โทชิส (แสดงดังภาพ 3.4) ดังนี้

- ▶ **แพลติคอร์ติก (Platykurtic)** เป็นการแจกแจงที่มีความโด่งต่ำกว่าความโด่งของการแจกแจงปกติ ซึ่งจะมีค่าอิคเซส-คอร์โทชิส น้อยกว่า 0
- ▶ **เมโซคอร์ติก (Mesokurtic)** เป็นการแจกแจงที่มีความโด่งเท่ากับความโด่งของการแจกแจงปกติ ซึ่งจะมีค่าอิคเซส-คอร์โทชิส เท่ากับ 0
- ▶ **เลปโตคอร์ติก (Leptokurtic)** เป็นการแจกแจงที่มีความโด่งมากกว่าความโด่งของการแจกแจงปกติ ซึ่งจะมีค่าอิคเซส-คอร์โทชิส มากกว่า 0

(Westfall 2014) Peter H. Westfall (2014). "Kurtosis as Peakedness." In: *The American Statistician* 68.3. url: <https://doi.org/10.1080/00031305.2014.917055>

### ตัวอย่าง 3.7

พิจารณา ชุดค่าของตัวแปรประสิทธิภาพของงาน (Job Performance: JP)

$X_{JP} = (7, 10, 11, 15, 10, 10, 12, 14, 16, 12)$  จากกลุ่มตัวอย่างพนักงานบริษัทจำนวน 10 คน ซึ่งมีค่าเฉลี่ย ( $\bar{x}_{JP}$ ) เท่ากับ 11.7 (จากตัวอย่าง 3.1) จะสามารถหาค่าอิคเซส-เคอร์โทซิส ได้ดังนี้

$x_{i,JP}$	$x_{i,JP} - \bar{x}_{JP}$	$(x_{i,JP} - \bar{x}_{JP})^2$	$(x_{i,JP} - \bar{x}_{JP})^4$
7	$7-11.7 = -4.7$	22.09	487.97
10	$10-11.7 = -1.7$	2.89	8.35
11	$11-11.7 = -0.7$	0.49	0.24
15	$15-11.7 = 3.3$	10.89	118.59
10	$10-11.7 = -1.7$	2.89	8.35
10	$10-11.7 = -1.7$	2.89	8.35
12	$12-11.7 = 0.3$	0.09	0.01
14	$14-11.7 = 2.3$	5.29	27.98
16	$16-11.7 = 4.3$	18.49	341.88
12	$12-11.7 = 0.3$	0.09	0.01
รวม		66.10	1001.73

จากสูตรการหาค่าสัมประสิทธิ์ความเบี้ยว

$$g_2 = \frac{\frac{1}{n} \sum_{i=1}^n (x_{i,j} - \bar{x}_j)^4}{\left[ \frac{1}{n} \sum_{i=1}^n (x_{i,j} - \bar{x}_j)^2 \right]^2} - 3$$

แทนค่าในสูตร จะได้

$$\begin{aligned} g_2 &= \frac{\frac{1}{10} \times 1001.73}{\left[ \frac{1}{10} \times 66.10 \right]^2} - 3 \\ &= \frac{100.173}{6.610^2} - 3 \\ &= \frac{100.173}{43.69} - 3 \\ &= 2.29 - 3 = -0.71 \end{aligned}$$

ดังนั้น ค่าอิคเซส-เคอร์โทซิสของตัวแปรประสิทธิภาพของงาน เท่ากับ -0.71 จากค่าอิคเซส-เคอร์โทซิสมีค่าน้อยกว่า 0 จึงกล่าวได้ว่า โค้งการแจกแจงของค่าตัวแปรประสิทธิภาพของงานมีความโดยนัยกว่าการแจกแจงปกติ และมีลักษณะความโดยแบบพลาติเคอร์ติด

## ความแปรปรวนร่วม

ความแปรปรวนร่วม (Covariance) เป็นค่าซึ่งวัดการเปลี่ยนแปลงของค่าตัวแปรตัวใดตัวหนึ่งเมื่อมีการเปลี่ยนแปลงในค่าตัวแปรอีกตัวหนึ่ง ซึ่งแสดงระดับความสัมพันธ์เชิงเส้นตรงของตัวแปร 2 ตัวแปร กำหนดให้  $X_j = (x_{1,j}, x_{2,j}, \dots, x_{n,j})$  และ  $X_k = (x_{1,k}, x_{2,k}, \dots, x_{n,k})$  เป็นชุดของค่าตัวแปร  $X_j$  และ  $X_k$  ของข้อมูลจำนวน  $n$  ข้อมูล โดยค่า  $x_{i,j}$  และ  $x_{i,k}$  เป็นค่าตัวแปร  $X_j$  และ  $X_k$  ของข้อมูลที่  $i$  ค่าความแปรปรวนร่วมระหว่างตัวแปร  $X_j$  และ  $X_k$  ของประชากร แทนด้วยสัญลักษณ์  $\sigma_{X_j, X_k}$  สามารถคำนวณได้จากสูตร


$$\sigma_{X_j, X_k} = \frac{1}{n} \sum_{i=1}^n (x_{i,j} - \mu_j)(x_{i,k} - \mu_k) \quad (3.10)$$

และค่าความแปรปรวนร่วมระหว่างตัวแปร  $X_j$  และ  $X_k$  ของตัวอย่าง แทนด้วยสัญลักษณ์  $s_{X_j, X_k}$  สามารถคำนวณได้จากสูตร


$$s_{X_j, X_k} = \frac{1}{n-1} \sum_{i=1}^n (x_{i,j} - \bar{x}_j)(x_{i,k} - \bar{x}_k) \quad (3.11)$$

ค่าความแปรปรวนร่วม มีค่าที่เป็นไปได้อยู่ระหว่าง  $-\infty$  และ  $\infty$  ค่าความแปรปรวนร่วมที่มีค่ามากกว่า 0 แสดงถึงความสัมพันธ์ระหว่างตัวแปรทั้งสองโดยเมื่อค่าของตัวแปรหนึ่งมีค่ามาก ค่าของอีกตัวแปรหนึ่งมักมีค่ามากด้วย ในทางเดียวกันเมื่อค่าตัวแปรหนึ่งมีค่าน้อย ค่าของอีกตัวแปรหนึ่งมักมีค่าน้อยตามไปด้วย ในกรณีที่ค่าความแปรปรวนร่วมมีค่าน้อยกว่า 0 แสดงถึงความสัมพันธ์ระหว่างสองตัวแปรในทางตรงกันข้าม กล่าวคือเมื่อค่าของตัวแปรหนึ่งมีค่ามาก ค่าของอีกตัวแปรหนึ่งมักมีค่าน้อย ในทางกลับกันเมื่อค่าตัวแปรหนึ่งมีค่าน้อย ค่าของอีกตัวแปรหนึ่งมักมีค่ามาก ส่วนค่าความแปรปรวนร่วมที่มีค่าเท่ากับ 0 บ่งบอกถึงค่าของตัวแปรทั้งสองตัวแปรไม่มีความสัมพันธ์เชิงเส้นตรงต่อกัน แสดงแผนภาพการกระจายของค่าข้อมูลระหว่าง 2 ตัวแปร และค่าความแปรปรวนร่วมที่สัมพันธ์กัน ดังภาพ 3.5


เนื่องจากค่าความแปรปรวนร่วมสามารถแสดงระดับความสัมพันธ์ระหว่างตัวแปรได้เพียง 2 ตัวแปร เราจึงไม่สามารถหาค่าความแปรปรวนร่วมเพียงค่าเดียว ในกรณีที่จำนวนตัวแปรที่สนใจมากกว่า 2 ตัวแปรได้ อย่างไรก็ตาม เราสามารถพิจารณาค่าความแปรปรวนร่วมของแต่ละคู่ของตัวแปรที่ทำการศึกษาโดยสร้างเมตริกซ์ความแปรปรวนร่วม (Covariance Matrix) ขนาด  $d \times d$  เมื่อ  $d$  คือ จำนวนตัวแปรที่ศึกษา กำหนด  $\mathbf{X} = (X_1, X_2, \dots, X_d)$  เป็นชุดตัวแปรบนชุดข้อมูล  $\mathbf{D}$  เมทริกซ์ความแปรปรวนร่วมของชุดตัวแปร  $\mathbf{X}$  แทนด้วยสัญลักษณ์



(a)



(b)



(c)

ภาพ 3.5: แผนภาพ การก ะ จ าย ของ ค่า ข้อมูลที่สัมพันธ์กับค่าความแปรปรวนร่วม 3 ลักษณะ คือ (a) ค่าความแปรปรวนร่วมมีค่ามากกว่า 0 (b) ค่าความแปรปรวนร่วมมีค่าเท่ากับ 0 (c) ค่าความแปรปรวนร่วมมีค่าน้อยกว่า 0

$\text{cov}(\mathbf{X})$  สามารถสร้างได้ ดังนี้

$$\text{cov}(\mathbf{X}) = \begin{bmatrix} \sigma_{X_1, X_1} & \sigma_{X_1, X_2} & \cdots & \sigma_{X_1, X_d} \\ \sigma_{X_2, X_1} & \sigma_{X_2, X_2} & \cdots & \sigma_{X_2, X_d} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{X_d, X_1} & \sigma_{X_d, X_2} & \cdots & \sigma_{X_d, X_d} \end{bmatrix} \quad (3.12)$$

จากคุณสมบัติของค่าความแปรปรวนร่วม  $\sigma_{X_j, X_k} = \sigma_{X_k, X_j}$  จึงทำให้เมทริกซ์ความแปรปรวนร่วมเป็นเมทริกซ์สมมาตร (Symmetric Matrix) ซึ่งมีค่าในตำแหน่ง  $(j, k)$  เท่ากับค่าในตำแหน่ง  $(k, j)$  และจากคุณสมบัติ  $\sigma_{X_j, X_j} = \sigma_{X_j}^2$  ทำให้ค่าในเส้นทแยงมุม (ตำแหน่ง  $(j, k)$  ที่  $j = k$ ) ของเมทริกซ์แสดงค่าความแปรปรวนของค่าตัวแปร  $X_j$  นั่นเอง

### ตัวอย่าง 3.8

พิจารณา ชุดข้อมูลจากการสำรวจระดับเชาว์ปัญญา (IQ) และประสิทธิภาพของงาน (Job Performance: JP) จากตัวอย่างพนักงานบริษัท จำนวน 10 คน (แสดงดังตาราง ด้านล่าง) โดยค่าเฉลี่ยระดับเชาว์ปัญญา ( $\bar{x}_{\text{IQ}}$ ) เท่ากับ 111.5 และค่าเฉลี่ยประสิทธิภาพของงาน ( $\bar{x}_{\text{JP}}$ ) เท่ากับ 11.7 จะสามารถหาค่าความแปรปรวนร่วมระหว่างตัวแปรระดับเชาว์ปัญญาและประสิทธิภาพของงาน ได้ดังนี้

$x_{i,\text{IQ}}$	$x_{i,\text{JP}}$	$x_{i,\text{IQ}} - \bar{x}_{\text{IQ}}$	$x_{i,\text{JP}} - \bar{x}_{\text{JP}}$	$(x_{i,\text{IQ}} - \bar{x}_{\text{IQ}})(x_{i,\text{JP}} - \bar{x}_{\text{JP}})$
99	7	-12.5	-4.7	58.75
105	10	-6.5	-1.7	11.05
105	11	-6.5	-0.7	4.55
106	15	-5.5	3.3	18.15
108	10	-3.5	-1.7	5.95
112	10	0.5	-1.7	-0.85
113	12	1.5	0.3	0.45
115	14	3.5	2.3	8.05
118	16	6.5	4.3	27.95
134	12	22.5	0.3	6.75
รวม				140.80

จากสูตรการหาค่าความแปรปรวนร่วมของตัวอย่าง

$$s_{X_{\text{IQ}}, X_{\text{JP}}} = \frac{1}{n-1} \sum_{i=1}^n (x_{i,\text{IQ}} - \bar{x}_{\text{IQ}})(x_{i,\text{JP}} - \bar{x}_{\text{JP}})$$

แทนค่าในสูตร จะได้

$$\begin{aligned}s_{X_{|Q}, X_{|P}} &= \frac{1}{10 - 1} \sum_{i=1}^{10} (x_{i,|Q} - \bar{x}_{|Q})(x_{i,|P} - \bar{x}_{|P}) \\&= \frac{1}{9} \times 140.80 \\&= 15.64\end{aligned}$$

ดังนั้น ค่าความแปรปรวนร่วมระหว่างตัวแปรระดับเชาว์ปัญญาและประสิทธิภาพของงาน เท่ากับ 15.64 บ่งชี้ว่าค่าตัวแปรระดับเชาว์ปัญญาและประสิทธิภาพของงานมีความสัมพันธ์กัน โดยเมื่อค่าตัวแปรระดับเชาว์ปัญญามีค่ามาก ค่าตัวแปรประสิทธิภาพของงานจะมีค่ามากด้วย ในขณะเดียวกันเมื่อค่าตัวแปรระดับเชาว์ปัญญามีค่าน้อย ค่าตัวแปรประสิทธิภาพของงานจะมีค่าน้อยด้วย


อย่างไรก็ตามขนาดของค่าความแปรปรวนร่วมนั้นยากที่นำมาแปลความหมายและเปรียบเทียบกัน เนื่องจากค่าความแปรปรวนร่วมไม่ได้ถูกทำให้เป็นบรรทัดฐาน อีกทั้งยังขึ้นอยู่กับขนาดของค่าตัวแปร ค่าวัดระดับความสัมพันธ์เชิงเส้นตรงของตัวแปร 2 ตัวแปร อีกค่าหนึ่ง คือ ค่าสัมประสิทธิ์สหสัมพันธ์เพียร์สัน (Pearson Correlation Coefficient) ซึ่งเป็นค่าความแปรปรวนร่วมระหว่างตัวแปร 2 ตัวแปรที่ถูกทำให้เป็นบรรทัดฐาน โดยการหารด้วยผลคูณของค่าส่วนเบี่ยงเบนมาตรฐานของทั้งสองตัวแปร ค่าสัมประสิทธิ์สหสัมพันธ์เพียร์สันระหว่างตัวแปร  $X_j$  และ  $X_k$  สำหรับประชากร แทนด้วยสัญลักษณ์  $\rho_{X_j, X_k}$  สามารถคำนวณได้จาก

$$\rho_{X_j, X_k} = \frac{\sigma_{X_j, X_k}}{\sigma_{X_j} \sigma_{X_k}} \quad (3.13)$$


และ ค่าสัมประสิทธิ์สหสัมพันธ์เพียร์สันระหว่างตัวแปร  $X_j$  และ  $X_k$  สำหรับตัวอย่าง แทนด้วยสัญลักษณ์  $r_{X_j, X_k}$  สามารถคำนวณได้จาก

$$r_{X_j, X_k} = \frac{s_{X_j, X_k}}{\sqrt{s_{X_j} s_{X_k}}} \quad (3.14)$$

ค่าสัมประสิทธิ์สหสัมพันธ์เพียร์สัน มีค่าที่เป็นไปได้อยู่ระหว่าง -1 และ 1 ค่าสัมประสิทธิ์สหสัมพันธ์ ที่มีค่าเท่ากับ 1 บ่งบอกถึงความสัมพันธ์เชิงเส้นตรงอย่างสมบูรณ์แบบระหว่างค่าตัวแปรทั้งสอง เมื่อค่าของตัวแปรหนึ่งเพิ่มขึ้นค่าของอีกตัวแปรหนึ่งจะเพิ่มขึ้นตามไปด้วย ส่วนค่าสัมประสิทธิ์สหสัมพันธ์ที่มีค่าเท่ากับ -1 แสดงถึงความสัมพันธ์เชิงเส้นตรงในลักษณะตรงข้ามอย่างสมบูรณ์ของตัวแปรทั้งสอง โดยเมื่อค่าของตัวแปรหนึ่งเพิ่มขึ้นค่าของอีกตัวแปรหนึ่งจะลดลง ในกรณีที่ค่าสัมประสิทธิ์สหสัมพันธ์มีค่าเท่ากับ 0 แสดงถึงค่าของตัวแปรทั้งสองตัวแปรไม่มีความสัมพันธ์เชิงเส้นตรงต่อกัน ค่าสัมบูรณ์ (Absolute)



ภาพ 3.6: คาร์ล เพียร์สัน (Karl Pearson: ค.ศ. 1857-1936) นักคณิตศาสตร์และนักชีววิทยาอังกฤษ ผู้พัฒนาสัมประสิทธิ์สหสัมพันธ์เพียร์สัน (ที่มา: [https://en.wikipedia.org/wiki/Karl\\_Pearson](https://en.wikipedia.org/wiki/Karl_Pearson))



ภาพ 3.7: แผนภูมิการกระจายของค่าข้อมูลที่สัมพันธ์กับค่าสัมประสิทธิ์สัมพันธ์เพียร์สัน 7 ลักษณะ

(Intrate Value) ค่าสัมประสิทธิ์สัมพันธ์เพียร์สัน ยังชี้วัดระดับความสัมพันธ์ของค่าตัวแปรทั้งสองด้วย กล่าวคือ ค่าสัมบูรณ์ของค่าสัมประสิทธิ์สัมพันธ์ที่มีค่ามาก บ่งบอกถึงค่าตัวแปรทั้งสองมีความสัมพันธ์กันอย่างมากกว่า ในขณะที่ค่าสัมบูรณ์ของค่าสัมประสิทธิ์สัมพันธ์ที่มีค่าน้อย แสดงถึงความสัมพันธ์ในระดับต่ำระหว่างตัวแปรทั้งสองด้วย แสดงแผนภูมิการกระจายของค่าข้อมูลระหว่าง 2 ตัวแปร และสัมประสิทธิ์สัมพันธ์เพียร์สันที่สัมพันธ์กัน ดังภาพ 3.7

เช่น เดียว กับ ค่า ความ แปรปรวน ร่วม เราย สามารถ อธิบาย ความ สัมพันธ์ สำหรับชุดข้อมูล ที่มีจำนวนตัวแปรมากกว่า 2 ตัวแปรได้ โดยการสร้าง เมทริกซ์ สาสัมพันธ์เพียร์สัน (Pearson Correlation Matrix) สำหรับ อธิบาย ความ สัมพันธ์ระหว่างแต่ละคู่ของตัวแปร เมทริกซ์สาสัมพันธ์เพียร์สัน ของชุดตัวแปร  $X$  แทนด้วยสัญลักษณ์  $\text{corr}(X)$  สามารถสร้างได้ ดังนี้

$$\text{corr}(X) = \begin{bmatrix} \rho_{X_1, X_1} & \rho_{X_1, X_2} & \cdots & \rho_{X_1, X_d} \\ \rho_{X_2, X_1} & \rho_{X_2, X_2} & \cdots & \rho_{X_2, X_d} \\ \vdots & \vdots & \ddots & \vdots \\ \rho_{X_d, X_1} & \rho_{X_d, X_2} & \cdots & \rho_{X_d, X_d} \end{bmatrix} \quad (3.15)$$

เมทริกซ์สาสัมพันธ์เพียร์สัน เป็น เมทริกซ์สมมาตร (Symmetric Matrix) ซึ่งมีค่าในตำแหน่ง  $(j, k)$  เท่ากับค่าในตำแหน่ง  $(k, j)$  และค่าในเส้นทแยงมุมของเมทริกซ์ ซึ่งแสดงค่าสัมประสิทธิ์สัมพันธ์เพียร์สันภายใต้ตัวแปรเดียวกัน มีค่าเท่ากับ 1 เสมอ

### ตัวอย่าง 3.9

พิจารณา ชุดข้อมูลจากการสำรวจระดับเชาว์ปัญญา (IQ) และประสิทธิภาพของงาน (Job Performance: JP) จากตัวอย่างพนักงานบริษัท จำนวน 10 คน โดยค่าส่วนเบี่ยงเบนมาตรฐานของค่าตัวแปรระดับเชาว์ปัญญา ( $s_{IQ}$ ) เท่ากับ 9.70 ค่าส่วนเบี่ยงเบนมาตรฐานของค่าตัวแปรประสิทธิภาพของงาน ( $s_{JP}$ ) เท่ากับ 2.71 และค่าความแปรปรวนร่วมระหว่างตัวแปรระดับเชาว์ปัญญาและประสิทธิภาพของงาน เท่ากับ 15.64 (จากตัวอย่าง 3.8) จะสามารถหาค่าสัมประสิทธิ์สัมพันธ์เพียร์สันระหว่างตัวแปรระดับเชาว์ปัญญาและประสิทธิภาพของงาน ได้ดังนี้

จากสูตรการหาค่าสัมประสิทธิ์สัมพันธ์เพียร์สันของตัวอย่าง

$$r_{X_{IQ}, X_{JP}} = \frac{s_{IQ} s_{JP}}{s_Q s_{JP}} \quad (3.16)$$

แทนค่าในสูตร จะได้

$$\begin{aligned} r_{X_{IQ}, X_{JP}} &= \frac{15.64}{9.70 \times 2.71} \\ &= \frac{15.64}{26.287} \\ &= 0.59 \end{aligned}$$

ดังนั้น ค่าสัมประสิทธิ์สหสัมพันธ์เพียร์สันระหว่างตัวแปรระดับเชาว์ปัญญาและประสิทธิภาพของงาน เท่ากับ 0.59 บ่งชี้ว่าค่าตัวแปรระดับเชาว์ปัญญา และประสิทธิภาพของงานมีความสัมพันธ์เชิงเส้นตรงต่อกัน โดยเมื่อค่าตัวแปรระดับเชาว์ปัญญามีค่าเพิ่มขึ้น ค่าตัวแปรประสิทธิภาพของงานจะมีค่าเพิ่มขึ้นตามด้วย ในขณะเดียวกันเมื่อค่าตัวแปรระดับเชาว์ปัญญามีค่าลดลง ค่าตัวแปรประสิทธิภาพของงานจะมีค่าลดลงด้วย

ทั้งค่าความแปรปรวนร่วมและค่าสัมประสิทธิ์สหสัมพันธ์เพียร์สัน เป็นการหาความสัมพันธ์ระหว่างตัวแปร 2 ตัวแปร สามารถนำไปใช้เป็นเครื่องมือในการวิเคราะห์เชิงวินิจฉัยได้ อย่างไรก็ตามวิธีการวิเคราะห์ความสัมพันธ์ทั้ง 2 วิธี จะสามารถใช้ได้ก็ต่อเมื่อตัวแปรทั้ง 2 ตัวแปรมีชนิดข้อมูลเป็นข้อมูลเชิงตัวเลขเท่านั้น ยังมีวิธีการทางสถิติอื่นๆ ที่สามารถใช้ในการวัดระดับความสัมพันธ์ระหว่างตัวแปร 2 ตัวแปร ให้สามารถเลือกใช้ได้อย่างเหมาะสม เช่น การวิเคราะห์ความแปรปรวนหรืออโวโนวา (Analysis of Variance: ANOVA) ซึ่งสามารถใช้ในการวิเคราะห์ความสัมพันธ์ระหว่างตัวแปรเชิงตัวเลขและตัวแปรเชิงกลุ่มได้ และการทดสอบไคกำลังสอง (Chi-squared Test) ซึ่งสามารถใช้ทดสอบความสัมพันธ์ระหว่างตัวแปร 2 ตัวแปรที่มีชนิดข้อมูลเป็นข้อมูลเชิงกลุ่มได้ เป็นต้น

## 3.2 การวิเคราะห์จัดกลุ่ม

การวิเคราะห์จัดกลุ่ม (Cluster Analysis) เป็นการแบ่งข้อมูลออกเป็นกลุ่ม (Cluster) โดยพิจารณาจากค่าตัวแปรหรือคุณลักษณะที่สนใจ อาจแบ่งกลุ่มข้อมูลจาก การ พิจารณา เพียง ตัวแปรเดียว หรือ หลาย ตัวแปร ก็ได้ โดย ข้อมูล ในกลุ่มเดียวกัน จะ มี คุณลักษณะ คล้าย กัน ส่วน ข้อมูล ที่ ออยู่ ต่าง กลุ่ม กัน จะ มี คุณลักษณะ แตกต่าง กัน ในบริบทของวิทยาการข้อมูล การ จัด กลุ่ม ข้อมูล ถูก ดำเนินการอย่างอัตโนมัติโดยใช้วิธีการทางคณิตศาสตร์หรือสถิติ ทำให้สามารถ วิเคราะห์จัดกลุ่มของข้อมูลจำนวนมาก พร้อมกับการพิจารณาคุณลักษณะหลาย คุณลักษณะ ร่วม กัน ได้อย่างมีประสิทธิภาพ ในที่นี้จะกล่าวถึงวิธีการวิเคราะห์ แบ่งกลุ่มพื้นฐานและเป็นที่รู้จักอย่างแพร่หลาย 3 วิธีการ ที่มีแนวคิดพื้นฐาน ที่แตกต่างกัน อย่างไรก็ตาม เนื่องจากวิธีการวิเคราะห์จัดกลุ่มด้วยวิธีการทาง คณิตศาสตร์หรือสถิติมีพื้นฐานในการวัดระยะห่างระหว่างข้อมูล 2 ข้อมูล จึงจะ ได้กล่าวถึงการวัดระยะห่างระหว่างข้อมูลก่อนกล่าวถึงวิธีการวิเคราะห์กลุ่มต่อไป ทั้งนี้เพื่อต้องทราบไว้ประการหนึ่งว่า วิธีการวิเคราะห์จัดกลุ่ม โครงแบบของ วิธีการวิเคราะห์แบ่งกลุ่ม และตัวแปรที่นำมาพิจารณา ที่แตกต่างกัน อาจทำให้ ได้ผลลัพธ์การแบ่งกลุ่มที่แตกต่างกันด้วย อีกทั้งอาจไม่สอดคล้องกับกลุ่มข้อมูล ที่ถูกจัดโดยมนุษย์ด้วยเช่นกัน


### การวัดระยะห่างระหว่างข้อมูล

กำหนดให้  $\mathbf{x}_i = (x_{i,1}, x_{i,2}, \dots, x_{i,d})$  และ  $\mathbf{x}_j = (x_{j,1}, x_{j,2}, \dots, x_{j,d})$  เป็นข้อมูล 2 ข้อมูลที่ประกอบไปด้วยตัวแปรจำนวน  $d$  ตัวแปร เราสามารถแสดงระยะห่างระหว่างข้อมูล 2 ข้อมูล บนปริภูมิลักษณะเด่น  $d$  มิติได้ ด้วยค่าระยะทาง (Distance) ระหว่างข้อมูล ซึ่งบ่งบอกถึงขนาดของความแตกต่างระหว่างค่าตัวแปร ของข้อมูลทั้ง 2 ข้อมูล โดยทั่วไปแล้ว ค่าระยะทางระหว่างข้อมูลที่มีค่าน้อย แสดงว่าข้อมูลอยู่ใกล้กันบนปริภูมิลักษณะเด่น ในขณะที่ค่าระยะทางที่มีค่านาก บ่งบอกว่าข้อมูลอยู่ไกลกันมากด้วย การวัดระยะทางระหว่างข้อมูล 2 ข้อมูล สามารถทำได้หลายวิธี มีวิธีการที่เป็นที่รู้จักโดยทั่วไป ดังนี้

#### ระยะทางแบบยุคลิด (Euclidean Distance)

ระยะทางแบบยุคลิด ระยะห่างข้อมูล  $\mathbf{x}_i$  และ  $\mathbf{x}_j$  คือ ความยาวของเส้นตรงที่ลาก ระยะห่างจุดข้อมูลทั้ง 2 จุดข้อมูลในปริภูมิยุคลิด  $d$  มิติ สามารถคำนวณได้ ดังนี้

$$d(\mathbf{x}_i, \mathbf{x}_j) = \sqrt{\sum_{k=1}^d (x_{i,k} - x_{j,k})^2} \quad (3.17)$$



ภาพ 3.8: แนวคิดของการวัดระยะทางแบบยุคลิดของข้อมูลในปริภูมิ 2 มิติ


เมื่อ  $d(\mathbf{x}_i, \mathbf{x}_j)$  คือ ค่าระยะทางแบบยุคลิดระหว่างข้อมูลทั้งสองข้อมูล ซึ่งจะมีค่าเท่ากับ 0 เมื่อข้อมูลทั้งสองมีค่าตัวแปรทุกตัวแปรเท่ากัน นั่นหมายถึง ข้อมูลทั้งสองเป็นจุดข้อมูลเดียวกันบนปริภูมิลักษณะเด่น ระยะทางแบบยุคลิดจะมีค่ามาก เมื่อค่าตัวแปรของข้อมูลทั้ง 2 ข้อมูลแตกต่างกันมาก แสดงแนวคิดของการวัดระยะทางแบบยุคลิดของข้อมูลในปริภูมิ 2 มิติ ดังภาพ 3.8

### ระยะทางแบบ曼นฮัตตัน (Manhattan Distance)

ระยะทางแบบ曼นฮัตตัน ระหว่างข้อมูล  $\mathbf{x}_i$  และ  $\mathbf{x}_j$  แทนด้วย สัญลักษณ์  $d_M(\mathbf{x}_i, \mathbf{x}_j)$  สามารถคำนวณได้ดังนี้

$$d_M(\mathbf{x}_i, \mathbf{x}_j) = \sum_{k=1}^d |x_{i,k} - x_{j,k}| \quad (3.18)$$

เข่นเดียวกันระยะทางแบบยุคลิด ค่าระยะทางแบบ曼นฮัตตัน จะมีค่าเท่ากับ 0 เมื่อข้อมูลทั้ง 2 ข้อมูล มีค่าตัวแปรเท่ากันทุกตัวแปร ระยะทางแบบ曼นฮัตตันมีค่ามาก แสดงว่าข้อมูลทั้ง 2 ข้อมูลอยู่ห่างกันมาก เช่นกัน แสดงแนวคิดของการวัดระยะทางแบบ曼นฮัตตันของข้อมูลในปริภูมิ 2 มิติ ดังภาพ 3.8 ค่าระยะทางแบบ曼นฮัตตันนี้เหมือนระยะการเดินทางจากสี่แยกหนึ่งไปยังอีksี่แยกหนึ่งในเขตการปกรครองท้องถิ่น曼นฮัตตัน นครนิวยอร์ก สหรัฐอเมริกา ซึ่งมีการวางแผนเมืองเป็นรูปตารางพิกัดณา



ภาพ 3.9: แนวคิดของการวัดระยะทางแบบ曼นฮัตตันของข้อมูลในปริภูมิ 2 มิติ

### ตัวอย่าง 3.10


พิจารณา ข้อมูล 2 ข้อมูลที่ประกอบด้วยตัวแปรเชิงตัวเลข 4 ตัวแปร ต่อไปนี้

$$\mathbf{x}_1 = (5.1, 3.5, 1.4, 0.2) \text{ และ } \mathbf{x}_2 = (5.0, 3.5, 1.6, 0.6)$$

จะสามารถวัดระยะทางแบบยุคลิดระหว่าง  $\mathbf{x}_1$  และ  $\mathbf{x}_2$  ได้โดยใช้สมการ (3.17) ดังนี้

$$\begin{aligned} d(\mathbf{x}_1, \mathbf{x}_2) &= \sqrt{\sum_{k=1}^4 (x_{1,k} - x_{2,k})^2} \\ &= \sqrt{(5.1 - 5.0)^2 + (3.5 - 3.5)^2 + (1.4 - 1.6)^2 + (0.2 - 0.6)^2} \\ &= \sqrt{0.1^2 + 0^2 + (-0.2)^2 + (-0.4)^2} \\ &= \sqrt{0.01 + 0 + 0.04 + 0.16} \\ &= \sqrt{0.21} = 0.46 \end{aligned}$$

และจะสามารถวัดระยะทางแบบ曼นฮัตตันระหว่าง  $\mathbf{x}_1$  และ  $\mathbf{x}_2$  ได้โดย



ภาพ 3.10: แผนที่ ใจกลาง เขตการปกรครอง ท้องถิ่น แม่น ฮัตตัน นครนิวยอร์ก สหรัฐอเมริกา (ที่มา: <https://www.pinterest.com/pin/107523509833448381/>)

ใช้สมการ (3.18) ดังนี้

$$\begin{aligned}
 d_M(\mathbf{x}_1, \mathbf{x}_2) &= \sum_{k=1}^4 |x_{1,k} - x_{2,k}| \\
 &= |5.1 - 5.0| + |3.5 - 3.5| + |1.4 - 1.6| + |0.2 - 0.6| \\
 &= 0.1 + 0 + 0.2 + 0.4 \\
 &= 0.7
 \end{aligned}$$


ดังนั้น ระยะทางแบบยุคลิดและระยะทางแบบ曼นอัตตันระหว่าง  $\mathbf{x}_1$  และ  $\mathbf{x}_2$  มีค่าเท่ากับ 0.46 และ 0.7 ตามลำดับ

### ระยะทางแบบแฮมมิ่ง (Hamming Distance)

ระยะทางแบบแฮมมิ่ง เป็นการนับจำนวนตัวแปรที่มีค่าไม่เหมือนกันของข้อมูลทั้ง 2 ข้อมูล ซึ่งมักใช้กับข้อมูลที่มีตัวแปรเป็นชนิดข้อมูลเชิงกลุ่ม สามารถคำนวณได้ ดังนี้

$$d_H(\mathbf{x}_i, \mathbf{x}_j) = \sum_{k=1}^d (x_{i,k} \neq x_{j,k}) \quad (3.19)$$

เมื่อ  $d_H(\mathbf{x}_i, \mathbf{x}_j)$  คือ ค่าระยะทางแบบแฮมมิ่ง และการดำเนินการเปรียบเทียบไม่เท่ากับ  $\neq$  ให้ผลลัพธ์เป็น 1 ก็ต่อเมื่อ ตัวถูกดำเนินการทั้งสองมีค่าต่างกัน และให้ผลลัพธ์เป็น 0 ก็ต่อเมื่อตัวถูกดำเนินการทั้งสองมีค่าไม่ต่างกัน ค่าระยะทางแบบแฮมมิ่งจะมีค่าเท่ากับ 0 ก็ต่อเมื่อข้อมูลทั้ง 2 ข้อมูลมีค่าตัวแปรเหมือนกันทุกตัวแปร และมีค่ามากที่สุดที่เป็นไปได้ เท่ากับ จำนวนตัวแปรของข้อมูล ซึ่งจะเกิดขึ้นในกรณีที่ข้อมูลทั้ง 2 ข้อมูลมีค่าตัวแปรแตกต่างกันทุกตัวแปร แนวคิดของการวัดระยะทางแบบแฮมมิ่ง (ซึ่งแสดงตัวอย่างสำหรับคำที่ประกอบด้วย 3 ตัวอักษร ดังภาพ 3.11) สามารถอธิบายได้ด้วยจำนวนครั้งในการแก้ไขคำๆ หนึ่งให้เป็นคำอีกคำหนึ่งที่มีความยาวของคำเท่ากัน (ในภาพ 3.11 แสดงการแก้ไขคำว่า “cap” ไปเป็นคำว่า “ant” โดยมีลำดับการเปลี่ยนแปลงจากตัวอักษรทางซ้ายไปยังตัวอักษรทางขวา สุด)



ภาพ 3.11: แนวคิดของการวัดระยะทางแบบแฮมมิ่ง แสดงการเปลี่ยนคำว่า “cap” ไปเป็นคำว่า “ant” โดยมีลำดับการเปลี่ยนแปลงจากตัวอักษรทางซ้ายไปยังตัวอักษรทางขวา

### ตัวอย่าง 3.11

พิจารณา ข้อมูล 2 ข้อมูลที่ประกอบด้วยตัวแปรเชิงกลุ่ม 3 ตัวแปร ต่อไปนี้

$$\begin{aligned}
 \mathbf{x}_1 &= (\text{Short}, \text{Medium}, \text{versicolor}) \text{ และ} \\
 \mathbf{x}_2 &= (\text{VeryShort}, \text{Medium}, \text{setosa})
 \end{aligned}$$

จะสามารถวัดระยะทางแบบแฮมมิ่งระหว่าง  $\mathbf{x}_1$  และ  $\mathbf{x}_2$  ได้โดยใช้สมการ

3.19 ดังนี้

$$\begin{aligned}
 d_H(\mathbf{x}_i, \mathbf{x}_j) &= \sum_{k=1}^d (x_{i,k} \neq x_{j,k}) \\
 &= (\text{Short} \neq \text{VeryShort}) + (\text{Medium} \neq \text{Medium}) \\
 &\quad + (\text{versicolor} \neq \text{setosa}) \\
 &= 1 + 0 + 1 = 2
 \end{aligned}$$

ดังนั้น ระยะทางแบบแฮมมิงระหว่าง  $\mathbf{x}_1$  และ  $\mathbf{x}_2$  มีค่าเท่ากับ 2 นั่นคือ มีตัวแปรที่ข้อมูล  $\mathbf{x}_1$  และ  $\mathbf{x}_2$  มีค่าต่างกัน จำนวน 2 ตัวแปร


นอกจากค่าระยะทางแล้ว เรายังสามารถการอธิบายระยะห่างระหว่างข้อมูลด้วยความคล้าย (Similarity) ซึ่งบ่งบอกขนาดของความใกล้เคียงกันระหว่างค่าตัวแปรของข้อมูลทั้งสอง มีวิธีการวัดความคล้ายที่น่าสนใจ ดังนี้

### ความคล้ายแบบโคไซน์ (Cosine Similarity)

ความคล้ายแบบโคไซน์ของข้อมูล 2 ข้อมูล เป็นการวัดค่าโคไซน์ (Cosine) ของมุนระหว่างเวกเตอร์ 2 เวกเตอร์ ซึ่งพุ่งจากจุดกำเนิด (Origin) ไปยังจุดข้อมูลทั้งสองบนปริภูมิสักขณะเด่น แนวคิดของการวัดความคล้ายแบบโคไซน์ของข้อมูลในปริภูมิ 2 มิติ สามารถแสดงได้ดังภาพ 3.12 ความคล้ายแบบโคไซน์ระหว่างข้อมูล  $\mathbf{x}_i$  และ  $\mathbf{x}_j$  แทนด้วยสัญลักษณ์  $s_{cos}(\mathbf{x}_i, \mathbf{x}_j)$  สามารถคำนวณได้ ดังนี้

$$s_{cos}(\mathbf{x}_i, \mathbf{x}_j) = \frac{\sum_{k=1}^d x_{i,k} x_{j,k}}{\sqrt{\sum_{k=1}^d x_{i,k}^2} \sqrt{\sum_{k=1}^d x_{j,k}^2}} \quad (3.20)$$

ความคล้ายแบบโคไซน์จะมีค่าเท่ากับ 1 เมื่อเวกเตอร์ของข้อมูล 2 ข้อมูลมีทิศทางเดียวกัน ความคล้ายแบบโคไซน์จะมีค่าเท่ากับ 0 เมื่อเวกเตอร์ของข้อมูล 2 ข้อมูลทำมุมตั้งฉากกัน และความคล้ายแบบโคไซน์จะมีค่าเท่ากับ -1 เมื่อเวกเตอร์ของข้อมูล 2 ข้อมูลมีทิศทางตรงข้ามกัน ในทางปฏิบัติแล้ว เราจะใช้การวัดความคล้ายแบบโคไซน์ สำหรับข้อมูลที่ค่าตัวแปรทุกตัวมีค่ามากกว่าหรือเท่ากับ 0 ซึ่งจะทำให้ค่าความคล้ายที่วัดได้อยู่ในช่วงระหว่าง 0 ถึง 1



ภาพ 3.12: แนวคิดของการวัดความคล้ายแบบโคไซน์ของข้อมูลในปริภูมิ 2 มิติ

### ตัวอย่าง 3.12

พิจารณา ข้อมูล 2 ข้อมูลที่ประกอบด้วยตัวแปรเชิงตัวเลข 4 ตัวแปร ต่อไปนี้

$$\mathbf{x}_1 = (5.1, 3.5, 1.4, 0.2) \text{ และ } \mathbf{x}_2 = (5.0, 3.5, 1.6, 0.6)$$

จะสามารถวัดความคล้ายแบบโคไซน์ระหว่าง  $\mathbf{x}_1$  และ  $\mathbf{x}_2$  ได้โดยใช้สมการ 3.20 ดังนี้

$$\begin{aligned}
 s_{\cos}(\mathbf{x}_1, \mathbf{x}_2) &= \frac{\sum_{k=1}^4 x_{1,k} x_{2,k}}{\sqrt{\sum_{k=1}^4 x_{1,k}^2} \sqrt{\sum_{k=1}^4 x_{2,k}^2}} \\
 &= \frac{(5.1 \times 5.0) + (3.5 \times 3.5) + (1.4 \times 1.6) + (0.2 \times 0.6)}{\sqrt{5.1^2 + 3.5^2 + 1.4^2 + 0.2^2} \sqrt{5.0^2 + 3.5^2 + 1.6^2 + 0.6^2}} \\
 &= \frac{25.50 + 12.25 + 2.24 + 0.12}{\sqrt{26.01 + 12.25 + 1.96 + 0.04} \sqrt{25.00 + 12.25 + 2.56 + 0.36}} \\
 &= \frac{40.11}{\sqrt{40.26} \sqrt{40.17}} \\
 &= \frac{40.11}{6.35 \times 6.34} \\
 &= \frac{40.11}{40.26} = 0.9963
 \end{aligned}$$

ดังนั้น ความคล้ายแบบโคไซน์ระหว่าง  $\mathbf{x}_1$  และ  $\mathbf{x}_2$  มีค่าเท่ากับ 0.9963

### สัมประสิทธิ์ความคล้ายแจ็คการ์ด (Jaccard Similarity Coefficient)

สัมประสิทธิ์ความคล้ายแจ็คการ์ด เป็นมาตรวัดความคล้ายระหว่างเซตจำกัด (Finite Set) 2 เซต สามารถคำนวณได้ ดังนี้


$$s_J(A, B) = \frac{A \cap B}{A \cup B} \quad (3.21)$$

เมื่อ  $s_J(A, B)$  คือ ค่าสัมประสิทธิ์ความคล้ายแจ็คการ์ดระหว่างเซต  $A$  และ  $B$  จะมีค่าอยู่ระหว่าง 0 และ 1 โดยถ้าเซตทั้งสองมีสมาชิกร่วมกันจำนวนมากเมื่อเทียบกับจำนวนรวมของสมาชิกของทั้ง 2 เซต ค่าสัมประสิทธิ์ความคล้ายแจ็คการ์ดจะมีค่าเข้าใกล้ค่า 1 ในกรณีที่เซตทั้งสองเป็นเซตว่าง (Empty Set) ค่าสัมประสิทธิ์ความคล้ายแจ็คการ์ดถูกกำหนดให้มีค่าเท่ากับ 1 และหากเซตทั้งสองไม่มีสมาชิกร่วมกันเลย ค่าสัมประสิทธิ์ความคล้ายแจ็คการ์ดจะมีค่าเท่ากับ 0

สำหรับข้อมูล 2 ข้อมูล ที่ประกอบด้วยตัวแปรเชิงกลุ่ม เราสามารถหาค่าสัมประสิทธิ์ความคล้ายแจ็คการ์ดได้ โดยการเข้ารหัสข้อมูลด้วยวิธีการเข้ารหัสแบบบัน-ซอทก่อน ซึ่งจะทำให้ข้อมูลมีลักษณะเป็นข้อมูลแบบทวิภาค แล้วจึงคำนวณค่าสัมประสิทธิ์ความคล้ายแจ็คการ์ด ด้วยสูตรต่อไปนี้

$$s_J(\mathbf{x}_i, \mathbf{x}_j) = \frac{\sum_{k=1}^d \min(x_{i,k}, x_{j,k})}{\sum_{k=1}^d \max(x_{i,k}, x_{j,k})} \quad (3.22)$$

เมื่อ  $\min(a, b)$  และ  $\max(a, b)$  เป็นฟังก์ชันการหาค่าน้อยที่สุดและค่ามากที่สุด



ภาพ 3.13: แนวคิดของการวัดความคล้ายด้วยสัมประสิทธิ์ความคล้ายแจ็คการ์ด ข้อมูลในปริภูมิ 2 มิติ

ระหว่างค่าพารามิเตอร์  $a$  และ  $b$  นอกจากนี้เรายังสามารถประยุกต์ใช้สูตรข้างต้นสำหรับหาค่าสัมประสิทธิ์ความคล้ายแจ็คการ์ด ระหว่างข้อมูล 2 ข้อมูล ที่ตัวแปรเชิงตัวเลขทุกตัวแปรมีค่าที่เป็นไปได้มากกว่าหรือเท่ากับ 0 ได้ ภาพ 3.13 แสดงแนวคิดของ การวัดความคล้ายด้วยสัมประสิทธิ์ความคล้ายแจ็คการ์ดของข้อมูลในปริภูมิ 2 มิติ

### ตัวอย่าง 3.13

พิจารณา ข้อมูล 2 ข้อมูลที่ประกอบด้วยตัวแปรเชิงกลุ่ม 3 ตัวแปร ต่อไปนี้

$$\mathbf{x}_1 = (\text{Male}, \text{Singer}, \text{Married}) \text{ และ } \mathbf{x}_2 = (\text{Male}, \text{Actor}, \text{InRelationship})$$

เมื่อทำการเข้ารหัสข้อมูลทั้งสองด้วยวิธีเข้ารหัสแบบวัน-ยกoth จะได้

$$\mathbf{x}_1 = (1, 0|1, 0, 0|0, 0, 0, 1) \text{ และ } \mathbf{x}_2 = (1, 0|0, 1, 0|0, 0, 1, 0)$$

จะสามารถวัดค่าสัมประสิทธิ์ความคล้ายแจ็คการ์ดระหว่าง  $\mathbf{x}_1$  และ  $\mathbf{x}_2$  ได้โดยใช้สมการ 3.22 ดังนี้

$$\begin{aligned} s_J(\mathbf{x}_1, \mathbf{x}_2) &= \frac{\sum_{k=1}^9 \min(x_{1,k}, x_{2,k})}{\sum_{k=1}^9 \max(x_{1,k}, x_{2,k})} \\ &= \frac{1 + 0 + 0 + 0 + 0 + 0 + 0 + 0 + 0}{1 + 0 + 1 + 1 + 0 + 0 + 0 + 1 + 1} \\ &= \frac{1}{5} = 0.2 \end{aligned}$$

ดังนั้น ค่าสัมประสิทธิ์ความคล้ายแจ็คการ์ดระหว่าง  $\mathbf{x}_1$  และ  $\mathbf{x}_2$  มีค่าเท่ากับ 0.2

### ตัวอย่าง 3.14

พิจารณา ข้อมูล 2 ข้อมูลที่ประกอบด้วยตัวแปรเชิงตัวเลข 4 ตัวแปร ต่อไปนี้

$$\mathbf{x}_1 = (5.1, 3.5, 1.4, 0.2) \text{ และ } \mathbf{x}_2 = (5.0, 3.5, 1.6, 0.6)$$

จะสามารถวัดค่าสัมประสิทธิ์ความคล้ายแจ็คการ์ดระหว่าง  $\mathbf{x}_1$  และ  $\mathbf{x}_2$  ได้

ดังนี้

$$\begin{aligned}
 s_j(\mathbf{x}_1, \mathbf{x}_2) &= \frac{\sum_{k=1}^4 \min(x_{1,k}, x_{2,k})}{\sum_{k=1}^4 \max(x_{1,k}, x_{2,k})} \\
 &= \frac{\min(5.1, 5.0) + \min(3.5, 3.5) + \min(1.4, 1.6) + \min(0.2, 0.6)}{\max(5.1, 5.0) + \max(3.5, 3.5) + \max(1.4, 1.6) + \max(0.2, 0.6)} \\
 &= \frac{5.0 + 3.5 + 1.4 + 0.2}{5.1 + 3.5 + 1.6 + 0.6} \\
 &= \frac{10.10}{10.80} = 0.94
 \end{aligned} \tag{3.23}$$

ดังนั้น ค่าสัมประสิทธิ์ความคล้ายแจ็คการ์ดระหว่าง  $\mathbf{x}_1$  และ  $\mathbf{x}_2$  มีค่าเท่ากับ 0.94

เราสามารถแทนระยะห่างระหว่างข้อมูลทั้งหมดในชุดข้อมูลได้ในรูปแบบ เมทริกซ์ระยะทาง (Distance Matrix) หรือ เมทริกซ์ความคล้าย (Similarity Matrix) ซึ่งเป็นเมทริกซ์จตุรัสขนาด  $n \times n$  เมื่อ  $n$  คือ จำนวนข้อมูลทั้งหมดในชุดข้อมูล และในตำแหน่ง  $(i, j)$  ของเมทริกซ์จัดเก็บค่าระยะทาง หรือ ค่าความคล้ายระหว่างข้อมูล  $\mathbf{x}_i$  และ  $\mathbf{x}_j$  สามารถแสดงเมทริกซ์ระยะทาง หรือ เมทริกซ์ความคล้าย สำหรับชุดข้อมูล  $\mathbf{D}$  ได้ดังนี้

$$\Delta = \begin{bmatrix} \delta_{x_1, x_1} & \delta_{x_1, x_2} & \dots & \delta_{x_1, x_n} \\ \delta_{x_2, x_1} & \delta_{x_2, x_2} & \dots & \delta_{x_2, x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \delta_{x_d, x_1} & \delta_{x_d, x_2} & \dots & \delta_{x_d, x_n} \end{bmatrix} \tag{3.24}$$

เมื่อ  $\delta_{x_i, x_j}$  คือ ค่าระยะทางหรือค่าความคล้ายระหว่างข้อมูล  $\mathbf{x}_i$  และ  $\mathbf{x}_j$  ซึ่ง ถูกคำนวณด้วยมาตรฐานวัดระยะทางหรือความคล้ายวิธีการใดวิธีการหนึ่ง เราจะเรียกเมทริกซ์  $\Delta$  ว่า เมทริกซ์ระยะทาง เมื่อค่าระยะห่างระหว่างข้อมูลถูกคำนวณด้วยมาตรฐานวัดระยะทาง และจะเรียกเมทริกซ์  $\Delta$  ว่า เมทริกซ์ความคล้าย เมื่อค่าระยะห่างระหว่างข้อมูลถูกคำนวณด้วยมาตรฐานวัดความคล้าย เมทริกซ์  $\Delta$  นี้อาจเป็นเมทริกซ์สมมาตรหรือไม่ก็ได้ ทั้งนี้ขึ้นอยู่กับมาตรฐานวัดระยะห่างระหว่างข้อมูลที่นำมาใช้

## การจัดกลุ่มแบบเคลื่อน

การจัดกลุ่มแบบเคลื่อน (K-means Clustering) เป็นการแบ่งข้อมูลออกเป็น  $k$  กลุ่ม โดยระยะทางระหว่างข้อมูลในกลุ่มเดียวกันมีค่าน้อยกว่าระยะทางไปยังข้อมูลที่อยู่ต่างกลุ่มกัน เราสามารถนิยามปัญหาการจัดกลุ่มข้อมูลดังกล่าวให้อยู่

ในรูปการคำนวณ โดยกำหนดให้  $\mu_j = (\mu_1, \mu_2, \dots, \mu_d)$  เป็นจุดศูนย์กลางของกลุ่มข้อมูล  $C_j$  บนปริภูมิลักษณะเด่น  $d$  มิติ เมื่อ  $j = 1, 2, \dots, k$  โดย  $\mu_i$  เป็นค่าเฉลี่ยของตัวแปร  $X_i$  ของข้อมูลในกลุ่ม  $C_j$  และนิยามฟังก์ชันผลรวมกำลังสองของระยะทางระหว่างข้อมูลและจุดศูนย์กลางของกลุ่มที่ข้อมูลนั้นอยู่ ดังนี้

$$J = \sum_{j=1}^k \sum_{x_i \in C_j} d(x_i, \mu_j)^2 \quad (3.25)$$

เป้าหมายของการจัดกลุ่มแบบเคมีน คือ การแบ่งข้อมูลออกเป็น  $k$  กลุ่ม โดยผลรวมกำลังสองของระยะทางระหว่างข้อมูลและจุดศูนย์กลางของกลุ่มของข้อมูลนั้นมีค่าน้อยที่สุด เราสามารถแสดงเป้าหมายดังกล่าวในรูปฟังก์ชันวัตถุประสงค์ (Objective Function) ได้ดังนี้

$$C^* = \arg \min_C J \quad (3.26)$$

เมื่อ  $C = \{C_1, C_2, \dots, C_k\}$  คือ เซตของกลุ่มข้อมูล  $k$  กลุ่ม โดย  $C_j$  เป็นเซตของข้อมูลที่ถูกจัดอยู่ในกลุ่ม

จากการนิยามปัญหาการจัดกลุ่มแบบเคมีนข้างต้น สามารถแก้ปัญหานี้ได้โดยใช้กระบวนการวนเร็วซ้ำ (Iterative Process) มีขั้นตอน ดังนี้

ขั้นตอนที่ 1 สุมจุดบนปริภูมิลักษณะเด่นจำนวน  $k$  จุด เพื่อแทนจุดศูนย์กลางของข้อมูลแต่ละกลุ่ม จะได้  $\{\mu_1, \mu_2, \dots, \mu_k\}$

ขั้นตอนที่ 2 สร้างเซตว่าง  $C_j$  สำหรับ  $j = 1, 2, \dots, k$  เพื่อใช้เก็บข้อมูลที่ถูกจัดอยู่ในกลุ่ม  $C_j$

ขั้นตอนที่ 3 กำหนดตัวนับจำนวนรอบของการทำซ้ำ  $t$  ให้มีค่าเริ่มต้นเท่ากับ 0

ขั้นตอนที่ 4 สำหรับข้อมูลแต่ละข้อมูล  $x_i$  ในชุดข้อมูล D ทำขั้นตอนดังนี้

4.1 คำนวณค่าระยะทางระหว่าง  $x_i$  และ  $\mu_j$  เมื่อ  $j = 1, 2, \dots, k$  สำหรับจุดศูนย์กลางของแต่ละกลุ่มข้อมูล

4.2 หากลุ่มข้อมูล  $C_j$  ที่ค่าระยะทางระหว่าง  $x_i$  และ  $\mu_j$  มีค่าน้อยที่สุด

4.3 นำข้อมูล  $x_i$  เข้าอยู่ในกลุ่ม  $C_j$

ขั้นตอนที่ 5 สำหรับแต่ละกลุ่มข้อมูล  $C_j$  เมื่อ  $j = 1, 2, \dots, k$  ทำปรับค่าจุดศูนย์กลางข้อมูล  $\mu_j$  โดย  $\mu_j = \frac{1}{|C_j|} \sum_{x_i \in C_j} x_i$

ขั้นตอนที่ 6 เพิ่มค่าตัวนับ  $t$  ขึ้น 1

ขั้นตอนที่ 7 กลับไปเริ่มดำเนินการตั้งแต่ขั้นตอนที่ 4 จนกระทั่งไม่มีการเปลี่ยนกลุ่มของข้อมูล หรือจำนวนรอบของการทำซ้ำ  $t$  มีค่ามากเกินกว่าที่กำหนด

จะเห็นได้ว่าขั้นตอนวิธีการจัดกลุ่มแบบเคมีนนั้น เป็นการดำเนินการวนซ้ำของการจัดข้อมูลแต่ละข้อมูลเข้ากลุ่ม (ในขั้นตอนที่ 4) และการคำนวณหา

จุดศูนย์กลางกลุ่มข้อมูล (ในขั้นตอนที่ 5) กระบวนการรวมข้า้นี้จะถูกดำเนินการต่อเนื่องไปจนกระทั่งไม่มีข้อมูลใดถูกเปลี่ยนกลุ่ม ในบางครั้งอาจต้องใช้จำนวนรอบของการรวมข้า้นจำนวนมาก อย่างไรก็ตาม เราสามารถกำหนดจำนวนรอบสูงสุด เพื่อให้การรวมข้า้วยุติการทำงาน แม้ว่ายังมีการเปลี่ยนกลุ่มของข้อมูลอยู่ก็ได้ การใช้งานวิธีการจัดกลุ่มแบบเคลื่อนเรามาจะต้องกำหนดค่าจำนวนกลุ่มที่ต้องการ เรียกว่าพารามิเตอร์ และมาตรฐานระดับทางที่เหมาะสม ซึ่งขึ้นอยู่กับสมมติฐานและลักษณะของข้อมูลที่ทำการจัดกลุ่ม

### ตัวอย่าง 3.15

จากภาพ 3.14 แสดงการแบ่งข้อมูลที่ประกอบด้วยตัวแปรเชิงตัวเลข 2 ตัวแปร คือ  $X_1$  และ  $X_2$  จำนวน 20 ข้อมูล (แสดงข้อมูลในแผนภาพการกระจายช้ายานของภาพ 3.14) ออกเป็น 2 กลุ่มด้วยวิธีการจัดกลุ่มแบบเคลื่อน เมื่อกำหนด  $k = 2$  เริ่มต้นด้วยการสุ่มจุดศูนย์กลางกลุ่ม 2 จุด (แทนด้วยสัญลักษณ์ ★ ในแผนภาพการกระจายขawan) ได้ค่า ดังนี้

$$\mu_1 = (2.50, 2.05) \text{ และ } \mu_2 = (4.30, 5.07)$$

ในการทำงานรอบที่ 1 ( $t = 1$ ) ทำการจัดข้อมูลแต่ละข้อมูลเข้ากลุ่มที่ระยะห่างจากข้อมูลและจุดศูนย์กลางของกลุ่มมีค่าน้อยที่สุด ได้ผลลัพธ์ดังแผนภาพการกระจายขawanของภาพ 3.14 ข้อมูลที่ถูกจัดเข้ากลุ่มที่ 1 แทนด้วยสัญลักษณ์ ◆ และข้อมูลที่ถูกจัดเข้ากลุ่มที่ 2 แทนด้วยสัญลักษณ์ + ต่อมาทำการปรับจุดศูนย์กลางกลุ่ม ได้ค่าดังนี้

$$\mu_1 = (2.24, 1.45) \text{ และ } \mu_2 = (4.02, 4.80)$$

ในรอบการทำงานที่ 2 ( $t = 2$ ) ทำการปรับกลุ่มข้อมูลอีกครั้งโดยนำข้อมูลแต่ละข้อมูลเข้ากลุ่มที่ระยะห่างจากข้อมูลและจุดศูนย์กลางของกลุ่มมีค่าน้อยที่สุด ได้ผลลัพธ์ดังแผนภาพการกระจายช้ายานล่าง แล้วจึงทำการปรับจุดศูนย์กลางกลุ่ม ได้ค่าดังนี้


$$\mu_1 = (2.01, 1.33) \text{ และ } \mu_2 = (4.08, 4.59)$$

ในรอบการทำงานที่ 3 ( $t = 3$ ) ทำการจัดกลุ่มข้อมูลอีกครั้ง โดยใช้จุดศูนย์กลางที่ถูกคำนวณค่าใหม่แล้ว ได้ผลลัพธ์ดังแผนภาพการกระจายขawanล่าง แล้วทำการปรับจุดศูนย์กลางกลุ่ม ได้ค่าดังนี้

$$\mu_1 = (2.01, 1.33) \text{ และ } \mu_2 = (4.08, 4.59)$$

จะสังเกตเห็นว่ากลุ่มข้อมูลไม่มีการเปลี่ยนแปลง จึงทำให้ค่าจุดศูนย์กลาง กลุ่มที่ถูกคำนวณใหม่ไม่เปลี่ยนแปลงตามไปด้วย ดังนั้น จึงหยุดกระบวนการ วนซ้ำเมื่อสิ้นสุดการทำงานในรอบที่ 3 นี้

ผลลัพธ์การจัดกลุ่มข้อมูลแสดงดังแผนภูมิการกระจายข้าว่างของ ภาพ 3.14 โดยข้อมูลถูกจัดเป็น 2 กลุ่ม โดยข้อมูลที่ถูกจัดอยู่ในกลุ่มนั้นแห่งเดียว สัญลักษณ์ ◆ และข้อมูลที่ถูกจัดอยู่ในอีกกลุ่มนั่น แทนด้วยสัญลักษณ์ +



ภาพ 3.14: ตัวอย่างการจัดกลุ่มแบบเคลื่อนของข้อมูลบนปริภูมิ 2 มิติ โดยแบ่งข้อมูลออก เป็น 2 กลุ่ม แทนจุดข้อมูลในแต่ละกลุ่มด้วย สัญลักษณ์ที่แตกต่างกัน คือ ◆ และ + และ จุดศูนย์กลางกลุ่มแห่งเดียวสัญลักษณ์ \*

### การจัดกลุ่มแบบลำดับชั้น

การจัดกลุ่มแบบลำดับชั้น (Hierarchical Clustering) เป็นการจัดกลุ่มโดยการสร้างลำดับการแบ่งหรือรวมข้อมูลช้อนๆ กัน ซึ่งสามารถแสดงของลำดับการแบ่งหรือรวมกลุ่มข้อมูลนั้นได้ด้วยแผนภูมิเดนดร็อแกรม (Dendrogram) ดังแสดงตัวอย่างในภาพ 3.15 โดยโหนดในระดับล่างสุดของต้นไม้หรือโหนดใบ (Leave Node) เป็นกลุ่มข้อมูลขนาดเล็กที่สุด ซึ่งบรรจุข้อมูลเพียงข้อมูลเดียว โหนดระหว่างโหนดใบและโหนดราก (Root Node) เป็นกลุ่มข้อมูลที่มีขนาดค่อนข้างใหญ่ๆ เติบโตขึ้น ซึ่งเกิดจากการรวมกลุ่มข้อมูลขนาดเล็กกว่า (ในโหนดรั้งต่ำล่าง) เข้าด้วยกัน จนกระทั่งที่โหนดรากเป็นกลุ่มข้อมูลที่มีขนาดใหญ่ที่สุดซึ่งรวมทุกๆ ข้อมูลเข้าไปในกลุ่มเดียว หรือในอีกนัยหนึ่งคือ กลุ่มข้อมูลในโหนด

ระดับบันค่อยๆ ถูกแบ่งให้มีขนาดเล็กลงเป็นโนนดในระดับล่าง จนกระทั้งกลุ่มข้อมูลเหลือเพียงข้อมูลเดียวเป็นสมาชิกซึ่งไม่สามารถถูกแบ่งได้อีก

การจัดกลุ่มแบบลำดับชั้น สามารถทำได้ 2 แนวทาง คือ 1) การแบ่งข้อมูลจากกลุ่มใหญ่ค่อยๆ แบ่งกลุ่มให้เล็กลงจนได้จำนวนกลุ่มที่ต้องการ เรียกว่า การแบ่งกลุ่มแบบลำดับชั้น (Divisive Hierarchical Clustering) และ 2) การรวมข้อมูลแต่ละข้อมูลเป็นกลุ่มข้อมูลขนาดเล็กที่สุด แล้วค่อยๆ รวมกลุ่มขนาดเล็กทีละคู่ให้มีขนาดใหญ่ขึ้น จนกระทั้งได้จำนวนกลุ่มตามที่ต้องการ เรียกว่า การรวมกลุ่มแบบลำดับชั้น (Agglomerative Hierarchical Clustering) ในที่นี้จะกล่าวถึงเฉพาะวิธีการรวมกลุ่มแบบลำดับชั้นเท่านั้น

### ตัวอย่าง 3.16

พิจารณาภาพ 3.15 ซึ่งแสดงตัวอย่างการจัดกลุ่มแบบลำดับชั้นของข้อมูล  $\{A, B, C, D, E\}$  แผนภาพเดนโตรแกรมดังกล่าวแสดงลำดับการจัดกลุ่มด้วยวิธีการรวมกลุ่มแบบลำดับชั้น ดังนี้

ลำดับ	กลุ่มข้อมูล
1	$\{A\}, \{B\}, \{C\}, \{D\}, \{E\}$
2	$\{A, B\}, \{C\}, \{D\}, \{E\}$
3	$\{A, B\}, \{C\}, \{D, E\}$
4	$\{A, B\}, \{C, D, E\}$
5	$\{A, B, C, D, E\}$

หากต้องการแบ่งข้อมูลออกเป็น 2 กลุ่ม กระบวนการทำงานจะหยุดเมื่อเสร็จสิ้นการทำงานในลำดับที่ 4 และจะได้กลุ่มข้อมูลผลลัพธ์ คือ  $\{A, B\}$  และ  $\{C, D, E\}$


เมื่อกำหนดจำนวนกลุ่มข้อมูลที่ต้องการ  $k$  วิธีการรวมกลุ่มแบบลำดับชั้น บนชุดข้อมูล  $D$  มีขั้นตอนดังนี้

ขั้นตอนที่ 1 สร้างเซตของกลุ่มข้อมูล  $C$  สำหรับแต่ละข้อมูล  $x_i$  ในชุดข้อมูล  $D$  จะได้  $C = \{C_1, C_2, \dots, C_n\}$  เมื่อ  $C_i = \{x_i\}$  สำหรับ  $i = 1, 2, \dots, n$  และ  $n$  คือ จำนวนข้อมูลในชุดข้อมูล  $D$

ขั้นตอนที่ 2 คำนวณเมทริกซ์ระยะทาง  $\Delta$  สำหรับชุดข้อมูล  $D$  โดยใช้สมการ

$$(3.24)$$

ขั้นตอนที่ 3 คำนวณหาค่าระยะทางระหว่างกลุ่มข้อมูล  $C_i$  และ  $C_j$  แทนด้วย สัญลักษณ์  $d_{C_i, C_j}$  สำหรับทุกๆ คู่ของกลุ่มข้อมูลในเซต  $C$  โดยอาศัยเมทริกซ์ระยะทาง  $\Delta$



ภาพ 3.15: ตัวอย่างแผนภาพเดนโตรแกรมแสดงการแบ่งกลุ่มแบบลำดับชั้นของข้อมูล  $A, B, C, D$  และ  $E$

ขั้นตอนที่ 4 หาค่าของกลุ่มข้อมูล  $C_i$  และ  $C_j$  ที่มีค่าระยะทางระหว่างกลุ่มข้อมูลน้อยที่สุด

ขั้นตอนที่ 5 สร้างกลุ่มข้อมูลใหม่  $C_{ij}$  โดยการรวมกลุ่มข้อมูล  $C_i$  และ  $C_j$  เข้าด้วยกัน

ขั้นตอนที่ 6 ทำการลบกลุ่มข้อมูล  $C_i$  และ  $C_j$  ออกจากเซต  $C$  และเพิ่มข้อมูลใหม่  $C_{ij}$  เข้าไปยังเซต  $C$


ขั้นตอนที่ 7 กลับไปเริ่มการดำเนินการตั้งแต่ขั้นตอนที่ 3 จนกระทั่งจำนวนสมาชิกในเซต  $C$  มีค่าเท่ากับ  $k$

จากขั้นตอนวิธีการแบ่งกลุ่มแบบลำดับชั้นในขั้นตอนที่ 3 เราจำเป็นต้องคำนวณค่าระยะทางระหว่างกลุ่มข้อมูล 2 กลุ่มข้อมูลใดๆ กำหนดให้  $C_i$  และ  $C_j$  เป็นกลุ่มข้อมูล 2 กลุ่ม ระยะทางระหว่างกลุ่มข้อมูลทั้งสอง แทนด้วยสัญลักษณ์  $\delta_{C_i, C_j}$  สามารถคำนวณได้ด้วยวิธีการ ดังนี้

**การเชื่อมต่อเดียว (Single-Linkage)** เป็นการใช้ค่าระยะทางที่น้อยที่สุดระหว่างข้อมูล 2 ข้อมูล โดย ข้อมูลหนึ่งเป็นสมาชิกของกลุ่มข้อมูล  $C_i$  และอีกข้อมูลหนึ่งเป็นสมาชิกของกลุ่มข้อมูล  $C_j$  เป็นค่าระยะทางระหว่างกลุ่มข้อมูล  $C_i$  และ  $C_j$  สามารถเขียนในรูปสมการคณิตศาสตร์ได้ดังนี้

$$\delta_{C_i, C_j} = \min\{\delta_{x_p, x_q} | x_p \in C_i, x_q \in C_j\} \quad (3.27)$$

จะสังเกตได้ว่ากลุ่มข้อมูลทั้งสอง เชื่อมต่อกันด้วยข้อมูล 2 ข้อมูลจากคนละกลุ่มที่อยู่ใกล้กันที่สุดเพียง 1 คู่ (1 การเชื่อมต่อ) เท่านั้น แสดงถึงวิธีการเชื่อมต่อเดียวระหว่างกลุ่มข้อมูล 2 กลุ่ม บนปริภูมิ 2 มิติ ดังภาพ 3.16 โดยเส้นทึบที่เชื่อมระหว่างข้อมูล 2 ข้อมูลจากกลุ่มข้อมูลต่างกัน เป็นระยะทางที่น้อยที่สุดระหว่างข้อมูลจากกลุ่มข้อมูลทั้งสอง




ภาพ 3.16: ตัวอย่างการเชื่อมต่อเดียวระหว่างกลุ่มข้อมูล 2 กลุ่มบนปริภูมิ 2 มิติ โดยจุดข้อมูลในแต่ละกลุ่มแทนด้วยสัญลักษณ์ที่แตกต่างกัน คือ ◆ และ + เส้นทึบที่เชื่อมระหว่างข้อมูล 2 ข้อมูลจากต่างกลุ่มข้อมูล เป็นระยะทางที่น้อยที่สุดระหว่างข้อมูลจากกลุ่มข้อมูลทั้งสอง ซึ่งเชื่อมต่อกลุ่มข้อมูลเข้าด้วยกัน

**การเชื่อมต่อสมบูรณ์ (Complete-Linkage)** เป็นการใช้ค่าระยะทางที่มากที่สุดระหว่างข้อมูล 2 ข้อมูล โดย ข้อมูลหนึ่งมาจากการกลุ่มข้อมูล  $C_i$  และอีกข้อมูลหนึ่งมาจากกลุ่มข้อมูล  $C_j$  เป็นค่าระยะทางระหว่างกลุ่มข้อมูล  $C_i$  และ  $C_j$  สามารถเขียนในรูปสมการคณิตศาสตร์ ได้ดังนี้

$$\delta_{C_i, C_j} = \max\{\delta_{x_p, x_q} | x_p \in C_i, x_q \in C_j\} \quad (3.28)$$

แม้ว่าการวัดระยะทางระหว่างกลุ่มข้อมูลวิธีนี้จะใช้ค่าระยะทางที่มากที่สุดระหว่างข้อมูล 2 ข้อมูลที่มาจากการกลุ่มข้อมูลเพียงค่าเดียว เมื่อคู่ของข้อมูลจากทั้ง 2 กลุ่มข้อมูลที่อยู่ห่างกันมากที่สุดสร้างการเชื่อมต่อกลุ่มข้อมูลทั้ง 2 กลุ่ม จึงทำให้คู่ข้อมูลอื่นๆ ที่เป็นไปได้ห่างหมวด ระหว่างกลุ่มข้อมูลทั้ง 2 กลุ่ม อยู่ภายใต้



ภาพ 3.17: ตัวอย่าง การ เชื่อม ต่อ สมบูรณ์ ระหว่างกลุ่มข้อมูล 2 กลุ่ม โดยจุดข้อมูลในแต่ละกลุ่มแทนด้วยสัญลักษณ์ที่แตกต่างกัน คือ ◆ และ + เส้นทึบที่เชื่อมระหว่างข้อมูล 2 ข้อมูลจากต่างกลุ่มกัน เป็นระยะทางที่มากที่สุดระหว่างข้อมูลจากกลุ่มข้อมูลทั้งสอง ซึ่งทำให้เกิดการเชื่อมต่อกันระหว่างกลุ่มข้อมูล 2 กลุ่มอย่างสมบูรณ์

ให้ระยะทางนี้ด้วย และทำให้กลุ่มข้อมูลทั้งสองเข้ามottกันอย่างสมบูรณ์ ภาพ 3.17 แสดงตัวอย่างการเข้มต่อสมบูรณ์ระหว่างกลุ่มข้อมูล 2 กลุ่ม บนปริภูมิ 2 มิติ เส้นทึบในภาพแสดงระยะทางที่มากที่สุดระหว่างข้อมูลจากกลุ่มข้อมูลทั้งสอง

**การเข้มต่อเฉลี่ย (Average-Linkage)** ค่าระยะทางระหว่างกลุ่มข้อมูล  $C_i$  และ  $C_j$  เป็นค่าเฉลี่ยของระยะทางระหว่างข้อมูลทุกคู่ที่เป็นไปได้ โดยข้อมูลหนึ่งเป็นสมาชิกของกลุ่มข้อมูล  $C_i$  และอีกข้อมูลหนึ่งเป็นสมาชิกของกลุ่มข้อมูล  $C_j$  สามารถเขียนในรูปสมการคณิตศาสตร์ ได้ดังนี้

$$\delta_{C_i, C_j} = \frac{\sum_{x_p \in C_i} \sum_{x_q \in C_j} \delta_{x_p, x_q}}{|C_i| \cdot |C_j|} \quad (3.29)$$

ภาพ 3.18 แสดงการเข้มโยงข้อมูลทุกๆ คู่ที่เป็นไปได้โดยข้อมูลแต่ละคู่มาจากการต่างกลุ่มข้อมูลกัน ระยะทางของคู่ข้อมูลแต่ละคู่นี้ถูกนำมาเฉลี่ยเพื่อใช้แทนค่าระยะทางระหว่างกลุ่มข้อมูลทั้ง 2 กลุ่ม

**ระยะทางระหว่างศูนย์กลางกลุ่ม (Centroid Distance)** เป็นการวัดระยะทางระหว่างกลุ่มข้อมูลโดยใช้จุดศูนย์กลางของกลุ่มข้อมูลเป็นตัวแทนของข้อมูลในกลุ่ม และวัดระยะทางระหว่างจุดศูนย์กลางของกลุ่มทั้งสอง กำหนดให้  $\mu_i$  และ  $\mu_j$  เป็นจุดศูนย์กลางของกลุ่ม  $C_i$  และ  $C_j$  ตามลำดับ ระยะทางระหว่างกลุ่มข้อมูล  $C_i$  และ  $C_j$  คือ


$$\delta_{C_i, C_j} = \delta_{\mu_i, \mu_j} \quad (3.30)$$

ภาพ 3.19 แสดงตัวอย่างระยะทางระหว่างศูนย์กลางกลุ่ม ของกลุ่มข้อมูล 2 กลุ่ม บนปริภูมิ 2 มิติ โดยจุดศูนย์กลางกลุ่มข้อมูลแต่ละกลุ่ม แทนด้วยสัญลักษณ์  $\star$


### ตัวอย่าง 3.17

พิจารณาเมทริกซ์ระยะทางของข้อมูล 5 ข้อมูล ต่อไปนี้

$$\Delta = \begin{bmatrix} x_1 & x_2 & x_3 & x_4 & x_5 \\ x_1 & 0 & 2.40 & 3.27 & 10.45 & 11.68 \\ x_2 & 2.40 & 0 & 0.93 & 8.21 & 9.33 \\ x_3 & 3.27 & 0.93 & 0 & 7.27 & 8.42 \\ x_4 & 10.45 & 8.21 & 7.27 & 0 & 1.86 \\ x_5 & 11.68 & 9.33 & 8.42 & 1.86 & 0 \end{bmatrix}$$



ภาพ 3.18: ตัวอย่างการเข้มต่อเฉลี่ยระหว่างกลุ่มข้อมูล 2 กลุ่ม โดยจุดข้อมูลในแต่ละกลุ่มแทนด้วยสัญลักษณ์ที่แตกต่างกัน คือ ◆ และ + เส้นทึบที่เชื่อมระหว่างข้อมูล 2 ข้อมูลทุกๆ คู่ที่เป็นไปได้ โดยข้อมูลแต่ละคู่มารวมจากต่างกลุ่มข้อมูลกัน ถูกใช้ในการคำนวณระยะทางของการเข้มต่อเฉลี่ย



ภาพ 3.19: ตัวอย่าง ระยะทางระหว่างศูนย์กลางกลุ่ม โดย จุด ข้อมูล ใน แต่ละ กลุ่ม แทนด้วยสัญลักษณ์ที่แตกต่างกัน คือ ◆ และ + และจุดศูนย์กลางกลุ่มแทนด้วยสัญลักษณ์ ★ เส้นทึบเชื่อมระหว่างจุดศูนย์กลางกลุ่มทั้งสอง ซึ่งใช้แทนระยะทางระหว่างกลุ่มข้อมูล

กำหนดกลุ่มข้อมูล  $C_1$  และ  $C_2$  โดย  $C_1 = \{x_1, x_2, x_3\}$  และ  $C_2 = \{x_4, x_5\}$  จะสามารถหาระยะทางระหว่างกลุ่มข้อมูลทั้ง 2 ด้วยวิธีต่างๆ ได้ดังนี้

วิธีการเชื่อมต่อเดียว พิจารณาหาค่าระยะทางที่น้อยที่สุดจากค่าระยะทางของคู่ข้อมูลที่เป็นไปได้ทั้งหมด โดยข้อมูลแต่ละคู่มาจากการต่างกลุ่มข้อมูลกัน ดังนี้

$$\begin{aligned}\delta_{C_i, C_j} &= \min\{\delta_{x_1, x_4}, \delta_{x_1, x_5}, \delta_{x_2, x_4}, \delta_{x_2, x_5}, \delta_{x_3, x_4}, \delta_{x_3, x_5}\} \\ &= \min\{10.45, 11.68, 8.21, 9.33, 7.27, 8.42\} \\ &= 7.27\end{aligned}$$

ดังนั้น ระยะทางระหว่างกลุ่มข้อมูล  $C_1$  และ  $C_2$  เมื่อวัดด้วยวิธีการเชื่อมต่อเดียว มีค่าเท่ากับ 7.27

วิธีการเชื่อมต่อสมบูรณ์ พิจารณาหาค่าระยะทางที่มากที่สุดจากค่าระยะทางของคู่ข้อมูลที่เป็นไปได้ทั้งหมด โดยข้อมูลแต่ละคู่มาจากการต่างกลุ่มข้อมูลกัน ดังนี้

$$\begin{aligned}\delta_{C_i, C_j} &= \max\{\delta_{x_1, x_4}, \delta_{x_1, x_5}, \delta_{x_2, x_4}, \delta_{x_2, x_5}, \delta_{x_3, x_4}, \delta_{x_3, x_5}\} \\ &= \max\{10.45, 11.68, 8.21, 9.33, 7.27, 8.42\} \\ &= 11.68\end{aligned}$$

ดังนั้น ระยะทางระหว่างกลุ่มข้อมูล  $C_1$  และ  $C_2$  เมื่อวัดด้วยวิธีการเชื่อมต่อสมบูรณ์ มีค่าเท่ากับ 11.68

วิธีการเชื่อมต่อเฉลี่ย หาค่าเฉลี่ยของค่าระยะทางของคู่ข้อมูลที่เป็นไปได้ทั้งหมด โดยข้อมูลแต่ละคู่มาจากการต่างกลุ่มข้อมูลกัน ดังนี้

$$\begin{aligned}\delta_{C_i, C_j} &= \frac{\delta_{x_1+x_4} + \delta_{x_1, x_5} + \delta_{x_2, x_4} + \delta_{x_2, x_5} + \delta_{x_3, x_4} + \delta_{x_3, x_5}}{6} \\ &= \frac{10.45 + 11.68 + 8.21 + 9.33 + 7.27 + 8.42}{6} \\ &= \frac{55.36}{6} = 9.26\end{aligned}$$

ดังนั้น ระยะทางระหว่างกลุ่มข้อมูล  $C_1$  และ  $C_2$  เมื่อวัดด้วยวิธีการเชื่อมต่อเฉลี่ย มีค่าเท่ากับ 9.26

ระยะทางระหว่างศูนย์กลาง กลุ่ม เมื่อคำนวณค่าศูนย์กลาง กลุ่มของกลุ่มข้อมูล  $C_1$  และ  $C_2$  ได้ ดังนี้

$$\mu_1 = (1.38, 3.83) \text{ และ } \mu_2 = (10.00, 7.05)$$

จะสามารถคำนวณระยะทางระหว่างศูนย์กลางกลุ่มทั้งสองด้วยระยะทางแบบยุคลิด ได้ดังนี้

$$\begin{aligned}\delta_{C_i, C_j} &= \sqrt{(1.38 - 10.00)^2 + (3.83 - 7.05)^2} \\ &= \sqrt{(-8.62)^2 + (-3.22)^2} \\ &= \sqrt{74.30 + 10.37} \\ &= \sqrt{84.67} = 9.20\end{aligned}$$

ดังนั้น ระยะทางระหว่างกลุ่มข้อมูล  $C_1$  และ  $C_2$  เมื่อใช้ระยะทางระหว่างศูนย์กลางกลุ่ม มีค่าเท่ากับ 9.20

### ตัวอย่าง 3.18

จากข้อมูล 5 ข้อมูลที่ประกอบด้วยตัวแปรเชิงตัวเลข 2 ตัวแปร ต่อไปนี้

$$\begin{aligned}\mathbf{x}_1 &= (0.80, 4.12) \quad \mathbf{x}_2 = (0.88, 4.17) \quad \mathbf{x}_3 = (2.49, 4.33) \\ \mathbf{x}_4 &= (8.79, 8.36) \text{ และ } \mathbf{x}_5 = (10.72, 7.62)\end{aligned}$$

สามารถจัดกลุ่มข้อมูลทั้ง 5 ข้อมูลออกเป็น 2 กลุ่ม ด้วยวิธีการรวมกลุ่มแบบลำดับชั้น ได้ดังนี้

เริ่มต้นด้วยการสร้างเซตของกลุ่มข้อมูล  $C = \{C_1, C_2, C_3, C_4, C_5\}$  สำหรับแต่ละข้อมูล ต่อมาทำการคำนวณเมตริกซ์ระยะทางระหว่างข้อมูล  $\Delta$  ได้ดังนี้

$$\Delta = \begin{bmatrix} \mathbf{x}_1 & \mathbf{x}_2 & \mathbf{x}_3 & \mathbf{x}_4 & \mathbf{x}_5 \\ \mathbf{x}_1 & 0 & 0.09 & 1.71 & 9.05 & 10.52 \\ \mathbf{x}_2 & 0.09 & 0 & 1.62 & 8.96 & 10.43 \\ \mathbf{x}_3 & 1.71 & 1.62 & 0 & 7.48 & 8.86 \\ \mathbf{x}_4 & 9.05 & 8.96 & 7.48 & 0 & 2.06 \\ \mathbf{x}_5 & 10.52 & 10.43 & 8.86 & 2.06 & 0 \end{bmatrix}$$

ตัวอย่างนี้ใช้วิธีการเชื่อมต่อสมบูรณ์ในการหาค่าระยะทางระหว่างกลุ่มข้อมูล ทำการหาค่าของกลุ่มข้อมูลที่มีระยะทางระหว่างกลุ่มข้อมูลน้อยที่สุด ได้ค่าของกลุ่มข้อมูล  $C_1$  และ  $C_2$  ซึ่งมีระยะทางระหว่างกลุ่มข้อมูลเท่ากับ 0.09 ทำการรวมกลุ่มข้อมูล  $C_1$  และ  $C_2$  เข้าด้วยกัน ได้กลุ่มข้อมูลใหม่  $C_{12} = \{\mathbf{x}_1, \mathbf{x}_2\}$  และปรับเซตของกลุ่มข้อมูล  $C$  ใหม่ ได้ดังนี้

$$C = \{C_{12}, C_3, C_4, C_5\}$$

ต่อมาทำการหาค่าของกลุ่มข้อมูลที่มีระยะทางระหว่างกลุ่มข้อมูลน้อยที่สุด ได้ค่าของกลุ่มข้อมูล  $C_{12}$  และ  $C_3$  ซึ่งมีระยะทางระหว่างกลุ่มข้อมูลเท่ากับ 1.71 จึงทำการรวมกลุ่มข้อมูล  $C_{12}$  และ  $C_3$  เข้าด้วยกัน ได้กลุ่มข้อมูลใหม่  $C_{123} = \{x_1, x_2, x_3\}$  และปรับเซตของกลุ่มข้อมูล  $C$  ใหม่ ได้ดังนี้

$$C = \{C_{123}, C_4, C_5\}$$

ต่อมาทำการหาค่าของกลุ่มข้อมูลที่มีระยะทางระหว่างกลุ่มข้อมูลน้อยที่สุด ได้ค่าของกลุ่มข้อมูล  $C_4$  และ  $C_5$  ซึ่งมีระยะทางระหว่างกลุ่มข้อมูลเท่ากับ 2.06 จึงทำการรวมกลุ่มข้อมูล  $C_4$  และ  $C_5$  เข้าด้วยกัน ได้กลุ่มข้อมูลใหม่  $C_{45} = \{x_4, x_5\}$  และปรับเซตของกลุ่มข้อมูล  $C$  ใหม่ ได้ดังนี้


$$C = \{C_{123}, C_{45}\}$$

จากผลลัพธ์พบว่าจำนวนกลุ่มข้อมูลที่ได้มีค่าเท่ากับจำนวนกลุ่มข้อมูลที่ต้องการ จึงหยุดกระบวนการรวมกลุ่มข้อมูล

ดังนั้น การจัดกลุ่มข้อมูล 5 ข้อมูลข้างต้น ออกเป็น 2 กลุ่ม ด้วยวิธีการรวมกลุ่มแบบลำดับชั้น ได้ผลลัพธ์ คือ


$$\{x_1, x_2, x_3\} \text{ และ } \{x_4, x_5\}$$

และสามารถแสดงลำดับการแบ่งกลุ่มข้อมูลแบบลำดับชั้นด้วยแผนภาพเดนโตรแกรม ได้ดังนี้



### การจัดกลุ่มบนฐานความหนาแน่น

การจัดกลุ่มบนฐานความหนาแน่น (Density-Based Clustering) เป็นการใช้ความหนาแน่นของข้อมูลในการพิจารณาจัดกลุ่มข้อมูล วิธีการจัดกลุ่มบน




ภาพ 3.21: นุ่มนองการจัดกลุ่มด้วยวิธีบีสแกน (a) แผนภูมิการกระจายของข้อมูลบนปริภูมิ 2 มิติ (b) แผนภูมิพื้นผิวแสดงความหนาแน่นของข้อมูล

ฐานความหนาแน่นโดยส่วนใหญ่ทำให้ได้กลุ่มข้อมูลผลลัพธ์ที่ไม่ถูกกำจัดด้วยสมมติฐานของรูปร่างของกลุ่มข้อมูล อีกทั้งยังสามารถจัดการกับข้อมูลผิดปกติ (Outlier) ได้อย่างมีประสิทธิภาพ วิธีการหนึ่งในการจัดกลุ่มข้อมูลบนฐานความหนาแน่นที่เป็นที่รู้จัก คือ วิธีบีสแกน (Density-Based Spatial Clustering of Applications with Noise: DBSCAN) โดยวิธีการนี้กำหนดนิยามความหนาแน่นของข้อมูล ดังนี้ กำหนดให้  $V_\varepsilon(x_i)$  เป็นเขตของจุดข้อมูลในชุดข้อมูล D ที่อยู่ภายในทรงกลม ขนาดรัศมี  $\varepsilon$  ซึ่งเป็นพารามิเตอร์ที่ต้องถูกกำหนดค่า โดยมีจุดข้อมูล  $x_i$  เป็นจุดศูนย์กลาง สามารถเขียนในรูปสัญลักษณ์คณิตศาสตร์ ได้ดังนี้

$$V_\varepsilon(x_i) = \{p \in D | \delta_{x_i, p} \leq \varepsilon\} \quad (3.31)$$

ค่าความหนาแน่น ณ ตำแหน่งของจุดข้อมูล  $x_i$  แทนด้วยสัญลักษณ์  $N_\varepsilon(x_i)$  คือ จำนวนข้อมูลที่อยู่ห่างจากข้อมูล  $x_i$  ไม่เกินรัศมี  $\varepsilon$  ทั้งนี้นับรวมข้อมูล  $x_i$  ด้วย นั่นคือ  $N_\varepsilon(x_i) = |V_\varepsilon(x_i)|$  แสดงตัวอย่างการคำนวณค่าความหนาแน่น ณ ตำแหน่งของจุดข้อมูล  $x_i$  ดังภาพ 3.20 ซึ่งภายในวงกลมขนาดรัศมี  $\varepsilon$  ที่มีจุด  $x_i$  เป็นจุดศูนย์กลาง มีจำนวนจุดข้อมูลทั้งหมด 5 จุด ดังนั้น ค่าความหนาแน่น ณ ตำแหน่งของจุดข้อมูล  $x_i$  จึงมีค่าเท่ากับ 5

เพื่อให้เข้าใจหลักการของวิธีบีสแกนในการจัดกลุ่มข้อมูล ลองจินตนาการ ว่าจุดข้อมูลถูกวางบนระนาบ 2 มิติที่สอดคล้องกับปริภูมิลักษณะเด่นของข้อมูล ต่อมาทำการยกข้อมูลขึ้นจากระนาบ โดยใช้ค่าความหนาแน่นของข้อมูล ณ ตำแหน่งของแต่ละข้อมูลแทนความสูง เราจะได้ภาพจากจินตนาการ ดังแสดง ตัวอย่างในภาพ 3.21(b) ซึ่งมีลักษณะคล้ายกับแผนที่ภูมิประเทศของเทือกเขา วิธีบีสแกนทำการจัดกลุ่มข้อมูลที่อยู่บนเทือกเขาเดียวกันเข้าไว้ด้วยกัน ส่วน ข้อมูลที่กระจายบนพื้นราบ (มีความหนาแน่นต่ำ) นั่น จะถูกจัดเป็นข้อมูลผิดปกติ




ภาพ 3.20: ตัวอย่างการหาค่าความหนาแน่นของข้อมูล ณ ตำแหน่งจุดข้อมูล  $x_i$  เมื่อกำหนดค่ารัศมีวงกลมขนาด  $\varepsilon$  ทำให้ความหนาแน่นของข้อมูล ณ ตำแหน่งจุดข้อมูล  $x_i$  มีค่าเท่ากับ 5

ในการจัดกลุ่มด้วยวิธีดีบีสแกน จุดข้อมูลแต่ละจุดจะถูกจำแนกออกเป็น 3 ประเภท คือ


- ▶ **จุดแกน (Core Point)** คือ ข้อมูลที่ความหนาแน่น ณ จุดข้อมูลนั้นมีค่ามากกว่าหรือเท่ากับ ค่า  $minPts$  นั่นคือ จุดข้อมูล  $x_i$  จะเป็นจุดแกน ก็ต่อเมื่อ  $N_\epsilon(x_i) \geq minPts$  เมื่อ  $minPts$  เป็นค่าขีด界ปั๊กความหนาแน่นเฉพาะถันที่จะต้องถูกกำหนดขึ้น ซึ่งถือว่าเป็นค่าพารามิเตอร์อีกค่าหนึ่งของวิธีดีบีสแกน
- ▶ **จุดขอบ (Border Point)** คือ ข้อมูลที่ความหนาแน่น ณ จุดข้อมูลนั้นมีค่าน้อยกว่า ค่า  $minPts$  และ เป็นจุดข้อมูลที่อยู่ภายใต้รัศมี  $\epsilon$  ของข้อมูลที่เป็นจุดแกน ข้อมูล  $x_i$  จะถูกจัดเป็นจุดขอบ ก็ต่อเมื่อ  $N_\epsilon(x_i) < minPts$  และ  $x_i \in V_\epsilon(x_j)$  เมื่อ  $x_j$  เป็นจุดแกนจุดหนึ่ง
- ▶ **จุดข้อมูลรบกวน (Noise Point)** หรือ ข้อมูลผิดปกติ คือ ข้อมูลที่ความหนาแน่น ณ จุดข้อมูลนั้นเป็นจุดศูนย์กลางมีค่าน้อยกว่า ค่า  $minPts$  และ ไม่เป็นจุดข้อมูลที่อยู่ภายใต้รัศมี  $\epsilon$  ของข้อมูลที่เป็นจุดแกน นั่นคือ ข้อมูล  $x_i$  จะถูกจัดเป็นจุดข้อมูลรบกวน ก็ต่อเมื่อ  $x_i$  ไม่เป็นจุดแกนและจุดขอบ

เราจะกล่าวว่า จุดข้อมูล  $x_i$  สามารถไปถึงได้ด้วยความหนาแน่นโดยตรง (Directly Density Reachable) จากจุดข้อมูล  $x_j$  ถ้าจุดข้อมูล  $x_i$  อยู่ในวงรัศมี  $\epsilon$  ของจุดข้อมูล  $x_j$  และ จุดข้อมูล  $x_j$  เป็นจุดแกน (แสดงภาพประกอบคำอธิบายดังภาพ 3.22) เสมือนว่าจากจุด  $x_j$  เราสามารถลิ้นไอล์ไปยังจุดข้อมูล  $x_i$  โดยตรงจากจุดข้อมูล  $x_j$  โดยอาศัยความลาดชัดของความหนาแน่นได้ และจุดข้อมูล  $x_i$  เป็นจุดข้อมูลในแนวกลุ่มข้อมูล (เทือกเขา) เดียวกับจุดข้อมูล  $x_j$  โดยอยู่ในระดับความหนาแน่น (ความสูงจากพื้นราบ) ที่ต่ำกว่า  $x_j$  นั่นเอง นอกจากนี้ เราจะกล่าวว่า จุดข้อมูล  $x_k$  สามารถไปถึงได้ด้วยความหนาแน่น (Density Reachable) จากจุดข้อมูล  $x_j$  ถ้ามีลูกโซ่ของจุดข้อมูล  $x_0, x_1, \dots, x_l$  ที่  $x_0 = x_k$  และ  $x_l = x_j$  และ  $x_p$  สามารถไปถึงได้ด้วยความหนาแน่นโดยตรงจาก จุดข้อมูล  $x_{p-1}$  สำหรับ  $p = 1, 2, \dots, l$  (แสดงภาพประกอบคำอธิบายดังภาพ 3.23) กล่าวคือ เราสามารถลิ้นไอล์จากจุดแกน  $x_j$  ไปยัง  $x_k$  โดยผ่านจุดแกน  $x_1, x_2, \dots, x_{l-1}$  ตามลำดับ


กำหนดให้ จุดข้อมูล  $x_i$  และ  $x_k$  ถูกเชื่อมโยงกันด้วยความหนาแน่น (Density Connected) ถ้ามีจุดแกน  $x_j$  ที่ทั้ง  $x_i$  และ  $x_k$  สามารถไปถึงได้ด้วยความหนาแน่นจากจุดข้อมูล  $x_j$  (ดูภาพ 3.24 ประกอบคำอธิบาย) กลุ่มข้อมูลบนฐานความหนาแน่น คือ เซตขนาดใหญ่ที่สุดของจุดข้อมูลที่แต่ละคู่ของจุดข้อมูลที่เป็นไปได้ทั้งหมดในเซตถูกเชื่อมโยงกันด้วยความหนาแน่น วิธีดีบีสแกน มีขั้นตอนดำเนินการหากลุ่มข้อมูลบนฐานความหนาแน่นในชุดข้อมูล  $D$  เมื่อกำหนดค่าพารามิเตอร์  $\epsilon$  และ  $minPts$  ดังนี้




ภาพ 3.22: จุดข้อมูล  $x_i$  สามารถไปถึงได้ด้วยความหนาแน่นโดยตรง (Directly Density Reachable) จากจุดข้อมูล  $x_j$  เมื่อกำหนดค่าพารามิเตอร์  $minPts = 5$



ภาพ 3.23: จุดข้อมูล  $x_k$  สามารถไปถึงได้ด้วยความหนาแน่น (Density Reachable) จากจุดข้อมูล  $x_j$  ผ่านจุดข้อมูล  $x_1$  และ  $x_2$  ตามลำดับเมื่อกำหนดค่าพารามิเตอร์  $minPts = 5$



ภาพ 3.24: จุดข้อมูล  $x_i$  และ  $x_k$  ถูกเชื่อมโยงกันด้วยความหนาแน่น (Density Connected) โดยมีจุดแกน  $x_j$  เป็นจุดเริ่มต้น เมื่อกำหนดค่าพารามิเตอร์  $minPts = 5$



ภาพ 3.25: ตัวอย่างการจัดกลุ่มด้วยวิธีดีบีสแกนสำหรับข้อมูล 12 ข้อมูล บนบริภูมิ 2 มิติ จุดกลุ่มของแข็ง แทน ข้อมูลที่เป็นจุดแกน (Core Point) จุดกลุ่มไม่มีขอบ แทน ข้อมูลที่เป็นจุดขอบ (Border Point) และจุดกลุ่มที่เป็นข้อมูลผิดปกติ (Outlier) เมื่อกำหนดค่าพารามิเตอร์  $minPts = 5$  จุดข้อมูลแต่ละจุดถูกล้อมด้วยวงกลมรัศมี  $\epsilon$

ขั้นตอนที่ 1 สำหรับทุกๆ ข้อมูล  $x_i$  ในข้อมูล  $D$  ทำการหาเขต  $V_\epsilon(x_i)$  ซึ่งเป็นเขตของจุดข้อมูลที่อยู่ภายในทรงกลมรัศมี  $\epsilon$  ที่มีจุด  $x_i$  เป็นจุดศูนย์กลาง

ขั้นตอนที่ 2 คำนวณหาค่าความหนาแน่น ณ ตำแหน่งของจุดข้อมูล  $x_i$  ทุกๆ ข้อมูล โดยค่าความหนาแน่น  $N_\epsilon(x_i) = |V_\epsilon(x_i)|$

ขั้นตอนที่ 3 หาเขตของจุดแกน  $Core$  โดย  $Core = \{x_i | N_\epsilon(x_i) \geq minPts\}$

ขั้นตอนที่ 4 กำหนดให้  $k$  มีค่าเท่ากับ 0 สำหรับใช้นับจำนวนกลุ่มข้อมูล

ขั้นตอนที่ 5 กำหนดให้  $C$  เป็นเขตว่าง สำหรับบรรจุกลุ่มข้อมูล

ขั้นตอนที่ 6 กำหนดให้  $L$  เป็นเขตของข้อมูลทั้งหมดในชุดข้อมูล  $D$

ขั้นตอนที่ 7 วนทำข้อขั้นตอนต่อไปนี้ จนกระทั่ง เขต  $Core$  เป็นเขตว่าง

- 7.1 นำสมาชิก  $x_i$  จากเขต  $Core$  มาพิจารณา
- 7.2 เพิ่มค่า  $k$  ขึ้น 1
- 7.3 สร้างเขต  $C_k$  โดย  $C_k = \{x_i\}$
- 7.4 หากจุดข้อมูลทุกจุดข้อมูลในเขต  $L$  ที่สามารถไปถึงได้ด้วยความหนาแน่นจากจุดข้อมูล  $x_i$  แล้วนำไปเพิ่มเป็นสมาชิกในเขต  $C_k$
- 7.5 ลบข้อมูลที่เป็นสมาชิกในเขต  $C_k$  ออกจากเขต  $L$  และเขต  $Core$
- 7.6 นำเขต  $C_k$  เพิ่มเป็นสมาชิกของเขต  $C$

ขั้นตอนที่ 8 สร้างเขต  $C_{noise} = L$

ขั้นตอนที่ 9 นำเขต  $C_{noise}$  เพิ่มเป็นสมาชิกของเขต  $C$

ขั้นตอนที่ 10 ผลลัพธ์ที่ได้ คือ เขต  $C = \{C_1, C_2, \dots, C_k, C_{noise}\}$  ซึ่งเป็นเขตของกลุ่มข้อมูล  $k$  กลุ่มและกลุ่มข้อมูลที่ถูกจัดให้เป็นข้อมูลผิดปกติ

### ตัวอย่าง 3.19

พิจารณาข้อมูลที่ประกอบด้วยตัวแปรเชิงตัวเลข 2 ตัวแปร จำนวน 12 ข้อมูล คือ A B C D E F G H I J K และ L และแสดงแผนภาพการกระจายข้อมูล ดังภาพ 3.25 และกำหนดค่าพารามิเตอร์  $\epsilon$  เท่ากับรัศมีวงกลมที่ล้อมรอบจุดข้อมูลในภาพ และค่าพารามิเตอร์  $minPts$  เท่ากับ 5

สร้างเซต  $L$  ที่มีสมาชิกเป็นข้อมูลทั้งหมด นั่นคือ  $L = \{A, B, C, D, E, F, G, H, I, J, K, L\}$  จากแผนภาพการกระจาย พบร่วมกันของ A G H และ K เป็นจุดแกน ดังนั้น เซต  $Core = \{A, G, H, K\}$

ในขณะที่จำนวนกลุ่ม  $k = 1$  พิจารณาจุดแกน A สร้างเซต  $C_1 = \{A\}$  และหาจุดข้อมูลที่สามารถไปถึงได้ด้วยความหนาแน่นจากจุด A ได้จุด B C D และ E นำจุดข้อมูลเหล่านี้บรรจุเป็นสมาชิกในเซต  $C_1$  จะได้  $C_1 = \{A, B, C, D, E\}$  จากนั้นทำการลบสมาชิกของเซต  $L$  และ  $Core$  ที่เป็นสมาชิก ในเซต  $C_1$  จะได้  $L = \{F, G, H, I, J, K, L\}$  และ  $Core = \{G, H, K\}$  ต่อมา นำเซต  $C_1$  เพิ่มเข้าเป็นสมาชิกของเซต  $C$  จะได้  $C = \{C_1\}$

ในขณะที่จำนวนกลุ่ม  $k = 2$  พิจารณาจุดแกน G สร้างเซต  $C_2 = \{G\}$  และหาจุดข้อมูลที่สามารถไปถึงได้ด้วยความหนาแน่นจากจุด G ได้จุด J K I L และ H นำจุดเข้ามูลเหล่านี้เข้าเป็นสมาชิกในเซต  $C_2$  จะได้  $C_2 = \{G, J, K, I, L, H\}$  จากนั้นลบสมาชิกของเซต  $L$  และ  $Core$  ที่เป็นสมาชิกในเซต  $C_2$  จะได้  $L = \{F\}$  และ  $Core = \{\}$  ต่อมา นำเซต  $C_2$  เพิ่มเข้าเป็นสมาชิกของ เซต  $C$  จะได้  $C = \{C_1, C_2\}$

เมื่อพบร่วมกันของ  $Core$  เป็นเซตว่าง จึงทำการสร้างเซต  $C_{noise}$  โดย  $C_{noise} = L = \{F\}$  และนำเซต  $C_{noise}$  เพิ่มเข้าเป็นสมาชิกของเซต  $C$  จะได้  $C = \{C_1, C_2, C_{noise}\}$

จากการจัดกลุ่มข้อมูลทั้ง 12 ข้อมูลด้วยวิธีดีบีสแกน ได้กลุ่มข้อมูล ผลลัพธ์ 2 กลุ่ม คือ  $C_1 = \{A, B, C, D, E\}$  และ  $C_2 = \{G, J, K, I, L, H\}$  ส่วน ข้อมูล F จัดเป็นข้อมูลผิดปกติ

## 3.3 การวิเคราะห์ความสัมพันธ์

การวิเคราะห์ความสัมพันธ์ (Association Analysis) เป็นการหาความสัมพันธ์ในรูปแบบการเกิดขึ้นร่วมกันหรือกฎความสัมพันธ์ของค่าตัวแปรตั้งแต่ 2 ตัวแปร ขึ้นไป มักถูกนำมาใช้ในการวิเคราะห์ข้อมูลรายการเปลี่ยนแปลง (Transaction Data) เช่น ข้อมูลรายการขายสินค้าของร้านค้า ข้อมูลรายการใช้จ่ายผ่านบัตรเครดิต และ ข้อมูลรายการซื้อสินค้าผ่านร้านค้าออนไลน์ เป็นต้น ในที่นี้เรา

จะศึกษาวิธีการวิเคราะห์ความสัมพันธ์ผ่านต้นแบบงานประยุกต์การวิเคราะห์ตระกร้าตลาด (Market Basket Analysis) ซึ่งเป็นการวิเคราะห์ความสัมพันธ์ของสินค้าในตระกร้าสินค้า จากข้อมูลรายการซื้อของลูกค้าทั้งหมด โดยมีเป้าหมาย 2 ข้อ คือ

- ▶ ค้นหาชุดของสินค้า เรียกว่า ไอเท็มเซต (Itemset) ที่ถูกซื้อร่วมกัน เช่น การซื้อนมกับขนมปังพร้อมกันในรายการซื้อสินค้าเดียวกัน
- ▶ ค้นหากฎความสัมพันธ์ (Association Rule) ระหว่างสินค้าในรายการซื้อของลูกค้า เช่น ถ้ามีการซื้อตันไม้ประเภทไม้ดอกแล้ว จะมีการปุยสำหรับบำรุงดอกด้วย

การวิเคราะห์ตระกร้าตลาดนี้ สามารถนำไปใช้ประโยชน์ได้อย่างมาก โดยเฉพาะการศึกษาพฤติกรรมของลูกค้า อันจะนำไปสู่การวางแผนส่งเสริมการขาย การจัดพื้นที่ร้านค้า และการจัดวางสินค้า เป็นต้น

## ไอเท็มเซต

ให้  $\mathcal{I} = \{X_1, X_2, \dots, X_d\}$  เป็นชุดของสิ่งสนใจทั้งหมด เซตย่อย (Subset) หนึ่งๆ ของเซต  $\mathcal{I}$  ยกเว้นเซตว่าง จะถูกเรียกว่า ไอเท็มเซต ในกรณีการวิเคราะห์ตระกร้าตลาด เซต  $\mathcal{I}$  คือ สินค้าทั้งหมดที่ลูกค้าสามารถหยิบใส่ตระกร้าสินค้าได้ และไอเท็มเซต คือ ชุดของสินค้าในตระกร้าสินค้าหนึ่งๆ ตัวอย่าง เช่น ร้านผลไม้แห่งหนึ่ง มีผลไม้ขายภายในร้าน 5 ชนิด คือ ส้ม แอปเปิล แตงโม มะละกอ และกล้วย ดังนั้น เซต  $\mathcal{I} = \{\text{ส้ม}, \text{แอปเปิล}, \text{แตงโม}, \text{มะละกอ}, \text{กล้วย}\}$  ซึ่งเป็นสินค้าที่ลูกค้าสามารถหยิบใส่ตระกร้าสินค้าได้ ลูกค้าคนแรกเลือกหยิบ ส้มและแอปเปิล และลูกค้าอีกคนหนึ่งเลือกหยิบ แตงโม มะละกอ และส้ม ทั้งเซต  $\{\text{ส้ม}, \text{แอปเปิล}\}$  และ  $\{\text{แตงโม}, \text{มะละกอ}, \text{ส้ม}\}$  ต่างก็เป็นไอเท็มเซตที่เกิดขึ้นภายในร้านผลไม้นี้ เมื่อเซต  $\mathcal{I}$  มีจำนวนสมาชิกเท่ากับ  $m$  ตัว จะได้ว่าไอเท็มเซตที่เป็นไปได้ทั้งหมดมีจำนวน  $2^m - 1$  ไอเท็มเซต นั่นคือ เซตย่อยทั้งหมดของเซต  $\mathcal{I}$  ไม่รวมเซตว่าง

### ตัวอย่าง 3.20

ร้านขายอาหารเชาริมทางร้านหนึ่ง มีสินค้าขายทั้งหมด 4 ชนิด คือ กล้วย นม แอปเปิล และขนมปัง ดังนั้น ไอเท็มเซตของสินค้าที่ลูกค้าสามารถซื้อพร้อมกันได้สำหรับร้านค้าแห่งนี้ มีทั้งหมด  $2^4 - 1 = 15$  ไอเท็มเซต ที่เป็นไปได้ ดังนี้

{กล้วย}	{นม}	{แอปเปิล}	{ขนมปัง}
{กล้วย, นม}	{กล้วย, แอปเปิล}	{กล้วย, ขนมปัง}	{นม, แอปเปิล}
{นม, ขนมปัง}	{แอปเปิล, ขนมปัง}		
{กล้วย, นม, แอปเปิล}	{กล้วย, นม, ขนมปัง}		

{กล้วย, แอปเปิล, นมปัง} {นม, แอปเปิล, นมปัง}

และ {กล้วย, นม, แอปเปิล, นมปัง}

กำหนดให้ชุดข้อมูล D จัดเก็บข้อมูลรายการเปลี่ยนแปลงในรูปแบบฐานข้อมูลทวิภาค (Binary Database) ที่ประกอบด้วยคอลัมน์จำนวน  $d$  คอลัมน์ แต่ละคอลัมน์แทนสินค้าหนึ่งๆ และแถวข้อมูลจำนวน  $n$  แถว โดยแต่ละแถวแทนรายการซื้อ/ขาย รายการที่  $i$  ประกอบด้วยสินค้า  $X_j$  ก็ต่อเมื่อ ฐานข้อมูลทวิภาคแถวที่  $i$  คอลัมน์ที่  $j$  มีค่าเป็น 1 ตาราง 3.1 แสดงตัวอย่างข้อมูลรายการเปลี่ยนแปลงในรูปแบบฐานข้อมูลทวิภาค ที่ประกอบด้วยสินค้าทั้งหมด 4 สินค้า และรายการซื้อ 10 รายการ รายการ 5 แสดงการซื้อสินค้า 3 สินค้า คือ นม แอปเปิล และ นมปัง ในหัวข้อนี้เราจะใช้การแทนข้อมูลรายการเปลี่ยนแปลงในรูปแบบฐานข้อมูลทวิภาคในการอธิบายรายละเอียดของการวิเคราะห์ต่อไปนี้

ตาราง

	Banana	Milk	Apple	Bread
$t_1$	0	1	1	0
$t_2$	1	1	0	0
$t_3$	0	1	0	1
$t_4$	1	0	1	0
$t_5$	0	1	1	1
$t_6$	1	1	0	1
$t_7$	0	1	1	1
$t_8$	0	0	1	0
$t_9$	0	1	0	1
$t_{10}$	1	0	1	1

ค่าสนับสนุน (Support) ของไอเท็มเซตหนึ่งๆ เป็นค่าสัดส่วนของจำนวนรายการในชุดข้อมูลที่ไอเท็มเซตเป็นส่วนหนึ่งของสมาชิก ต่อจำนวนรายการทั้งหมด ค่าสนับสนุนของไอเท็มเซต  $I = \{X_p, \dots, X_q\}$  ในชุดข้อมูล D แทนด้วยสัญลักษณ์  $sup(I, D)$  สามารถคำนวณได้ด้วยสมการต่อไปนี้

$$sup(I, D) = \frac{|\{t | t \in D \text{ and } I \subseteq t\}|}{n} \quad (3.32)$$

เมื่อ  $n$  คือ จำนวนรายการในชุดข้อมูล D

เราจะกล่าวว่า ไอเท็มเซต  $I$  เป็นไอเท็มเซตถี่ (Frequent Itemset) ในชุดข้อมูล D ถ้า  $sup(I, D) \geq minsup$  เมื่อ  $minsup$  คือ ค่าขีดแบ่งค่าสนับสนุนต่ำสุดซึ่งจะต้องถูกกำหนดขึ้น

### ตัวอย่าง 3.21

จากชุดข้อมูลรายการซื้อสินค้าในตาราง 3.1 เราสามารถหาค่าสนับสนุนของแต่ละไอเท็มเซตที่เป็นไปได้ได้ดังนี้

ตาราง 3.1: ข้อมูลรายการซื้อสินค้าจากร้านขายอาหารเจ้า ริมทาง แห่งหนึ่ง ซึ่งมีสินค้า วางขาย 4 ชนิด คือ กล้วย (Banana) นม (Milk) แอปเปิล (Apple) และนมปัง (Bread) จำนวน 10 รายการซื้อ เมื่อค่า 1 แทนสถานะการมีสินค้าชนิดนั้นในรายการซื้อ และค่า 0 แทนสถานะการไม่มีสินค้าชนิดนั้นในรายการซื้อ

ค่าสนับสนุน	ไอเท็มเซต
0.7	{nm}
0.6	{แอปเปิล} และ {นมปั่ง}
0.5	{nm, นมปั่ง}
0.4	{กล้วย}
0.3	{nm, แอปเปิล} และ {แอปเปิล, นมปั่ง}
0.2	{กล้วย, นม} และ {กล้วย, แอปเปิล} และ {กล้วย, นมปั่ง} และ {nm, แอปเปิล, นมปั่ง}
0.1	{กล้วย, นม, นมปั่ง} และ {กล้วย, แอปเปิล, นมปั่ง}

เมื่อกำหนดค่า  $minsup = 0.5$  จะได้ว่าไอเท็มเซตต่อไปนี้เป็นไอเท็มเซตที่

{nm} {แอปเปิล} {นมปั่ง} และ {nm, นมปั่ง}

เนื่องจากมีค่าสนับสนุนมากกว่าหรือเท่ากับค่าขีดแบ่งค่าสนับสนุนต่ำสุดที่กำหนด

การค้นหาไอเท็มเซตที่ในชุดข้อมูล D ที่มีเซตของสินค้าที่สนใจ  $\mathcal{I} = \{X_1, X_2, \dots, X_d\}$  และกำหนดค่าขีดแบ่งค่าสนับสนุนต่ำสุด  $minsup$  สามารถดำเนินการได้อย่างอัตโนมัติ โดยการใช้ขั้นตอนวิธีเอปิโพรอรี (Apriori Algorithm) ซึ่งมีขั้นตอนดังนี้

ขั้นตอนที่ 1 สร้างชุดของไอเท็มเซต  $C_1$  ที่มีสมาชิกเพียง 1 สินค้า โดย  $C_1 = \{\{X_1\}, \{X_2\}, \dots, \{X_d\}\}$

ขั้นตอนที่ 2 คำนวณค่าสนับสนุนของแต่ละไอเท็มเซตในเซต  $C_1$  บนชุดข้อมูล D

ขั้นตอนที่ 3 สร้างเซต  $L_1$  โดยคัดเลือกไอเท็มเซตในเซต  $C_1$  ที่มีค่าสนับสนุน

มากกว่าหรือเท่ากับ  $minsup$  จะได้  $L_1 = \{I | I \in C_1 \text{ and } sup(I, D) \geq minsup\}$

ขั้นตอนที่ 4 กำหนดค่า  $k = 2$

ขั้นตอนที่ 5 ทำขั้นตอนต่อไปนี้ จนกว่าทั้งเซต  $L_{k-1}$  เป็นเซตว่าง

5.1 สร้างชุดของไอเท็มเซต  $C_k$  โดยการเชื่อม (Join) เซต  $L_{k-1}$  และ  $L_{k-1}$  เข้าด้วยกัน โดยสมาชิกในเซต  $L_{k-1}$  จะนำมาเชื่อมกันได้ ถ้ามีสินค้าร่วมกันจำนวน  $k - 2$  สินค้า

5.2 คำนวณค่าสนับสนุนของแต่ละไอเท็มเซตในเซต  $C_k$  บนชุดข้อมูล D

5.3 สร้างเซต  $L_k$  โดยคัดเลือกไอเท็มเซตในเซต  $C_k$  ที่มีค่าสนับสนุนมากกว่าหรือเท่ากับ  $minsup$  จะได้  $L_k = \{I | I \in C_k \text{ and } sup(I, D) \geq minsup\}$

5.4 เพิ่มค่า  $k$  ขึ้น 1

ขั้นตอนที่ 6 รวมเซต  $L_i$  สำหรับ  $i = 1, 2, \dots, k - 2$  เป็นเซตของไออีเมชेटถี่

จากขั้นตอนวิธีไอเพรออริ เราจะเห็นว่าเป็นสร้างและค้นหาไออีเมชेटถี่โดยเริ่มสร้างไออีเมชेटที่มีประกอบด้วยสินค้า 1 สินค้า ในขั้นตอนที่ 1 แล้วค่อยๆ สร้างไออีเมชेटที่มีขนาดเพิ่มขึ้นเรื่อยๆ โดยอาศัยไออีเมชेटที่มีจำนวนสินค้าน้อยกว่า 1 สินค้า ในขั้นตอนที่ 5 (กรณีค่า  $k \geq 2$ ) เป็นการสร้างไออีเมชेटที่ประกอบด้วยสินค้ามากกว่าหรือเท่ากับ 2 สินค้า (ในขั้นตอนที่ 5.1) โดยอาศัยไออีเมชेटถี่ที่ประกอบด้วยจำนวนสินค้าน้อยกว่า 1 สินค้า โดยการจับคู่ไออีเมชेटเหล่านั้นที่มีสินค้าเหมือนกัน  $k - 2$  สินค้า เพื่อให้ได้ไออีเมชेटที่มีสินค้า  $k$  ชิ้น ตัวอย่างเช่น การสร้างไออีเมชेटที่ประกอบด้วยสินค้า 5 ชิ้น จากไออีเมชेटที่ประกอบด้วยสินค้า 4 ชิ้นที่มีสมาชิกเหมือนกัน 3 สินค้า เนื่องจากสมาชิกในเซตจะต้องมีค่าไม่เหมือนกัน การรวมเซต 2 เซต สมาชิกเหมือนกันจะถูกนำเข้าเซตเพียงแค่ 1 ครั้ง เช่น การรวมเซต  $\{A, B, C, D\}$  และ  $\{A, B, C, E\}$  จะได้เซตผลลัพธ์  $\{A, B, C, D, E\}$  ดังนั้น การรวมไออีเมชेटที่ประกอบด้วยสินค้า 4 ชิ้นที่มีสมาชิกเหมือนกัน 3 สินค้า ได้ผลลัพธ์ไออีเมชेटที่ประกอบด้วยสินค้า 5 สินค้า นอกจากนี้เมื่อพิจารณาขั้นตอนที่ 3 และ 5.3 แล้ว จะพบว่ามีการตัดไออีเมชेटที่มีค่าสนับสนุนน้อยกว่าค่า  $minsup$  ซึ่งเป็นการคัดกรองไออีเมชेटถี่ โดยผลลัพธ์จะถูกนำไปสร้างไออีเมชेटใหม่ที่ประกอบด้วยสินค้าเพิ่มขึ้น 1 สินค้า (ในขั้นตอนที่ 5.1) การพิจารณาเฉพาะไออีเมชेटถี่ทำให้เวลาในการดำเนินการลดลงเนื่องจากไออีเมชेटที่ไม่ได้เกิดขึ้นบ่อยครั้งจะไม่สามารถสร้างไออีเมชेटถี่ใหม่ที่ประกอบด้วยสินค้าเพิ่มขึ้น 1 สินค้าได้

### ตัวอย่าง 3.22

จากชุดข้อมูลรายการซื้อสินค้าในตาราง 3.1 สามารถค้นหาไออีเมชेटถี่โดยใช้ขั้นตอนวิธีไอเพรออริในการ เมื่อกำหนดค่า  $minsup = 0.5$  ได้ดังนี้

สร้างชุดไออีเมชेटที่ประกอบด้วยสินค้า 1 สินค้า และคำนวนค่าสนับสนุนของแต่ละไออีเมชेट จะได้

$C_1$	ค่าสนับสนุน
{กล้วย}	0.4
{นม}	0.7
{แอปเปิล}	0.6
{ขนมปัง}	0.6

ต่อมาสร้างเซต  $L_1$  บรรจุไออีเมชेटใน  $C_1$  ที่มีค่าสนับสนุนมากกว่าหรือเท่ากับค่า  $minsup$  จะได้

$$L_1 = \{\{\text{นม}\}, \{\text{แอปเปิล}\}, \{\text{ข้าวมันปั่ง}\}\}$$

ในขณะที่ค่า  $k = 2$  ทำการสร้างชุดของไอเท็มเซต  $C_2$  จากการเขื่อมเซต  $L_1$  โดยที่ไอเท็มเซตที่สามารถเขื่อมกันได้ จะต้องมีสมาชิกร่วมกัน  $k - 2 = 2 - 2 = 0$  สมาชิก พร้อมทั้งหาค่าสนับสนุนของไอเท็มเซตผลลัพธ์ จะได้

$C_2$	ค่าสนับสนุน
{กล้วย, นม}	0.2
{กล้วย, แอปเปิล}	0.2
{กล้วย, ข้าวมันปั่ง}	0.2
{นม, แอปเปิล}	0.3
{นม, ข้าวมันปั่ง}	0.5
{แอปเปิล, ข้าวมันปั่ง}	0.3

ต่อมาสร้างเซต  $L_2$  บรรจุไอเท็มเซตใน  $C_2$  ที่มีค่าสนับสนุนมากกว่าหรือเท่ากับค่า  $minsup$  จะได้

$$L_2 = \{\{\text{นม}, \text{ข้าวมันปั่ง}\}\}$$

ในขณะที่ค่า  $k = 3$  ทำการสร้างชุดของไอเท็มเซต  $C_3$  จากการเขื่อมเซต  $L_2$  และ  $L_2$  โดยที่ไอเท็มเซตที่สามารถเขื่อมกันได้ จะต้องมีสมาชิกร่วมกัน  $k - 2 = 3 - 2 = 1$  สมาชิก พร้อมทั้งหาค่าสนับสนุนของไอเท็มเซตผลลัพธ์ พบว่าไม่สามารถนำไอเท็มเซตใดใน  $L_2$  มาสร้างเป็นไอเท็มเซตใหม่ได้ จึงทำให้เซต  $C_3$  เป็นเซตว่าง และทำให้เซต  $L_3$  เป็นเซตว่างตามไปด้วย

ในขณะที่ค่า  $k = 4$  เมื่อเซต  $L_3$  เป็นเซตว่าง จึงหยุดกระบวนการค้นหา ไอเท็มเซตถี่

ดังนั้น ไอเท็มเซตถี่ที่ได้จากการกระบวนการค้นหาด้วยวิธีไอเพรออวี คือ สมาชิกของ  $L_1$  บ  $L_2$  นั่นคือ

$$\{\text{นม}\} \quad \{\text{แอปเปิล}\} \quad \{\text{ข้าวมันปั่ง}\} \quad \text{และ } \{\text{นม}, \text{ข้าวมันปั่ง}\}$$

## กฎความสัมพันธ์

กฎ ความสัมพันธ์ เป็นการ อธิบาย ความสัมพันธ์ ระหว่าง ไอ เท็ม เซต 2 เซต ในลักษณะ การเกิดขึ้นร่วม กันอย่าง มีเงื่อนไข โดย อธิบาย ในรูปแบบ กฎถ้า-แล้ว (If-then Rule) ตัวอย่าง เช่น ถ้าถูกค้ำซึ่องมและแอปเปิลร่วม กันแล้ว เขา มีแนว

โน้มจะซื้อกลับด้วย กำหนดให้  $I$  และ  $J$  เป็นไอเท็มเซต โดยที่  $I$  และ  $J$  ไม่มีสมาชิกร่วมกัน และ  $I, J \subseteq \mathcal{I}$  กฎความสัมพันธ์  $I \Rightarrow J$  แสดงความสัมพันธ์ระหว่างไอเท็มเซต  $I$  และ  $J$  ว่า ถ้าลูกค้าซื้อสินค้าในไอเท็มเซต  $I$  ร่วมกันแล้ว เขาไม่แน่ใจจะซื้อสินค้าทั้งหมดในไอเท็มเซต  $J$  ด้วย เราจะเรียก  $I$  ว่า ส่วนข้ามมือ (Left-Hand-Side: LHS) และเรียก  $J$  ว่า ส่วนขวามือ (Right-Hand Side: RHS) และพึงทราบประการหนึ่งว่า กฎความสัมพันธ์  $I \Rightarrow J$  ไม่เท่ากับ กฎความสัมพันธ์  $J \Rightarrow I$  เนื่องจากการดำเนินการ ถ้า-แล้ว ไม่มีคุณสมบัติการสลับที่ (Commutative Property) ตัวอย่างเช่น จากกฎความสัมพันธ์ที่ว่า ถ้า ลูกค้าซื้อนมและแอปเปิลร่วมกันแล้ว เขาไม่แน่ใจจะซื้อกลับด้วย เราจะสามารถเขียนในรูปสัญลักษณ์ได้ ดังนี้ {นม, แอปเปิล}  $\Rightarrow$  {กล้วย} โดยที่ ไอเท็มเซต {นม, แอปเปิล} เป็นส่วนข้ามมือของกฎ และไอเท็มเซต {กล้วย} เป็นส่วนข้ามมือของกฎ

ค่าสนับสนุน ของกฎความสัมพันธ์ คือ ค่าสัดส่วนของจำนวนรายการในชุดข้อมูลที่ไอเท็มเซต  $I \cup J$  เป็นส่วนหนึ่งของสมาชิก ต่อจำนวนรายการทั้งหมด กล่าวอีกนัยหนึ่งคือค่าสนับสนุนของไอเท็มเซต  $I \cup J$  นั่นเอง สามารถเขียนในรูปสมการคณิตศาสตร์ ได้ดังนี้

$$\text{sup}(I \Rightarrow J) = \text{sup}(I \cup J) \quad (3.33)$$

เมื่อ  $\text{sup}(I \Rightarrow J)$  คือ ค่าสนับสนุนของกฎความสัมพันธ์  $I \Rightarrow J$

ค่าความเชื่อมั่น (Confidence) เป็นค่าที่แสดงว่ากฎความสัมพันธ์หนึ่งๆ เป็นจริงบ่อยครั้งเพียงใดในชุดข้อมูล D สามารถคำนวณได้ ดังนี้

$$\text{conf}(I \Rightarrow J) = \frac{\text{sup}(I \cup J)}{\text{sup}(I)} \quad (3.34)$$

เมื่อ  $\text{conf}(I \Rightarrow J)$  คือ ค่าความเชื่อมั่นของกฎความสัมพันธ์  $I \Rightarrow J$

เราจะกล่าวว่า กฎความสัมพันธ์  $I \Rightarrow J$  เป็นกฎที่เกิดขึ้นบ่อยครั้งในชุดข้อมูล D ถ้า  $\text{sup}(I \Rightarrow J) \geq \text{minsup}$  และจะกล่าวว่า เป็นกฎที่น่าเชื่อถือในชุดข้อมูล D ถ้า  $\text{conf}(I \Rightarrow J) \geq \text{minconf}$  เมื่อ  $\text{minsup}$  และ  $\text{minconf}$  คือ ค่าขีด界ของค่าสนับสนุนต่ำสุด และค่าขีด界ของค่าความเชื่อมั่นต่ำสุด ที่จะต้องถูกกำหนดขึ้น

ค่าลิฟท์ (Lift) เป็นค่าอัตราส่วนระหว่างค่าสนับสนุนของกฎความสัมพันธ์ และค่าสนับสนุนคาดหวัง ซึ่งแสดงถึงผลกระทบที่เกิดจากกฎความสัมพันธ์ สามารถคำนวณได้จากสูตรต่อไปนี้

$$\text{lift}(I \Rightarrow J) = \frac{\text{sup}(I \cup J)}{\text{sup}(I) \times \text{sup}(J)} \quad (3.35)$$

ค่าลิฟท์ของกฎความสัมพันธ์  $I \Rightarrow J$  เขียนแทนด้วยสัญลักษณ์  $lift(I \Rightarrow J)$  มีค่าอยู่ระหว่าง 0 และ ค่าอนันต์ ถ้าค่าลิฟท์มีค่าเท่ากับ 1 บ่งบอกว่า ความน่าจะเป็นของการเกิดໄออิเท็มเซตในส่วนซ้ายมีอยู่ในตระกร้าสินค้าและໄอิเท็มเซตส่วนขวามีเป็นอิสระต่อ กัน ค่าลิฟท์ที่มีค่ามากกว่า 1 แสดงถึงระดับความขึ้นต่อกันของความน่าจะเป็นของการเกิดໄอิเท็มเซตในส่วนซ้ายมีอยู่และໄอิเท็มเซตส่วนขวามีอยู่ในชุดข้อมูล การเมื่อไหร่เมื่อเที่มเซตส่วนซ้ายมีอยู่ในตระกร้าสินค้าส่างผลให้ความน่าจะเป็นของการเกิดໄอิเท็มเซตทางขวามีอยู่ในตระกร้าสินค้าเพิ่มขึ้น ด้วย และถ้าค่าลิฟท์มีค่าน้อยกว่า 1 แสดงนัยว่าໄอิเท็มเซตส่วนซ้ายมีอยู่ในตระกร้าสินค้าส่างผลให้ความน่าจะเป็นของการเกิดໄอิเท็มเซตทางขวามีอยู่ในตระกร้าสินค้าลดลง

### ตัวอย่าง 3.23

พิจารณากฎความสัมพันธ์  $\{nm\} \Rightarrow \{\text{ขنمปง}\}$  จากข้อมูลรายการซื้อสินค้าในตาราง 3.1 สามารถหาค่าสนับสนุนของกฎความสัมพันธ์นี้ได้ดังนี้

$$\begin{aligned} sup(\{nm\} \Rightarrow \{\text{ขنمปง}\}) &= sup(\{nm\} \cup \{\text{ขنمปง}\}) \\ &= sup(\{nm, \text{ขنمปง}\}) \\ &= 0.5 \end{aligned}$$

และความเชื่อมั่นของกฎความสัมพันธ์ สามารถคำนวณ ดังนี้

$$\begin{aligned} conf(\{nm\} \Rightarrow \{\text{ขنمปง}\}) &= \frac{sup(\{nm, \text{ขنمปง}\})}{sup(\{nm\})} \\ &= \frac{0.5}{0.7} = 0.71 \end{aligned}$$

เมื่อกำหนดค่า  $minsup = 0.5$  และ  $minconf = 0.3$  พบร่วม กฎความสัมพันธ์  $\{nm\} \Rightarrow \{\text{ขنمปง}\}$  มีค่าสนับสนุนมากกว่าค่า  $minsup$  ดังนั้น กฎความสัมพันธ์นี้จึงเป็นกฎที่เกิดขึ้นบ่อยครั้ง นอกจากนี้ยังพบว่าค่าความเชื่อมั่นของกฎความสัมพันธ์มีค่าสนับสนุนมากกว่าค่า  $minconf$  ดังนั้น กฎความสัมพันธ์นี้จึงเป็นกฎนำเข้าถือด้วย

นอกจากนี้ เรายังสามารถหาค่าลิฟท์ของกฎความสัมพันธ์ ได้ดังนี้

$$\begin{aligned} lift(\{nm\} \Rightarrow \{\text{ขنمปง}\}) &= \frac{sup(\{nm\} \cup \{\text{ขنمปง}\})}{sup(\{nm\}) \times sup(\{\text{ขنمปง}\})} \\ &= \frac{sup(\{nm, \text{ขنمปง}\})}{sup(\{nm\}) \times sup(\{\text{ขنمปง}\})} \\ &= \frac{0.5}{0.7 \times 0.6} \\ &= \frac{0.5}{0.42} = 1.19 \quad (3.36) \end{aligned}$$

จากค่าลิฟท์ของกฎความสัมพันธ์  $\{nm\} \Rightarrow \{xnmp\}$  มีค่าเท่ากับ 1.19 ซึ่งมีค่ามากกว่า 1 ดังนั้น เราจึงสามารถกล่าวได้ว่าถ้ามีนิมอยู่ในตระกร้าสินค้าของลูกค้าแล้ว มีแนวโน้มสูงที่ในตระกร้าสินค้านั้นจะมีขั้นบัญชีด้วย

เราสามารถค้นหากฎความสัมพันธ์ที่มีความน่าเชื่อถือจากชุดของไอเท็มเซต  $\mathcal{A}$  ในชุดข้อมูล D ได้อย่างอัตโนมัติ โดยการกำหนดค่า  $minconf$  และดำเนินการตามขั้นตอนวิธี ต่อไปนี้

สำหรับแต่ละไอเท็มเซต  $Z$  ในเซต  $\mathcal{A}$  ที่มีจำนวนสินค้าในไอเท็มเซตมากกว่า 2 สินค้า ดำเนินการขั้นตอนดังนี้

ขั้นตอนที่ 1 สร้างเซต  $\mathcal{A}$  ซึ่งเป็นเซตของเซตย่อยทั้งหมดของ  $I$  ยกเว้นเซตว่าง

โดย  $\mathcal{A} = \{I | I \subset Z, I \neq \emptyset\}$

ขั้นตอนที่ 2 ทำขั้นตอนต่อไปนี้จนกระทั่ง เซต  $\mathcal{A}$  เป็นเซตว่าง

2.1 ให้ไอเท็มเซต  $I$  เป็นไอเท็มเซตใน  $\mathcal{A}$  ที่มีขนาดใหญ่ที่สุด (จำนวนสมาชิกมากที่สุด)

2.2 นำไอเท็มเซต  $I$  ออกจาก การเป็นสมาชิกของเซต  $\mathcal{A}$

2.3 สร้างไอเท็มเซต  $J$  โดย  $J$  คือ ผลลัพธ์จากการนำสินค้าที่อยู่ในไอเท็มเซต  $I$  ออกจากไอเท็มเซต  $Z$  นั่นคือ  $J = Z \setminus I$

2.4 คำนวณค่าความเชื่อมั่น  $c$  โดย  $c = \frac{\text{sup}(Z)}{\text{sup}(I)}$

2.5 ถ้าค่า  $c$  มีค่ามากกว่าหรือเท่ากับ  $minconf$  แล้ว สร้างกฎความสัมพันธ์  $I \Rightarrow J$  ถ้าไม่ เช่นนั้น ทำให้การลบไอเท็มเซตที่เป็นเซตย่อยทั้งหมดของ  $I$  ออกจากเซต  $\mathcal{A}$

จากขั้นตอนวิธีสำหรับค้นหากฎความสัมพันธ์ที่น่าเชื่อถือข้างต้น เป็นการนำแต่ละไอเท็มเซต  $Z$  ที่ประกอบด้วยจำนวนสินค้ามากกว่า 2 สินค้าขึ้นไป ทั้งหมดมาพิจารณา โดยการสร้างไอเท็มเซตส่วนซ้ายมีของกฎทั้งหมดที่เป็นไปได้จากไอเท็มเซต  $Z$  ในขั้นตอนที่ 1 ต่อมานำแต่ละไอเท็มเซตส่วนซ้ายมีอ  $I$  มาพิจารณาสร้างส่วนขวามีอ  $J$  โดยส่วนขวามีอเป็นไอเท็มเซตของสินค้าที่เหลือ จากการนำสินค้าในส่วนซ้ายมีอออกจากไอเท็มเซต  $Z$  และทำการคำนวณค่าความเชื่อมั่นที่จะเกิดจากการสร้างกฎความสัมพันธ์  $I \Rightarrow J$  ถ้าค่าความเชื่อมั่นที่คำนวณมีค่ามากกว่าหรือเท่ากับค่า  $minconf$  จะทำการสร้างกฎความเชื่อมั่น  $I \Rightarrow J$  แต่ถ้าค่าความเชื่อมั่นที่คำนวณมีค่าน้อยกว่าค่า  $minconf$  จะทำการลบเซตย่อยทั้งหมดที่เป็นไปได้ออก去 ไอเท็มเซต  $I$  ออกจากเซตของไอเท็มเซตที่มีศักยภาพที่จะเป็นส่วนซ้ายมีออื่นขึ้นมาพิจารณา

### ตัวอย่าง 3.24

จากตัวอย่าง 3.22 ไอเท็มเซตที่ในชุดข้อมูลรายการสินค้าในตาราง 3.1 มี

จำนวน 4 ไอเท็มเซต คือ  $\{\text{นม}\}$   $\{\text{แอปเปิล}\}$   $\{\text{ขنمปัง}\}$  และ  $\{\text{นม}, \text{ขنمปัง}\}$  พบว่ามีเพียง 1 ไอเท็มเซตถี่ที่มีจำนวนสินค้ามากกว่า 2 สินค้า นั่นคือ  $Z = \{\text{นม}, \text{ขنمปัง}\}$  เมื่อกำหนดค่า  $\text{minconf} = 0.3$  เราสามารถสร้างกฎความสัมพันธ์ที่น่าเชื่อถือจากไอเท็มเซตถี่ดังกล่าว ได้ดังนี้

สร้างเซต  $\mathcal{A}$  ซึ่งเป็นเซตของเซตย่อยทั้งหมดของ  $\{\text{นม}, \text{ขنمปัง}\}$  จะได้  $\mathcal{A} = \{\{\text{นม}\}, \{\text{ขنمปัง}\}\}$

พิจารณาให้ไอเท็มเซต  $I = \{\text{นม}\}$  ซึ่งมีขนาดใหญ่ที่สุด เป็นส่วนช้วยเมื่อของกฎความสัมพันธ์ และนำเซต  $I$  ออกจากเซต  $\mathcal{A}$  จะได้  $\mathcal{A} = \{\{\text{ขنمปัง}\}\}$  ต่อมาสร้างไอเท็มเซต  $J = Z \setminus I = \{\text{นม}, \text{ขنمปัง}\} - \{\text{นม}\} = \{\text{ขنمปัง}\}$  จากนั้นคำนวณค่าความเชื่อมั่น  $c = \frac{\{\text{นม}, \text{ขنمปัง}\}}{\{\text{นม}\}} = \frac{0.5}{0.7} = 0.71$  เนื่องจากค่าความเชื่อมั่นที่คำนวณได้มีค่ามากกว่าค่า  $\text{minconf}$  ดังนั้น จึงสร้างกฎความสัมพันธ์  $\{\text{นม}\} \Rightarrow \{\text{ขنمปัง}\}$

พิจารณาให้ไอเท็มเซต  $I = \{\text{ขنمปัง}\}$  เป็นส่วนช้วยเมื่อของกฎความสัมพันธ์ และนำเซต  $I$  ออกจากเซต  $\mathcal{A}$  จะได้  $\mathcal{A} = \{\}$  ต่อมาสร้างไอเท็มเซต  $J = Z \setminus I = \{\text{นม}, \text{ขنمปัง}\} - \{\text{ขنمปัง}\} = \{\text{นม}\}$  จากนั้นคำนวณค่าความเชื่อมั่น  $c = \frac{\{\text{นม}, \text{ขنمปัง}\}}{\{\text{ขنمปัง}\}} = \frac{0.5}{0.6} = 0.83$  เนื่องจากค่าความเชื่อมั่นที่คำนวณได้มีค่ามากกว่าค่า  $\text{minconf}$  ดังนั้น จึงสร้างกฎความสัมพันธ์  $\{\text{ขنمปัง}\} \Rightarrow \{\text{นม}\}$

เมื่อพบว่าเซต  $\mathcal{A}$  เป็นเซตว่าง จึงหยุดการสร้างกฎความสัมพันธ์ที่น่าเชื่อถือจากไอเท็มเซตถี่  $Z$  อีกทั้งไม่มีไอเท็มเซตถี่อื่นที่มีจำนวนสินค้ามากกว่า 2 สินค้าที่สามารถนำมาสร้างกฎความสัมพันธ์ได้อีก ดังนั้น จากชุดข้อมูลรายการสินค้านี้ มีกฎความสัมพันธ์ที่น่าเชื่อถือ 2 กฎ คือ

$\{\text{นม}\} \Rightarrow \{\text{ขنمปัง}\}$  มีค่าความเชื่อมั่นเท่ากับ 0.71

$\{\text{ขنمปัง}\} \Rightarrow \{\text{นม}\}$  มีค่าความเชื่อมั่นเท่ากับ 0.83

### 3.4 เอกสารอ้างอิงและแหล่งศึกษาเพิ่มเติม

- Bishop, Christopher M. (2006). *Pattern Recognition and Machine Learning (Information Science and Statistics)*. Berlin, Heidelberg: Springer-Verlag.
- Joanes, D. N. and C. A. Gill (1998). “Comparing measures of sample skewness and kurtosis.” In: *Journal of the Royal Statistical Society: Series D (The Statistician)* 47.1, pp. 183–189.
- Raymond H. Meyers, Ronald E. Walpole and, Sharon L. Meyers, and Keying E. Ye (2012). *Probability & Statistics for Engineers & Scientists*. 9th. USA: Prentice Hall.
- Theodoridis, Sergios and Konstantinos Koutroumbas (2008). *Pattern Recognition*. 4th. USA: Academic Press, Inc.
- Westfall, Peter H. (2014). “Kurtosis as Peakedness” In: *The American Statistician* 68.3, pp. 191–195.
- Zaki, Mohammed J. and Wagner Meira Jr (2014). *Data Mining and Analysis: Fundamental Concepts and Algorithms*. USA: Cambridge University Press.

### 3.5 แบบฝึกหัดท้ายบท

- จงหาค่ากลางข้อมูล (ค่าเฉลี่ย ค่ามัธยมฐาน และค่าฐานนิยม) ส่วนเบี่ยงเบนมาตรฐาน และความแปรปรวน ของ ข้อมูลในชุดข้อมูลต่อไปนี้ (หมายเหตุ บางชุดข้อมูลอาจไม่สามารถคำนวณค่าสถิติเชิงพรรณนาบางค่าได้)
  - ข้อมูลระยะเวลา (หน่วย: ชั่วโมง) ของการแท้งของสีน้ำพลาสติกยี่ห้อหนึ่ง จากการทดลอง 15 ครั้ง มีข้อมูล ดังนี้

3.4	2.5	4.8	2.9	3.6
2.8	3.3	5.6	3.7	2.8
4.4	4.0	5.2	3.0	4.8

- ข้อมูลค่าพีอีช (pH) ของสารที่มีความเป็นกรด (pH=7) ที่ตรวจวัดได้จากเครื่องมือวัดเครื่องหนึ่ง โดย ทำการวัดซ้ำ 10 ครั้ง มีข้อมูล ดังนี้

7.07    7.00    7.10    6.97    7.00    7.03    7.01    7.01    6.98    7.08

- ข้อมูลระดับความพึงพอใจในการให้บริการจัดส่งสินค้าของบริษัทแห่งหนึ่ง ระดับความพึงพอใจ 5 ระดับ ได้แก่ ไม่พอใจ พ่อใจน้อย พ่อใจปานกลาง พ่อใจมาก และพ่อใจมากที่สุด จากผลการสำรวจผู้ใช้บริการ 15 คน มีข้อมูล ดังนี้

พ่อใจปานกลาง    พ่อใจมาก    พ่อใจมาก    พ่อใจน้อย    พ่อใจมากที่สุด  
 ไม่พอใจ    พ่อใจมาก    พ่อใจมากที่สุด    พ่อใจน้อย    พ่อใจมาก  
 พ่อใจปานกลาง    พ่อใจมาก    พ่อใจปานกลาง    พ่อใจน้อย    พ่อใจมากที่สุด

d) ข้อมูลสำรวจสีขันของแมวที่มีขนสีเดียว จำนวน 10 ตัว ไปบริเวณมหาวิทยาลัยเชียงใหม่ มีข้อมูล ดังนี้

ขาว ขาว ดำ แดง เทา ดำ ดำ ดำ แดง ดำ

2. จากชุดข้อมูล Iris สามารถคำนวณค่าสถิติเชิงพรรณนาสำหรับแต่ละตัวแปร ดังนี้

ค่าสถิติ	ตัวแปร			
	Sepal Length	Sepal Width	Petal Length	Petal Width
Mean	5.84	3.05	3.76	1.12
Median	5.80	3.00	4.35	1.30
Mode	5.00	3.00	1.50	0.20
SD	0.83	0.43	1.76	0.76
Skewness	0.31	0.33	-0.27	-0.10
Kurtosis	-0.55	0.29	-1.40	-1.34

จงหาดลักษณะการกระจายของแต่ละตัวแปร พิรุณระบุค่าเฉลี่ย ค่ามัธยมฐาน ค่าฐานนิยม และลักษณะการแจกแจงของค่าตัวแปร

3. จากชุดข้อมูล Iris สามารถคำนวณค่าสัมประสิทธิ์สัมพันธ์เพียร์สันระหว่างตัวแปรแต่ละคู่ และแสดงด้วยเมทริกซ์ สหสัมพันธ์เพียร์สัน ดังนี้

	Sepal Length	Sepal Width	Petal Length	Petal Width
Sepal Length	1.00	-0.11	0.87	0.82
Sepal Width	-0.11	1.00	-0.42	-0.36
Petal Length	0.87	-0.42	1.00	0.96
Petal Width	0.82	-0.36	0.96	1.00

จากเมทริกซ์สหสัมพันธ์เพียร์สันข้างต้น จงตอบคำถาม ต่อไปนี้

- a) ตัวแปรคูณความสัมพันธ์ระหว่างค่าตัวแปรมากที่สุด
  - b) ตัวแปรคูณความสัมพันธ์ระหว่างค่าตัวแปรน้อยที่สุด
  - c) จงอธิบายความสัมพันธ์ระหว่างตัวแปร Sepal Length และ Petal Length
  - d) จงอธิบายความสัมพันธ์ระหว่างตัวแปร Sepal Width และ Petal Width
4. กำหนดข้อมูล 5 ข้อมูล ต่อไปนี้

$$x_1 = (1.00, 2.45, 3.05) \quad x_2 = (2.20, 1.05, 4.00) \quad x_3 = (1.50, 0.05, 2.75)$$

$$x_4 = (5.60, 3.45, 1.95) \quad x_5 = (3.30, 3.00, 3.50)$$

จงสร้างเมทริกซ์ระยะห่างของข้อมูลทั้ง 5 ข้อมูล โดยใช้วิธีการวัดระยะทางแบบยุคลิด การวัดระยะทางแบบเมเนช์ตัน และการวัดความคล้ายแบบโคลีชัน

5. จงคำนวณระยะห่างแบบเยนมิงและค่าสัมประสิทธิ์ความคล้ายแจ็คการ์ดระหว่างข้อมูลนักศึกษามหาวิทยาลัย เชียงใหม่ 2 คน ต่อไปนี้

$s_1$  = (Science, Computer Science, Male, Frist year)

$s_2$  = (Science, Mathematics, Male, Male, Second year)

#### 6. จากชุดข้อมูล ต่อไปนี้

	$X_1$	$X_2$
$x_1$	4.03	2.25
$x_2$	3.73	0.64
$x_3$	2.70	1.23
$x_4$	3.29	1.15
$x_5$	2.21	-0.16
$x_6$	11.44	5.97
$x_7$	10.33	3.26
$x_8$	9.25	5.09

จงแสดงการจัดกลุ่มแบบเคลื่อน เมื่อกำหนดจำนวนกลุ่มที่ต้องการเท่ากับ 2

#### 7. จากชุดข้อมูลในข้อ 6 สามารถสร้างเมทริกซ์ระยะทางแบบยุคลิดของข้อมูล ได้ดังนี้

	$x_1$	$x_2$	$x_3$	$x_4$	$x_5$	$x_6$	$x_7$	$x_8$
$x_1$	0.00	1.64	1.68	1.33	3.02	8.29	6.38	5.94
$x_2$	1.64	0.00	1.19	0.67	1.72	9.37	7.10	7.09
$x_3$	1.68	1.19	0.00	0.6	1.47	9.94	7.90	7.60
$x_4$	1.33	0.67	0.60	0.00	1.70	9.47	7.35	7.14
$x_5$	3.02	1.72	1.47	1.70	0.00	11.08	8.81	8.78
$x_6$	8.29	9.37	9.94	9.47	11.08	0.00	2.93	2.36
$x_7$	6.38	7.10	7.90	7.35	8.81	2.93	0.00	2.12
$x_8$	5.94	7.09	7.60	7.14	8.78	2.36	2.12	0.00

จงแสดงการจัดกลุ่มข้อมูลในข้อ 6 โดยใช้วิธีการรวมกลุ่มแบบลำดับชั้น เมื่อกำหนดให้จำนวนกลุ่มข้อมูลที่ต้องการ มีค่าเท่ากับ 2 และใช้การเขื่อมต่อสมบูรณ์ในการคำนวณระยะห่างระหว่างกลุ่มข้อมูล

#### 8. จากชุดข้อมูลในข้อ 6 จงแสดงการจัดกลุ่มโดยใช้วิธีการดีปีสแกน เมื่อกำหนดค่าพารามิเตอร์ $minPts = 2$ และ $\varepsilon = 3$

#### 9. จากวิธีการวิเคราะห์จัดกลุ่ม 3 วิธี ได้แก่

- 1) วิธีการจัดกลุ่มแบบเคลื่อน 2) วิธีการรวมกลุ่มแบบลำดับชั้น 3) วิธีการดีปีสแกน

จงจับคู่วิธีการวิเคราะห์จัดกลุ่มที่เกี่ยวข้องกับคุณลักษณะ ต่อไปนี้

- a) การรวมข้อมูลเป็นกลุ่มจากกลุ่มที่มีขนาดเล็กเป็นกลุ่มที่มีขนาดใหญ่ขึ้นจนกระทั่งได้จำนวนกลุ่มข้อมูลตามที่ต้องการ
- b) การจัดข้อมูลที่อยู่ในบริเวณที่มีความหนาแน่นของข้อมูลบริเวณเดียวกันให้อยู่ในกลุ่มข้อมูลเดียวกัน
- c) การแบ่งกลุ่มข้อมูลโดยมีเป้าหมายให้ครุณระยะทางระหว่างข้อมูลในกลุ่มข้อมูลเดียวกันมีค่าน้อยที่สุด

- d) ต้องกำหนดจำนวนกลุ่มข้อมูลที่ต้องการ เป็นค่าพารามิเตอร์
- e) ต้องกำหนดค่ารัศมีที่ระบุขอบเขตของ จุดข้อมูลเพื่อบ้าน โดยมีจุดข้อมูลเป็นศูนย์กลาง เพื่อคำนวณ หาความหนาแน่นของข้อมูล ณ แต่ละจุดข้อมูล
- f) สามารถตรวจหาข้อมูลผิดปกติได้

10. จากชุดข้อมูลรายการซื้อสินค้าของร้านขายผลไม้แห่งหนึ่ง แสดงดังตารางต่อไปนี้

	Green grapes	Avocado	Tomato	Corn
$t_1$	0	1	1	0
$t_2$	1	1	0	0
$t_3$	0	1	0	1
$t_4$	1	0	1	0
$t_5$	0	1	1	1
$t_6$	1	1	0	1
$t_7$	0	1	1	1
$t_8$	0	0	1	0

จงตอบคำถามต่อไปนี้

- a) จงแจกแจงไอเท็มเซตทั้งหมดที่เป็นไปได้ของชุดข้อมูล
- b) จงหาค่าสนับสนุนของแต่ละไอเท็มเซตทั้งหมดที่เป็นไปได้จากชุดข้อมูล
- c) จงแสดงการค้นหาไอเท็มเซตถี่ (Frequent Itemset) ทั้งหมดจากชุดข้อมูล โดยใช้ขั้นตอนวิธีเอปรอปริ (Apriori Algorithm)
- d) จงหาค่าสนับสนุนของกฎความสัมพันธ์  $\{Tomato\} \Rightarrow \{Avocado\}$
- e) จงหาค่าความเชื่อมั่นของกฎความสัมพันธ์  $\{Tomato\} \Rightarrow \{Avocado\}$
- f) จงแสดงการค้นหากฎความสัมพันธ์ (Association Rule) ที่น่าเชื่อถือทั้งหมดจากชุดข้อมูล
- g) จงหาค่าลิฟท์ของกฎความสัมพันธ์  $\{Tomato\} \Rightarrow \{Avocado\}$
- h) นักศึกษาควรจัดรายการส่งเสริมการขาย โดยลดราคาอะโวคาโด (Avocado) ให้กับลูกที่ซื้อมะเขือเทศ (Tomato) ร่วมด้วย หรือไม่ จงอธิบายเหตุผลประกอบ