

วารสารเทคโนโลยีสารสนเทศ

Information Technology Journal

Vol. 12 No. 1 January – June 2016

ISSN 1685-8573

บทความวิจัย

การสืบค้นผู้มีอิทธิพลและผู้อุทกครอบจั่นเนฟลู๊ค

พนิดา ทรงวัชญ์	1
----------------------	---

ระบบแคปช่าเสียงเชิงคำถานกับรูปแบบรหัสคำอับสำหรับผู้พิการทางสายตา

เรืองไชย ไทรประเพลสุข ออมรชัย มโนปิยอนันต์ และ ณัฐชนนท์ วงศ์ริทีธาร	11
---	----

การพัฒนาชุดฝึกอบรมการเขียนโปรแกรมควบคุมหุ่นยนต์ด้วยภาษาซี สำหรับนักศึกษาครุศาสตร์อุดสาหกรรม

กิตติ เสือแพะ และ พัฒพงษ์ ออมรวงศ์	18
--	----

การกำหนดแบบดิจิทัลย่างบุติธรรมสำหรับควบคุมการเชื่อมต่ออินเตอร์เน็ตแบบทวิคุณด้วยนโยบายระดับกันค่าสูงสุดและทำสุด

อธิคม ศิริ เกศสุดา ค้าลีวงศ์ ธนาวุฒิ ธนาวนิชย์ และกมล บุญล้อม	24
---	----

การย้ายถิ่นแบบปรับตัวสำหรับจีเนติกอัลกอริทึมแบบกระจาย

ชัยวิวัฒน์ จันตีสาร และ พրเทพ ใจนวสุ	30
--	----

การทำเหมืองข้อมูลกฎความสัมพันธ์ด้วยวิธีค่าถ่วงน้ำหนักสูงสุดจากการภาพวินิจฉัยแบบสมมาตร

→ ประมูล สุขสากาผ่อง และ พยุง มีล้า	37
---	----

การกระจายภาระงานด้วยหลักโครงสร้างการรวมกลุ่มที่ดีที่สุด

พานิชย์ สุดโภด ฉัตรตะกูล สมบัติธีระ และ สาวนิด วัฒนศักดากุล	44
---	----

การเพิ่มประสิทธิภาพเทคนิคด้านไม้ดัดสินใจบนชุดข้อมูลที่ไม่สมดุลโดยวิธีการสุ่มเพิ่มตัวอย่างกลุ่มน้อย

สำหรับข้อมูลการเป็นโรคติดอินเทอร์เน็ต

กรันยา ปาลวิสุทธิ์	54
--------------------------	----

การพัฒนาระบบสารสนเทศสำหรับตรวจสอบสถานะเครื่องคอมพิวเตอร์ในเครือข่ายด้วยเทคนิคการเผยแพร่และการติดตาม

เอกรินทร์ วัทัญญาเดศกุล	64
-------------------------------	----

Research Paper

A Model Design for a Web-based Learning System using Project-based Learning of Imagineering to Enhance Creative Construction of Multimedia Skills and Cooperative Skills

Runanta Chatwattana and Rattanakorn Phadungthim	74
---	----

การทำเหมืองข้อมูลกฎความสัมพันธ์ด้วยวิธีค่าถ่วงน้ำหนักสูงสุด จากราฟบิบูรรณ์แบบสมมาตร

Associations Rule Mining By Using Top Weight of Complete Symmetric Digraphs

ประมวล สุขสาครพ่อง (*Pramool Suksakaophong*) และพยุง มีสัจ (*Phayung Meesad*)

คณะเทคโนโลยีสารสนเทศ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าฯ พระนครเหนือ

¹*pramool7@yahoo.com*, ²*pym@kmutnb.ac.th*

บทคัดย่อ

การทำเหมืองข้อมูลกฎความสัมพันธ์จากรายการซื้อขายเพื่อใช้ในการทำรายการส่งเสริมการขายและน้ำ ráyการสินค้าที่มักจะซื้อด้วยกันบ่อยๆ แต่การทำกฎความสัมพันธ์ต้องอาศัยการกำหนดค่าสนับสนุนขั้นต่ำที่เหมาะสม เพราะถ้ากำหนดค่าน้อยไป จำนวนกฎที่ได้ก็จะมากและถ้ากำหนดค่ามากไป จำนวนกฎที่ได้ก็จะน้อย ทำให้ผู้ใช้ยากจะหาค่าที่เหมาะสม ได้ในแต่ละชุดข้อมูล จากรากฐานข้อมูลเดียว ผู้ใช้ยังสามารถอธิบายการใหม่ในการเก็บความถี่ของข้อมูลในรูปแบบกราฟบิบูรรณ์แบบสมมาตรแบบมีพิเศษทางเพื่อนำค่าถ่วงน้ำหนักสูงสุด ไปคำนวณหากฎความสัมพันธ์ จากค่าสนับสนุนสูงสุด ได้และใช้ได้กับทุกชุดข้อมูล

คำสำคัญ: กฎความสัมพันธ์ กราฟบิบูรรณ์ เมทริกซ์ประชิด เหมืองข้อมูล

Abstract

Association rules mining from transaction data can be used to recommend the items that are often purchased together frequently. However, it is difficult to set minimum support threshold. If the minimum support threshold is set too high, then there may be only a small or even no result. If the threshold is set too low, it may generate many uninteresting associations. In addition, each supporting a different set of data, enabling users to find the optimal difficult. This paper presents a new approach to the collection frequency by using top weight of complete symmetric digraphs. Using the top weight, the association

rule with the maximum support can be calculated and it works with any dataset.

Keyword: Association rule mining, Complete Symmetric Digraphs, Adjacency matrix, Data mining.

1. บทนำ

การทำเหมืองข้อมูลกันหากกฎความสัมพันธ์ (Association rule mining) จากรายการซื้อขายสินค้า (Marker Basket Transaction) โดยกฎความสัมพันธ์สามารถสร้างขึ้นจากเซตรายการความถี่ (Frequent Itemsets) นำมาเปรียบเทียบกับค่าสนับสนุนขั้นต่ำ (Minimum Support) และค่าความเชื่อมั่นขั้นต่ำ (Minimum Confidence) จากในชุดข้อมูลขนาดใหญ่ แต่การค้นหากฏความสัมพันธ์จากข้อมูลที่มีรายการสินค้านานาจังหวะต้องใช้เวลาในการคำนวณมากและปัญหาที่สำคัญในการค้นหากฏความสัมพันธ์จากข้อมูลรายการซื้อขายสินค้าคือ ค่าที่เหมาะสมของค่าสนับสนุนขั้นต่ำ เพราะถ้ากำหนดค่าน้อยไป จำนวนกฎที่ได้ก็จะมากและถ้ากำหนดค่ามากไป จำนวนกฎที่ได้ก็จะน้อย หรือไม่สามารถหากฎความสัมพันธ์ได้

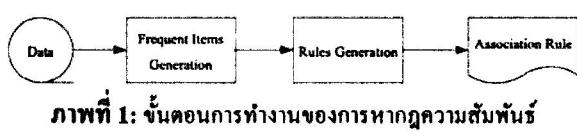
ขั้นตอนวิธีการค้นหากฏความสัมพันธ์ต้องอาศัยการกำหนดค่าสนับสนุนขั้นต่ำที่เหมาะสมเพื่อลดเวลาในการประมวลผลและตัดรายการที่มีความถี่น้อยๆ ออกไป ทำให้ไม่สามารถหากฎความสัมพันธ์ในรายการสินค้าที่มีความถี่น้อยแต่มีมูลค่าสูงซึ่งเป็นที่ต้องการของผู้ใช้ จึงคิดค้นขั้นตอนวิธีใหม่เพื่อให้เหมาะสมกับการใช้งานในพาณิชย์อิเล็กทรอนิกส์โดยใช้พื้นฐานจากทฤษฎีกราฟและกราฟบิบูรรณ์แบบสมมาตรแบบมีพิเศษทางเพื่อให้ลดการใช้หน่วยความจำและทำงานได้รวดเร็ว ข้อดีของ

การนำทฤษฎีกราฟมาใช้ทำให้การจัดเก็บความถี่ของแต่ละรายการสินค้าเป็นอิสระต่อกันทำให้สามารถสแกนหากรู้ความสัมพันธ์ในทุกรายการสินค้าได้

2. ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1 กราฟความสัมพันธ์

การค้นหากราฟความสัมพันธ์ มีขั้นตอนหลักๆ 2 ขั้นตอนคือ ขั้นแรก การนับรายการความถี่ (Frequent Items Generation) ที่เกิดขึ้นบ่อยทั้งหมดก่อน โดยใช้ตรายการต้องมีค่าความถี่มากกว่า หรือเท่ากับค่าสนับสนุนขั้นต่ำตามที่กำหนด ขั้นตอนที่สองคือ ค้นหากราฟความสัมพันธ์ของกลุ่มข้อมูลที่ปรากฏร่วมกันบ่อย (Rule Generation) ที่มีความเชื่อมั่นของกฎไม่น้อยกว่าค่าที่กำหนด และนำมาสร้างเป็นกราฟความสัมพันธ์ ขั้นตอนการทำงานของการหากราฟความสัมพันธ์ดังแสดงในภาพที่ 1



ภาพที่ 1: ขั้นตอนการทำงานของการหากราฟความสัมพันธ์

2.2 นิยามเบื้องต้นของกราฟความสัมพันธ์

ค่านิยามที่ใช้เรียกเพื่อใช้แทนสิ่งต่างๆ ใน การค้นหากราฟความสัมพันธ์ โดยกำหนดให้ $I = \{i_1, i_2, \dots, i_n\}$ เป็นเซตของชื่อ ข้อมูลหรือรายการสินค้า (items) ที่ประกอบด้วยรายการสินค้า จำนวน n ชื่นรายการสินค้า และให้ $T = \{t_1, t_2, \dots, t_m\}$ คือ เซต ข้อมูลรายการซื้อขายสินค้า (Transactions) ในฐานข้อมูล T ที่ ประกอบด้วยรายการข้อมูลมีสมาชิกจำนวน m รายการข้อมูล โดยที่แต่ละรายการ t_i จะประกอบไปด้วยรายการย่อยของ รายการสินค้าจากกลุ่มข้อมูล I

ค่าสนับสนุนขั้นต่ำ หรือเขียนแทนด้วย $minsup$ [1] การหาค่าสนับสนุน (Support) จากสมการ (1) คำนวณจาก ข้อมูลที่ปรากฏร่วมกันของ X และ Y ต่อสัดส่วนจำนวนรายการ ทั้งหมด (N)

$$s(X \rightarrow Y) = \frac{\sigma(X \cup Y)}{N} \quad (1)$$

ค่าความเชื่อมั่นขั้นต่ำของกฎหรือเขียนแทนด้วย $minconf$ [1] สามารถคำนวณค่า Confidence จากสมการ (2) รายการ X และ Y ปรากฏร่วมกัน ต่อสัดส่วนรายการ X

$$c(X \rightarrow Y) = \frac{\sigma(X \cup Y)}{\sigma(X)} \quad (2)$$

จำนวนกฎที่เป็นไปได้จะคำนวณได้จากสมการที่ (3)

$$R = \sum_{k=1}^{d-1} \left[\binom{d}{k} \times \sum_{j=1}^{d-k} \left(\frac{d-k}{j} \right) \right] \quad (3)$$

เมื่อค่า d คือจำนวนรายการ สมมุติว่ามี 4 รายการ จำนวนกฎที่เป็นไปได้จะเท่ากับ 50 กฎ แต่ถ้ามี 6 รายการ จะได้ 602 กฎ : ซึ่งเป็นการเพิ่มขึ้นในลักษณะเอ็กซ์โพเนนเชียล (Exponential) ยิ่งมีรายการสินค้ามาก จำนวนกฎจะมากตามไปด้วย

2.3 การใช้ทฤษฎีเซตในการหากราฟความสัมพันธ์

ขั้นตอนวิธี Apriori (Apriori Algorithm) [1] เป็นขั้นตอนวิธี ที่ได้รับการยอมรับและเป็นที่รู้จักในการค้นหากราฟความสัมพันธ์ โดยใช้ที่มีความถี่มากกว่าค่าสนับสนุนขั้นต่ำ เช่นบ่อยจะมี ความถี่ที่มากกว่า แล้วสามารถตัดเฉพาะรายการที่มีความถี่ต่ำออก ขั้นตอนวิธีในการค้นหาเครื่องการที่ปรากฏร่วมกันบ่อยและ นำมาสร้างกราฟความสัมพันธ์ ข้อดีของขั้นตอนวิธี Apriori คือ สามารถทำงานได้หากกำหนดค่าสนับสนุนขั้นต่ำมากๆ นี้ ขนาดของฐานข้อมูลขนาดเล็ก และมีจำนวนของรายการ น้อย ส่วนข้อเสีย คือต้องอ่านข้อมูลจากฐานข้อมูลหลายครั้ง จึง มีผู้คิดขั้นตอนวิธีใหม่โดยการนับข้อมูลในโครงสร้าง FP-Tree โดยใช้ชื่อขั้นตอนวิธี FP-Growth [2] ที่ใช้การอ่านข้อมูลจาก ฐานข้อมูลเพียง 2 ครั้ง ทำให้ทำงานได้เร็วขึ้น

2.4 การใช้ทฤษฎีกราฟในการหากราฟความสัมพันธ์

การค้นหากราฟความสัมพันธ์ด้วยวิธีกราฟ จะจำลองวิธีการ เก็บความถี่ในรูปของโหนด (Node) และเส้นเชื่อม (Edge) และ ค้นหาของข้อมูลที่ปรากฏร่วมกันบ่อยในรูปแบบของกราฟบอย ซึ่งมีปริมาณข้อมูลมาก ขั้นตอนวิธี FP-Growth Graph [3] จึงใช้ วิธีของ FP-Growth ใน การค้นหากราฟความสัมพันธ์

การใช้เมตริกซ์ประชิด (Adjacency Matrix) [4] เป็นการ จำลองข้อมูลกราฟในรูปของข้อมูลในเมทริกซ์และใช้คุณสมบัติ การบวกกันของเมทริกซ์เพื่อค้นหาความถี่ของข้อมูลที่ปรากฏ ร่วมกันบ่อย ขั้นตอนวิธี TDB [5] จะใช้วิธี (Path) ใน การค้นหา นอกจากนี้ยังมีการใช้arry (Array) [6] และการใช้กราฟ บริบูรณ์ (Completed Graph) โดยขั้นตอนวิธี GARM [9] จะ แปลงแต่ละรายการซื้อขายเป็นกราฟบริบูรณ์ ทำให้สามารถ เพิ่มเติมรายการข้อมูล (Dynamic Update) ในภายหลังได้ และ

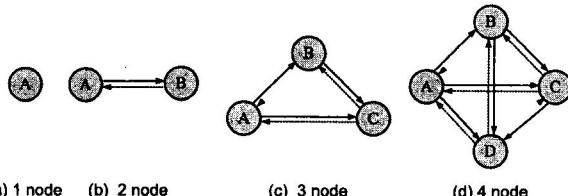
การใช้รูปแบบสมือนกราฟบิบูรณา [10] โดยใช้เมทริกซ์ในการเก็บข้อมูล

2.5 ปัญหาการกำหนดค่าที่เหมาะสมสำหรับค่าสนับสนุนขั้นต่ำและค่าความเชื่อมั่นของกฎ

ปัญหาสำคัญของการหากถูกความสัมพันธ์คือการกำหนดค่าที่เหมาะสมเพื่อกันหากถูกความสัมพันธ์ซึ่งมีค่าระหว่าง 0 กับ 1 ด้วยขั้นตอนวิธี Apriori ด้วยค่า $minsup = 0.1$ และ $minconf = 0.9$ ซึ่งไม่สามารถนำไปใช้ได้กับทุกชุดข้อมูลต้องเลือกค่าหลายครั้งกว่าจะใช้กันหากถูกความสัมพันธ์ได้ และได้มีจัดทำไว้ชี้ให้ใช้ค่าต่อไปนี้หานักเรียน WARM [8] และขั้นตอนวิธี Top-k [9] เพื่อแก้ปัญหาดังกล่าว

3. วิธีดำเนินงานวิจัย

จากปัญหาการหาค่าสนับสนุนขั้นต่ำ ผู้วิจัยจึงเลือกใช้ทฤษฎีกราฟ เพราะมีความยืดหยุ่นและแสดงถึงการเชื่อมโยงของข้อมูลได้ดี ขั้นแรกจะทำการแปลงรายการซื้อขายในรูปแบบของกราฟบิบูรณาแบบสมมาตร แทนสินค้าด้วยโหนดและความสัมพันธ์ระหว่างโหนดด้วยเส้นเชื่อม การเชื่อมต่อลักษณะนี้จะเป็นมีการเชื่อมต่อทั้งสองทิศทาง ซึ่งหมายความว่าความสัมพันธ์ที่มีการซื้อขายสินค้าไม่มีคำนึงถึงทิศทาง เนื่องจากในการซื้อขายกันจริงๆ ข้อมูลลำดับรายการซื้อขายอาจจะมีการสลับกันอยู่ จึงต้องเก็บข้อมูลทั้งสองทิศทางดังภาพที่ 2



ภาพที่ 2: กราฟบิบูรณาแบบสมมาตร

ข้อมูลรายการซื้อขายจะแปลงข้อมูลในรูปเมทริกซ์ มีค่าแทนรายการสินค้าด้วย 1 และไม่มีรายการสินค้าด้วย 0

ตารางที่ 1: ข้อมูลรายการซื้อขายสินค้า

TID	Items Bought
01	{Apple, Bread, Cake}
02	{Apple, Bread, Cake, Diaper}
03	{Apple, Cake}
04	{Cake, Diaper}
05	{Bread, Cake, Diaper}
06	{Bread, Cake}
07	{Bread, Diaper}
08	{Bread, Cake, Diaper}

TID	A	B	C	D
01	1	1	1	0
02	1	1	1	1
03	1	0	1	0
04	0	0	1	1
05	0	1	1	1
06	0	1	1	0
07	0	1	0	1
08	0	1	1	1

3.1 รายการซื้อขายในຕัวกร้าสินค้า

ตัวอย่างรายการตะกร้าสินค้าในตารางที่ 1 ประกอบด้วย ลำดับรายการซื้อ (Transaction ID) และ รายการสินค้า (Items) สามารถจดอยู่ในรูปแบบเมทริกซ์ในตัวแปร TID ที่เก็บค่าแต่ละรายการซื้อขายสินค้าในรูปแบบ 0 กับ 1

3.2 การนับความถี่ของรายการซื้อขายสินค้า

ขั้นตอนวิธีในการหากถูกความสัมพันธ์จากการตะกร้าสินค้า จะทำการนับความถี่โดยในแต่ละลำดับรายการซื้อขาย โดยจำลองข้อมูลรายการเป็นเมทริกซ์ประชิด (adjacency matrix) และทำการเก็บข้อมูลในเซลล์อาร์เรย์ (Cell Array, { }) โดย-ขั้นตอนวิธีการทำงานรวม ดังแสดงในภาพที่ 3

Algorithm 1 FEG Frequency-Edge-Graph Construction

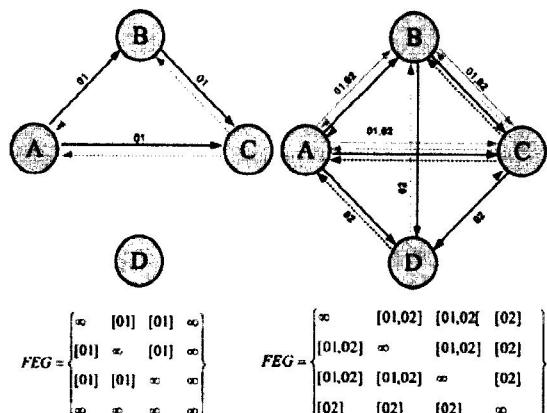
```

load data to transaction[]
[M, N ] = Transaction[]
for i=1 to M
    for j= 1 to N /*count items in each TID */
        if transaction(i,j)==1
            Items[] = j
        end
        for k = 1 to size(Items)
            FEG{} = [Items{M, N}, i]
        end
    end
end

```

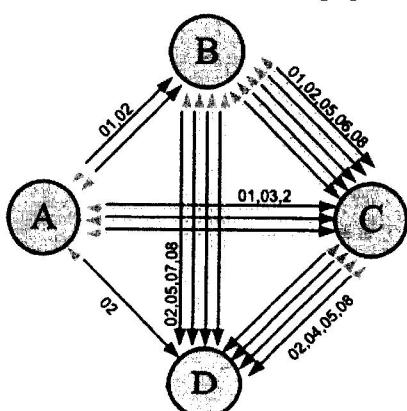
ภาพที่ 3: ขั้นตอนวิธีการนับความถี่

เริ่มแรกจะอ่านและเก็บข้อมูลรายการซื้อขายและเก็บในตัวแปร transaction[] จากนั้นรีบวนรอบในแต่ละรายการ เลือกเฉพาะรายการสินค้าที่มีค่าเป็น 1 นำมาสร้าง เมทริกซ์ประชิดในรูปของกราฟบิบูรณาแบบสมมาตรเพื่อนับความถี่ของแต่ละรายการสินค้าที่มีการซื้อขายด้วยกันในตัวแปร FEG{}



ภาพที่ 4: การจำลองข้อมูลรายการซื้อขายที่ 01 และ 02

จากภาพที่ 4 เริ่มอ่านข้อมูลรายการซื้อขายที่ 01 มีรายการสินค้า $items = \{A, B, C\}$ นำมาสร้างเน็ตเวิร์กซึ่งประกอบด้วย 3 รายการและเก็บค่าลำดับรายการซื้อขาย (TID = 01) ลงตัวแปร FEG {} ต่อตัวรายการซื้อขายที่ 02 (TID = 02) มีรายการสินค้า $items = \{A, B, C, D\}$ นำมาสร้างเป็นเน็ตเวิร์กซึ่งประกอบด้วย 4 รายการ มากกว่าค่าลำดับรายการซื้อขายในเซลล์อร์เรย์เดิม จำลองการทำงานเหมือน แมลติกราฟ (Multigraph)



ภาพที่ 5: จำลองการเก็บข้อมูล FEG{} เมื่อครบถ้วนรายการ

จากนั้นก็วนรอบเก็บข้อมูลลำดับรายการซื้อขายจนครบถ้วนรายการดังภาพที่ 5 จะได้ข้อมูลความถี่ในตัวแปร FEG{} ซึ่งจำลองการเก็บข้อมูลลำดับรายการซื้อขาย (TID) ในส่วนเชื่อมแบบแมลติกราฟ ข้อมูลที่เก็บในตัวแปรอร์เรย์ดังตารางที่ 3

ตารางที่ 2: เมทริกซ์รายการซื้อความถี่ของสินค้า

	A	B	C	D	Top_W
A	∞	[01,04]	[01,03,04]	[04]	3
B	[01,04]	∞	[01,04,05,06,08]	[04,05,07,08]	5
C	[01,03,04]	[01,04,05,06,08]	∞	[02,04,05,08]	5
D	[04]	[04,05,07,08]	[02,04,05,08]	∞	4
Union	3	6	7	5	

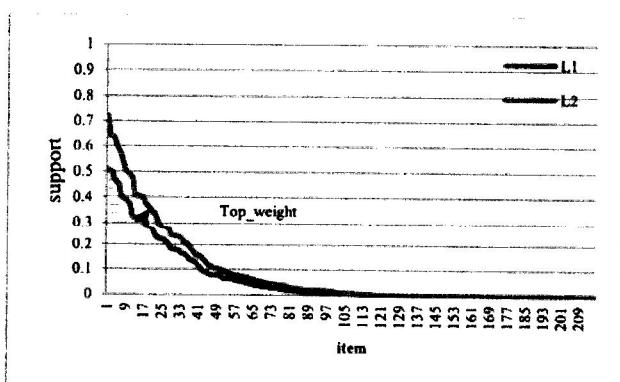
ข้อมูลที่จัดเก็บในตัวแปรเซลล์อร์เรย์ FEG{} ดังกล่าวแสดงในตารางที่ 2 เป็นเซลล์อร์เรย์เก็บลำดับรายการซื้อขายในเม็ตเวิร์กซึ่งประกอบด้วย 4 รายการนับผลรวมเพื่อระบุรายการสินค้าคือผลรวมการซูปเนี้ยบ (Union) ในแต่ละคอลัมน์ ส่วนค่าถ่วงน้ำหนักสูงสุด (Top_W) คือการหาค่าผลรวมแต่ละคู่รายการที่มีค่าสูงสุดในแต่ละ列 เช่น ค่าแรก {A,C} จะมีค่าสูงสุดคือ 3 เมื่อหารอบทุกແตรวจสอบมาเรียงข้อมูลใหม่ จะได้ค่าถ่วงน้ำหนักจากมากไปหาน้อย จะได้ $Top_Weight = [5 \ 5 \ 4 \ 3]$

3.3 การหาค่าสนับสนุนจากค่าถ่วงน้ำหนักสูงสุด (Top Weight)

ตามคุณสมบัติแอนติโนโทน (Anti-Monotone property) เช่นที่มีจำนวนข้อมูลมากกว่าไม่สามารถมีค่าสนับสนุนมากกว่าเขตยอดได้ตามสมการที่ (4)

$$\forall X, Y : (X \subseteq Y) \Rightarrow s(X) \geq s(Y) \quad (4)$$

จากคุณสมบัติดังกล่าวได้นำไปทดลองกับชุดข้อมูล supermarket เพื่อหาค่าสนับสนุนของชุดมูล 1 รายการและ 2 รายการ ได้ผลลัพธ์ในภาพที่ 6



ภาพที่ 6: ชุดข้อมูล supermarket เรียงตามค่าถ่วงน้ำหนัก

จากการทดลองแสดงให้เห็นว่าเขตยอดที่สูงสุด 1 รายการ L1 มีค่ามากที่สุด และ L2 รองลงมา โดยกฎความสมพันธ์จะเริ่มต้นจากความสมพันธ์ของ 2 รายการ ดังนั้นจึงเลือกค่าถ่วงน้ำหนักของ 2 รายการเพื่อนำไปคำนวณค่าถ่วงน้ำหนักสูงสุด เพื่อใช้ในการหาค่า Top_Weight

3.4 การหาคุณภาพสัมพันธ์

ผลจากการนับความถี่ในตารางที่ 2 แสดงความสัมพันธ์ของแต่ละค่ารายการสินค้าในรูปของเมตริกซ์ในตัวแปรเซลล์อาร์เรย์ FEG{} โดยเส้นเชื่อมจะเก็บค่ารายการความถี่ของค่าที่ปรากฏร่วมกัน ขั้นตอนการค้นหาคุณภาพสัมพันธ์ ดังแสดงในภาพที่ 7 เริ่มจากการหาค่าถ่วงน้ำหนักสูงสุด หาน้ำหนักของตัวแปรเซลล์อาร์เรย์ FEG{} จากนั้นกำหนดการวนรอบข้อมูล โดยหาค่าสูงสุดในแต่ละแถว เมื่อได้ครบทุกแถวที่นำมาเรียงข้อมูลใหม่ จะได้ค่าถ่วงน้ำหนักที่เรียงจากมากไปหาน้อย ขั้นตอนที่ได้จะสามารถนำไปคำนวณค่าสนับสนุนตาม สมการที่ (1)

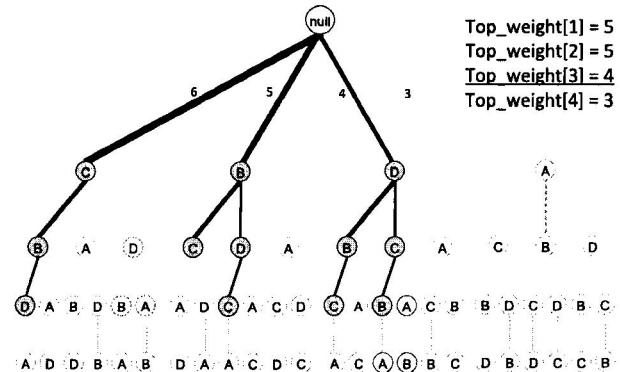
Algorithm2 Association rule Generation

```
[M, N] = size(FEG)
for i=1 to M
    for j=1 to N
        /*find Maximal Weight for each item */
        If ( sum(items(m,n)) > max_items )
            max_items = items(m,n)
        end
    end
    Top_Weight[] = max_items
    Sort(Top_Weight)
end

[M, N] = FEG{}
Top_Weight[] = d /* define Top_Weight level */
minconf= d
for (L1 Items >= Top_Weight)
    for L1 to Ln Items
        sort(intersect(items(L1,L2, →Ln) ≥ Top_Weith
        and items(items(L1,L2, →Ln) ≥ minconf
        Asso_rule[] = (items(L1,L2, →Ln)
    end
end
```

ภาพที่ 7: ขั้นตอนการคุณภาพสัมพันธ์

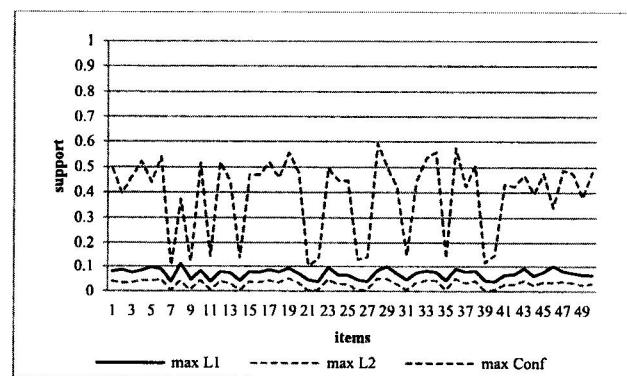
เมื่อได้ค่าสนับสนุนแต่ละรายการสินค้าแล้วนำมาเรียงข้อมูล และค้นหาลำดับเดียวกัน นำมาเปรียบเทียบกับค่าถ่วงน้ำหนักถ้ามีค่ามากกว่าก็นำไปเปรียบเทียบกับค่าความเชื่อมั่นของกฎถ้ามากกว่าก็จะนับเป็นคุณภาพสัมพันธ์ได้ ขั้นตอนวิธีหากคุณภาพสัมพันธ์โดยการตัดรายการความถี่ที่น้อยกว่าค่าถ่วงน้ำหนักลำดับที่ 3 คือมีค่าความถี่เท่ากัน 4 ดังภาพที่ 8 ทำให้ได้รายการที่เหลือเฉพาะค่าสนับสนุนที่สูงนำไปสร้างกฎความสัมพันธ์โดยวนรอบแต่ละรายการมาคำนวณค่าความเชื่อมั่นตามที่กำหนด



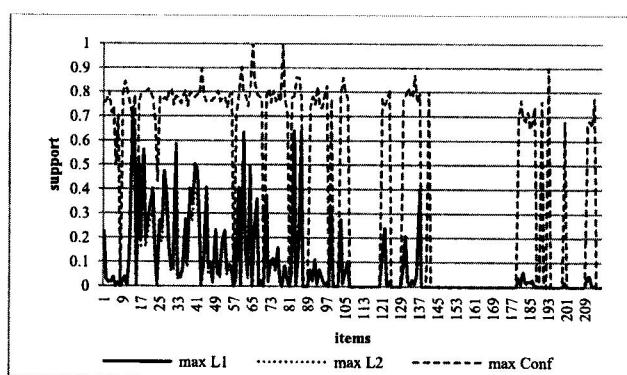
ภาพที่ 8: ผลการตัดรายการความถี่ที่ Top_weight = 4

4. ผลการดำเนินงาน

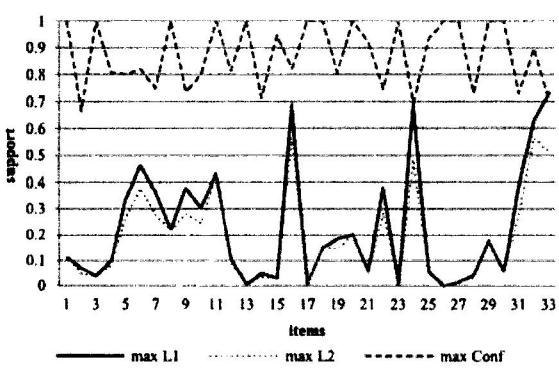
จากการออกแบบขั้นตอนวิธีที่ได้ นำมาเขียนโปรแกรม MATLAB R2012a 32BIT นำมาคำนวณหาค่าสนับสนุนตามสมการ (1) จะได้ค่าสนับสนุนสูงสุดของ 1 รายการ (max L1) และค่าสนับสนุน 2 รายการ (max L2) และค่าความเชื่อมั่นตามสมการ (2) จะได้ค่าความเชื่อมั่นสูงสุด 2 รายการ (max Conf) ผลลัพธ์ได้มาสร้างเป็นกราฟได้ดังภาพที่ 9 ถึง 11



ภาพที่ 9: ชุดข้อมูล Bakery



ภาพที่ 10: ชุดข้อมูล supermarket



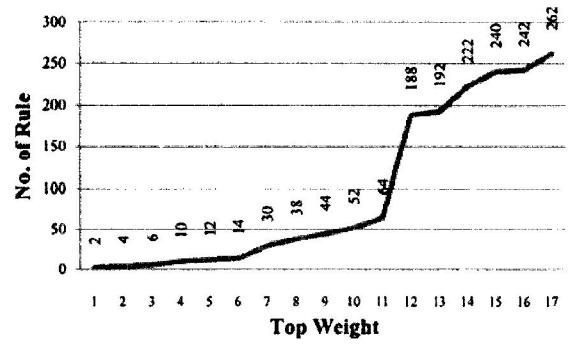
ภาพที่ 11: ชุดข้อมูล Chess

ภาพที่ 9 ชุดข้อมูล Bakery ประกอบด้วย 5,000 รายการซื้อขายสินค้าใน 50 สินค้า ค่าสนับสนุนแต่ละอย่างสินค้า (max L2) จะมีค่า 0.0512 ส่วนภาพที่ 10 ชุดข้อมูล supermarket ประกอบไปด้วย 4,627 รายการซื้อขายสินค้าจาก 217 สินค้า ค่าสนับสนุนแต่ละอย่างสินค้า (max L2) จะมีค่า 0.505079 และภาพที่ 11 ชุดข้อมูล Chess ประกอบไปด้วย 3,196 รายการซื้อขายสินค้าจาก 33 สินค้า ค่าสนับสนุนแต่ละอย่างสินค้า (max L2) จะมีค่า 0.56383 จากการทดลองกับชุดข้อมูลต่างๆ ทำให้เป็นได้ว่า แต่ละชุดข้อมูลมีค่าสนับสนุนและค่าความเชื่อมั่นในระดับที่แตกต่างกัน สามารถนำมาเปรียบเทียบได้ดังตารางที่ 4 โดยเลือกมาเพียง 5 อันดับแรกเรียงจากค่าสูงสุด

ตารางที่ 3: ผลการคำนวณสนับสนุนสูงสุด 5 อันดับ

Dataset	Chess	Supermarket	Bakery
1	0.56383	0.505079	0.0512
2	0.56383	0.502485	0.0496
3	0.513454	0.49665	0.0472
4	0.480914	0.473525	0.044
5	0.431477	0.460125	0.0436

จากค่าสนับสนุนที่ได้นำไปหาค่าความสัมพันธ์โดยทดลองกับชุดข้อมูล Supermarket เริ่มนับน้ำหนักสูงสุดคือ 0.505079 จะได้ 2 กฎ และลำดับสอง 0.502485 จะได้ 4 กฎ จนถึงอันดับที่ 5 คือ 0.460125 จะได้ 12 กฎ จำนวนกฏที่สัมพันธ์กับระดับค่าสนับสนุนจากสูงสุด แสดงในภาพที่ 12 ทำให้สามารถเลือกจำนวนกฏที่ต้องการอัดในมิติโดยการกำหนดระดับของค่าสนับสนุนจากอันดับสูงสุด



ภาพที่ 12: จำนวนกฎต่อค่าสนับสนุนในชุดข้อมูล supermarket

5. สรุป

การจำลองข้อมูลในรูปแบบกราฟบริบูรณ์สามารถลดค่าน้ำค่าสนับสนุนสูงสุดและค่าความเชื่อมั่นสูงสุดได้ที่ใช้ได้กับทุกชุดข้อมูล และนำค่าดังกล่าวมาหาค่าความสัมพันธ์โดยสามารถเลือกค่าความสัมพันธ์ที่มีค่าสนับสนุนและค่าความเชื่อมั่นที่จากระดับสูงสุดได้ และจากการทดลองค่าสนับสนุนแต่ละค่ามีความละเอียดถึงทศนิยม 6 ตำแหน่ง จึงเป็นการยากที่คู่ใช้งานจะคาดคะเนเพื่อเลือกค่าที่เหมาะสมด้วยตนเองได้ เพราะบางชุดข้อมูลเช่น Bakery ระดับค่าสนับสนุนห่างกันแค่เพียง 0.1 ทำให้การหาค่าที่เหมาะสมด้วยการกำหนดค่าเองเป็นไปได้ยาก การเลือกจากค่าสนับสนุนโดยกำหนดระดับจากสูงสุด ทำให้จำกัดปริมาณค่าความสัมพันธ์ และได้ค่าความสัมพันธ์ที่มีค่าสนับสนุนและความเชื่อมั่นที่สูงได้

เอกสารอ้างอิง

- [1] R. Agrawal, R. Srikant, "Fast Algorithms for Mining Association Rules in Large Databases," *Proceedings of the 20th International Conference on Very Large Data Bases*, 672836: Morgan Kaufmann Publishers Inc.; pp. 487-99, 1994
- [2] J. Han, J. Pei, and Y. Yin, "Mining frequent patterns without candidate generation," *Proceedings of the 2000 ACM SIGMOD international conference on Management of data*, ACM: Dallas, Texas, USA. pp. 1-12, 2000
- [3] V. Tiwari et al., "Association rule mining: A graph based approach for mining frequent itemsets," *Networking and Information Technology (ICNIT)*, 2010
- [4] A. Inokuchi, T. Washio, and H. Motoda, "Complete Mining of Frequent Patterns from Graphs: Mining Graph Data," *Machine Learning*, Vol 50(3): p. 321-354, 2003

- [5] S. Arumugam., and S. Sabeen, "Association Rule Mining using Path Systems in Directed Graphs," *International Journal of Computers, Communications & Control*, vol 8(6): pp. 791-799, 2013
- [6] L. Naili, and M. Lei, "Discovering frequent itemsets an improved algorithm of directed graph and array," *4th IEEE International Conference on. 2013Software Engineering and Service Science (ICSESS)*, 2013
- [7] P. Amal Dev, N.V. Sobhana, and P. Joseph, GARM: A Simple Graph Based Algorithm For Association Rule Mining. *International Journal of Computer Applications.*, Vol 76(1-16): pp. 1, 2013
- [8] A. Salam, and M. Sikandar Hayat Khayal, "Mining top-k frequent patterns without minimum support threshold," *Knowledge and Information Systems*, Vol 30(1): pp. 57-86, 2012.
- [9] R. Pears et al., "Weighted association rule mining via a graph based connectivity model," *Information Sciences*, Vol 218(0): pp. 61-84, 2013.
- [10] P. Suksakaophong and P. Meesad, "Complete-Graph-Like Association Rule Mining," *Joint Conference on ACTIS & NCOBA 2015* Nakhon Phanom, Thailand, January 30-31, 2015 pp. 148-154, 2015