

การศึกษาวิธีการกรองแบบร่วมกันสำหรับการแนะนำเมนูอาหาร

A study of collaborative filtering for menu recommendations

กวรรณ หนูแดง และผู้ช่วยศาสตราจารย์ ดร. เอกรัฐ รัฐกาญจน์

บทคัดย่อ

ในปัจจุบันสภาพการแข่งขันที่รุนแรงของธุรกิจร้านอาหารส่งผลให้ผู้ประกอบการต้องมีการปรับตัว และปรับกลยุทธ์ในการทำการตลาด การนำเอาข้อมูลการสั่งซื้อในอดีตมาวิเคราะห์ช่วยให้สามารถแนะนำเมนูอาหารให้กับลูกค้าได้อย่างรวดเร็วและตรงกับความต้องการ ในการศึกษาครั้งนี้ได้รวบรวมคำสั่งซื้อสินค้าของร้านอาหารญี่ปุ่นแห่งหนึ่ง นำมาสร้างและพัฒนาระบบแนะนำ ทั้งแบบเฉพาะบุคคลและไม่เฉพาะบุคคล โดยใช้วิธีการกรองร่วม (Collaborative Filtering) ผลการศึกษาพบว่า การสร้างระบบแนะนำแบบเฉพาะบุคคล อัลกอริทึมที่ให้ประสิทธิภาพที่ดีที่สุดคือวิธีการกรองร่วมโดยพิจารณาผู้ใช้เป็นหลัก (User-Based Collaborative Filtering) โดยใช้เทคนิค K-Nearest Neighbors และการสร้างระบบแนะนำแบบไม่เฉพาะบุคคล เพื่อหาคู่เมนูอาหารที่มีความสัมพันธ์ภายในออเดอร์เดียวกัน โดยใช้วิธีการกรองร่วมโดยพิจารณาสินค้า (Item-Based Collaborative Filtering) ด้วยเทคนิค Cosine Similarity พบว่าคู่เมนูอาหารที่มีความสัมพันธ์กันสูงสุด คือ ซูชิเซตแซลมอนเบียร์นิกิริและ Sushi Set ผลจากการวิจัยในครั้งนี้ สามารถเป็นแนวทางช่วยให้ผู้ประกอบการนำไปพิจารณาในการจัดกิจกรรมส่งเสริมการตลาดได้ เช่น การจัดโปรโมชั่นให้ตรงกับความต้องการของลูกค้า เพื่อดึงดูดความสนใจลูกค้าและกระตุ้นยอดขายได้

คำสำคัญ : ระบบแนะนำ, การคัดกรองร่วม, คัดกรองผู้ใช้, คัดกรองสิ่งของ

Abstract

The intense competition in the restaurant business has resulted in operators having to adjust marketing strategies. The analysis of past purchases allows us to quickly and precisely to recommend menus to customers that meet their needs. In this study, data from a Japanese restaurant were collected, to create and develop a recommendation system both individual and non-personal by using a common filtering method. (Collaborative Filtering). Creating a personalized recommendation system The best performing algorithm is a user-based collaborative filtering approach, using the K-Nearest Neighbors technique and creating a personalized recommendation system. A non-personalized by Item based collaborative filtering, using the Cosine Similarity technique, it was found that the menu pairs with the highest correlation is burn nigiri salmon sushi set and sushi set. The results of this research Can be a guideline to help entrepreneurs to consider in marketing strategies, such as organizing promotions to meet customer needs to attract customers' attention and drive sales.

Keyword : Recommendation System, Collaborative Filtering, User-Based, Item-Based

1. บทนำ

ธุรกิจร้านอาหารเป็นหนึ่งในธุรกิจบริการที่มีความสำคัญต่อระบบเศรษฐกิจของประเทศ ด้วยมูลค่าหมุนเวียนที่ไม่ต่ำกว่า 4 แสนล้านบาท คิดเป็นสัดส่วนร้อยละ 4.7 ของภาคบริการทั้งหมดของผลิตภัณฑ์มวลรวมในประเทศ (ศูนย์วิจัยกสิกรไทย, 2563) อีกทั้งในธุรกิจมีผู้ประกอบการที่หลากหลายทั้งผู้ประกอบการรายเล็ก (ระดับบุคคล) ไปจนถึงผู้ประกอบการรายใหญ่ที่สนใจเข้ามาเริ่มธุรกิจในตลาดอย่างต่อเนื่อง จึงถือได้ว่าเป็นตลาดที่ใหญ่และมีแนวโน้มการแข่งขันที่สูง ส่งผลให้ผู้ประกอบการจำเป็นต้องปรับตัวและปรับกลยุทธ์ในการจัดการธุรกิจ โดยไม่เพียงแต่ให้ความสำคัญกับรสชาติและคุณภาพของอาหาร แต่ควรคำนึงถึงความต้องการของผู้บริโภคที่แตกต่างกันอีกด้วย

การแข่งขันในธุรกิจร้านอาหารที่มีแนวโน้มเพิ่มสูงขึ้น ส่งผลให้ผู้ประกอบการร้านอาหารมีการเพิ่มกลยุทธ์ในการขายมากขึ้น ซึ่งเป้าหมายคือการเพิ่มรายได้ให้กับธุรกิจ เช่น การสร้างสรรค์เมนูใหม่ๆ การลดราคา และการจัดโปรโมชั่นเพื่อส่งเสริมการขาย เป็นต้น เพื่อสร้างความแตกต่างดึงดูดผู้บริโภค

การนำเอาเทคโนโลยีมาใช้ในการทำธุรกิจ จะช่วยให้ผู้ประกอบการมีโอกาสในการเข้าถึงพฤติกรรมและรสนิยมของผู้บริโภคที่มีอยู่หลากหลายและแตกต่างกันไปได้อย่างมีประสิทธิภาพมากขึ้น เพื่อให้สามารถตอบสนองความต้องการและให้บริการได้ตรงกลุ่มลูกค้า ในการศึกษาครั้งนี้ผู้วิจัยจึงสนใจนำเอาข้อมูลการสั่งซื้อของลูกค้าในอดีตมาวิเคราะห์พฤติกรรมการสั่งอาหารและหารูปแบบในการแนะนำเมนูอาหารให้ตรงกับความต้องการลูกค้า โดยใช้วิธีพิจารณาการกรองร่วมกัน (Collaborative Filtering) เพื่อนำมาช่วยในการออกแบบกิจกรรมส่งเสริมการขาย ทั้งสำหรับลูกค้าที่เป็นสมาชิก เพื่อให้มีความสอดคล้องกับความต้องการและพฤติกรรมการสั่งอาหารของลูกค้าแต่ละบุคคล และสำหรับลูกค้าใหม่ที่ไม่เคยมีประวัติการซื้อขาย เพื่อคาดการณ์โอกาสการซื้อที่ลูกค้าน่าจะชอบ

2. วัตถุประสงค์

การศึกษานี้มีวัตถุประสงค์เพื่อศึกษาความเป็นไปได้ในการประยุกต์ใช้วิธีพิจารณาการกรองร่วมกัน (Collaborative Filtering) มาจัดการข้อมูลการสั่งซื้อสำหรับแนะนำเมนูอาหารเพื่อให้ตรงกับพฤติกรรมและความต้องการของลูกค้า

3. ขอบเขตงานวิจัย

- 3.1. ขอบเขตด้านพื้นที่ : ร้านอาหารญี่ปุ่นแห่งหนึ่งในจังหวัดลพบุรี
- 3.2. ขอบเขตด้านเนื้อหา : ศึกษาข้อมูลของร้านอาหารโดยใช้ข้อมูลการขาย ตั้งแต่ 01/01/2018-06/05/2021 จำนวน 14,401 รายการ และใช้ข้อมูลสมาชิกทั้งสิ้น 156 คน

4. ประโยชน์ที่คาดว่าจะได้รับ

- 4.1. เป็นแนวทางในการประยุกต์ใช้ระบบแนะนำสินค้าให้กับร้านอาหาร
- 4.2. เป็นแนวทางสำหรับผู้ประกอบการร้านอาหารในการนำผลลัพธ์ที่ได้มาประกอบการตัดสินใจการจัดกิจกรรมส่งเสริมการขาย

5. การทบทวนแนวคิด ทฤษฎี และงานวิจัยที่เกี่ยวข้อง

ในการศึกษางานวิจัยเรื่อง การศึกษาวิธีการกรองแบบร่วมกันสำหรับการแนะนำเมนูอาหาร ผู้วิจัยได้ทำการทบทวนแนวคิด ทฤษฎี และงานวิจัยที่เกี่ยวข้อง โดยมีสาระสำคัญตามลำดับดังนี้

5.1. ระบบแนะนำ (Recommendation System)

ระบบแนะนำ (Recommendation System) คือ ระบบที่แนะนำข้อมูล ผลิตภัณฑ์ หรือผู้คนให้กับผู้ใช้ระบบ โดยอ้างอิงจากสมมุติฐานการเรียนรู้ข้อมูลความชอบหรือความต้องการ ณ ขณะนั้นของผู้ใช้ โดยระบบแนะนำสามารถจำแนกประเภทจากวิธีการแนะนำเป็น 5 ประเภท ได้แก่

1. วิธีพิจารณาจากข้อมูลสิ่งของ (Content-based Filtering) เป็นวิธีที่แนะนำสิ่งของ (Item) โดยพิจารณาจากคุณสมบัติของสิ่งของที่ผู้ใช้เคยชื่นชอบในอดีต ระบบจะแนะนำสิ่งของเมื่อสิ่งของนั้นมีคุณสมบัติตรงกับสิ่งที่ผู้ใช้เคยชอบในอดีตให้

2. วิธีพิจารณาร่วมกัน (Collaborative Filtering) เป็นวิธีการแนะนำโดยพิจารณาจากข้อมูลของผู้ใช้ในอดีตเช่นเดียวกับ Content-based Filtering แต่จะต่างตรงที่ Collaborative Filtering จะนิยมใช้กับระบบผู้แนะนำที่มีการให้คะแนนความชื่นชอบ (Rating) ต่อสิ่งของ วิธีการนี้สามารถได้หลายรูปแบบแต่วิธีที่เป็นที่นิยมจะมี 3 วิธีหลักๆ ดังนี้ 1.) User-Based Collaborative Filtering เป็นการดูจากความชอบของลูกค้าย่อยที่คล้ายกับลูกค้าย่อยเป้าหมาย โดยถ้าลูกค้าย่อยที่คล้ายกันอยู่ในกลุ่มเดียวกันมักจะชอบสินค้าที่มีลักษณะคล้ายกัน เช่น เช่น ผู้ชายสองคนที่กินอาหารเหมือนกัน เมื่อนาย B ซื้อน้ำอัดลม ก็มีความน่าจะเป็นที่นาย A จะซื้อเช่นกัน ทำให้ในการสั่งอาหารจะมีการแนะนำน้ำอัดลมให้นาย A 2.) Item-Based Collaborative Filtering จะแนะนำสินค้าโดยอาศัยข้อมูลและพฤติกรรมในอดีตของลูกค้าย่อยเป้าหมาย มาคำนวณหาสินค้าที่คล้ายคลึงกับสินค้าที่ลูกค้าย่อยเป้าหมายเคยชื่นชอบ โดยพิจารณาจากคะแนนความชื่นชอบที่ถูกให้โดยลูกค้าย่อยหลายคน 3.) Singular Value Decomposition เป็นการนำเอาหลักการแยกองค์ประกอบของเมทริกซ์มาใช้ โดยการแยกเมทริกซ์หลักออกเป็นเมทริกซ์ย่อย จากนั้นใช้ Optimization Algorithm ในการหาค่าพารามิเตอร์ที่เหมาะสมสำหรับเมทริกซ์นั้นๆ และนำผลลัพธ์ที่ได้มาหาคะแนนทำนายที่ใช้ในการแนะนำสิ่งของให้กับผู้ใช้เป้าหมาย (Sarwar, Karypis, Konstan, and Riedl, 2001)

3. วิธีพิจารณาโดยใช้ข้อมูลส่วนตัว (Demographic Filtering) เป็นวิธีการที่แนะนำโดยการพิจารณาข้อมูลส่วนตัวของบุคคล เช่น เพศ, อายุ, อาชีพ, ที่อยู่ หรือสัญชาติ แต่วิธีนี้ไม่เป็นที่นิยมมากนัก เนื่องจากมีกฎหมายคุ้มครองข้อมูลส่วนบุคคล (Privacy Policy) ส่งผลให้การเข้าถึงข้อมูลทำได้ยาก

4. วิธีการใช้ความรู้ที่ได้จากผู้ใช้โดยตรง (Knowledge-based Recommender) เป็นวิธีการที่จะสอบถามความชอบของผู้ใช้โดยตรงว่าให้ความสำคัญหรือคุณค่ากับคุณลักษณะใดของสินค้า เช่น ราคาสินค้า, ความใหม่ของสินค้า หรือความนิยมของสินค้า

5. วิธีแบบผสม (Hybrid) เป็นวิธีที่รวมเทคนิคอื่นๆตั้งแต่ 2 เทคนิคเข้าด้วยกัน แล้วนำข้อดีของแต่ละเทคนิคมาประยุกต์ใช้ เพื่อแก้ข้อบกพร่องของแต่ละอัลกอริทึม

5.2. แนวคิดเรื่องคะแนนความพึงพอใจ (Rating)

1. คะแนนความพึงพอใจแบบชัดเจน (Explicit Rating) เป็นคะแนนที่แสดงอยู่ในรูปของจำนวนตัวเลขตามระดับความนิยม โดยช่วงคะแนนจะขึ้นอยู่กับการใช้งาน ข้อมูลในส่วนนี้จะได้จากการสอบถามจากผู้ใช้โดยตรง เช่น การกดดาวให้ 5 ดาวสำหรับภาพยนตร์เรื่องหนึ่ง

2. คะแนนความพึงพอใจแบบไม่ชัดเจน (Implicit Rating) เป็นคะแนนที่ได้มาจากพฤติกรรมการใช้งานของผู้ใช้ต่าง เช่น การเช็คคะแนนโดยวัดจากจำนวนการซื้อ หรือการกดเพื่อเข้าไปดูสินค้า

5.3. การวัดประสิทธิภาพของระบบแนะนำ

การวัดประสิทธิภาพระบบแนะนำขึ้นอยู่กับลักษณะของข้อมูล และอัลกอริทึมที่ใช้ในการสร้าง โดยทั่วไปจะวัดโดยการนำระบบแนะนำไปทดลองใช้จริงและวัดอัตราการตอบสนองต่อสินค้าที่แนะนำ (Response Rate) หรือการวัดโดยดูจากค่าต่างๆ เรียกว่า วิธีการทดสอบกับคะแนนทำนาย โดยจะต้องแบ่งข้อมูลออกเป็น 2 ส่วน ส่วนแรกสำหรับให้อัลกอริทึมเรียนรู้ (Training Data) และส่วนที่สองสำหรับทดสอบ (Testing Data) (Shani and Gunawardana, 2011) แล้วจึงนำข้อมูลส่วนแรกไปสร้างระบบแนะนำ และทดสอบประสิทธิภาพกับส่วนที่สอง

วิธีการทดสอบกับคะแนนทำนาย เป็นการวัดผลของระบบแนะนำโดยดูจากค่าความแม่นยำว่าสามารถแนะนำสินค้าได้ตรงกับข้อมูลชุดทดสอบ (Testing Data) ได้เท่าไร โดยค่าความแม่นยำ (Precision) สามารถคำนวณได้ดังสมการ

$$Precision = \frac{TP}{TP+FP}$$

$$Recall = \frac{TP}{TP + FN}$$

เมื่อ TP คือ จำนวนสินค้าที่ระบบแนะนำได้ตรงกับสินค้าที่ลูกค้าเป้าหมายชอบ

FP คือ จำนวนสินค้าที่ระบบแนะนำได้ไม่ตรงกับสินค้าที่ลูกค้าเป้าหมายชอบ

FN คือ จำนวนสินค้าที่ลูกค้าเป้าหมายชอบแต่ระบบไม่ได้แนะนำ

แต่เนื่องจากค่าความแม่นยำที่ได้นั้น จะไม่สามารถระบุได้ว่าระบบแนะนำสามารถแนะนำสินค้าได้ตรงในลำดับที่เท่าไร และเพื่อให้สามารถวัดผลของลำดับในการแนะนำได้ จึงนำเอาค่าความแม่นยำเฉลี่ย (Average Precision : AP) และค่าเฉลี่ยของความแม่นยำเฉลี่ย (Mean Average Precision : MAP) มาพิจารณาในการวัดประสิทธิภาพของระบบแนะนำร่วมด้วย (Sawtelle, 2020) โดยมีสมการดังนี้

$$AP@K = \frac{1}{M} \sum_{k=1}^K P(k) \cdot rel(k)$$
$$MAP@K = \frac{1}{|U|} \sum_{K=1}^I U(AP@k)u$$

$$AR@K = \frac{1}{M} \sum_{k=1}^K R(k).rel(k)$$

$$MAR@K = \frac{1}{|U|} \sum_{K=1}^I U (AR@k)u$$

เมื่อ	AP@K	คือ	ค่าความแม่นยำเฉลี่ย ของการแนะนำสินค้า k ลำดับ
	MAP@K	คือ	ค่าเฉลี่ยของความแม่นยำเฉลี่ย ของการแนะนำสินค้า k ลำดับ
	AR@K	คือ	ค่าเฉลี่ยความระลึกได้ ของการแนะนำสินค้า k ลำดับ
	MAR@K	คือ	ค่าเฉลี่ยของค่าเฉลี่ยความระลึกได้ ของการแนะนำสินค้า k ลำดับ
	M	คือ	จำนวนครั้งที่ระบบแนะนำสินค้าได้ตรงกับสิ่งที่ผู้ใช้เป้าหมายชอบ
	U	คือ	จำนวนผู้ใช้ทั้งหมด

5.4. งานวิจัยที่เกี่ยวข้อง

Bayu Yudha Pratama, Indra Budi, Arlisa Yuliawati (2020) ได้ศึกษาเกี่ยวกับระบบแนะนำสินค้าในอุตสาหกรรมค้าปลีกแบบออนไลน์ โดยนำเอาข้อมูลรายการขายย้อนหลังมาแปลงเป็นค่า Rating ด้วยเทคนิค Min-Max Scaling จากนั้นสร้างระบบแนะนำด้วยวิธีพิจารณาการกรอกร่วมกัน ใน 2 แนวทาง ได้แก่ k-NN Algorithm และ SVD Matrix Factorization โดยมีวัตถุประสงค์เพื่อจัดทำระบบแนะนำสินค้าและค้นหาวิธีที่ดีที่สุด ผลลัพธ์ที่ได้พบว่า k-NN Algorithm มีประสิทธิภาพเหนือกว่า SVD Matrix Factorization อีกทั้งยังพบว่า ยิ่งใช้การฝึกอบรมข้อมูลมากเท่าใด ประสิทธิภาพของระบบการแนะนำก็จะยิ่งดีขึ้นเท่านั้น

ศุจินทร ทรงสิทธิเดช, ผนกร อินทร์พยุง(2019). ได้ศึกษาการสังเคราะห์ข้อมูลการสั่งซื้อสำหรับแนะนำเมนูอาหารเพื่อช่วยให้ร้านอาหารสามารถปรับปรุงคุณภาพในการบริการและเพิ่มผลประกอบการให้มากยิ่งขึ้น โดยการวิเคราะห์ความสัมพันธ์ของคู่เมนูอาหารที่ถูกคำสั่งในแต่ละออเดอร์ โดยใช้ระบบแนะนำแบบคัดกรองสินค้า (Item Based Collaborative Filtering) โดยการหาค่า Cosine Similarity ผลลัพธ์ที่ได้ คือ คู่เมนูอาหารที่มีความสัมพันธ์กันสูงและสามารถนำไปแนะนำลูกค้าต่อได้

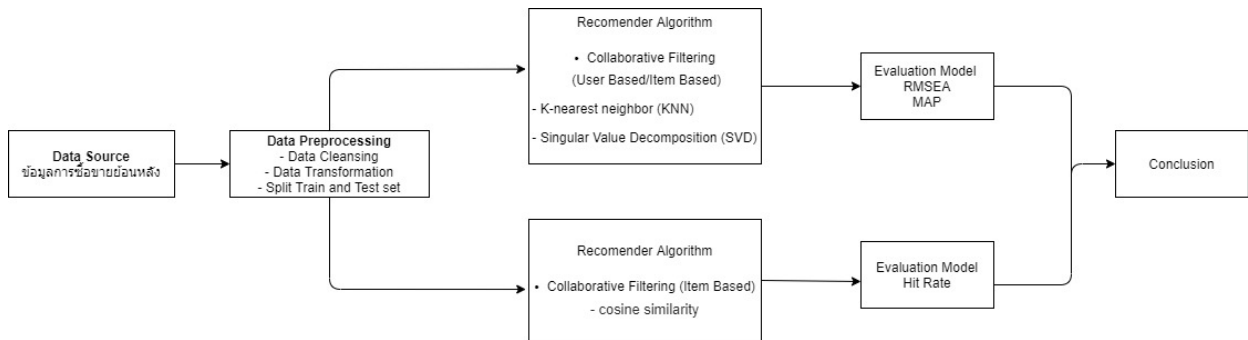
รัฐวรรณ พันธุนิล (2017). ได้ศึกษาการพัฒนาแนะนำส่วนบุคคลโดยใช้ขั้นตอนวิธีแบบคัดกรองผู้ใช้ ร่วมกับแบบคัดกรองสิ่งของร่วม เพื่อเปรียบเทียบประสิทธิภาพของอัลกอริทึม และพัฒนาระบบแนะนำสินค้า โดยใช้ข้อมูลจาก MovieLens Website จำนวน 1,000,000 Records พบว่าค่าเฉลี่ยความแม่นยำของระบบแนะนำแบบคัดกรองสินค้า (Item Based Collaborative Filtering) มีค่าสูงกว่าระบบแนะนำแบบคัดกรองผู้ใช้ (User Based Collaborative Filtering)

6. วิธีการดำเนินการวิจัย

ในการศึกษางานวิจัยเรื่อง การศึกษาวิธีการกรอกร่วมกันสำหรับการแนะนำเมนูอาหาร จะแบ่งการศึกษา ระบบแนะนำออกเป็น 2 ส่วน คือ

1. ระบบแนะนำเมนูอาหารเฉพาะบุคคล (สำหรับลูกค้าที่เป็นสมาชิก)
2. ระบบแนะนำเมนูอาหารแบบไม่เฉพาะบุคคล (สำหรับลูกค้าใหม่และลูกค้าทั่วไปที่ไม่ได้เป็นสมาชิก)

โดยผู้วิจัยได้แบ่งขั้นตอนการดำเนินงานวิจัยดังรูปภาพที่ (6-1)



รูปภาพที่ 6-1 ขั้นตอนการดำเนินงานวิจัย

6.1. แหล่งข้อมูล (Data Source)

ข้อมูลที่น่ามาใช้วิเคราะห์เป็นข้อมูลรายการขายย้อนหลังของร้านขายอาหารญี่ปุ่นแห่งหนึ่ง ที่ถูกจัดเก็บโดยโปรแกรม Loyverse ระบบ POS และดึงข้อมูลออกมาในรูปแบบไฟล์ประเภท Comma Separated Value (CSV) โดยใช้ข้อมูลย้อนหลังตั้งแต่วันที่ 1 มกราคม 2018 ถึง 31 พฤษภาคม 2021 โดยมี Transaction จำนวน 14,401 รายการ 21 คอลัมน์ ได้แก่ Date, Receipt number, Receipt type, Category, SKU, Item, Variant, Modifiers applied, Quantity, Gross sales, Discounts, Net sales, Cost of goods, Gross profit, Taxes, Dining option, POS Store, Cashier name, Customer name, Comment, Status โดยข้อมูลที่น่ามาศึกษาในงานวิจัยครั้งนี้จะใช้ข้อมูล 3 คอลัมน์ ได้แก่ Receipt Number (เลขที่ใบเสร็จจตุต 1 รอบการซื้อสินค้า), Customer_id (รหัสของลูกค้า) และ Item (ชื่อของสินค้า)

6.2. การเตรียมข้อมูล (Data Preprocessing)

6.2.1 การทำความสะอาดข้อมูล (Data Cleansing)

ทำการรวมเมนูที่เป็นเมนูเดียวกัน แต่ใน Transaction เป็นคนละชื่อเข้าด้วยกัน และแก้ไขชื่อให้ตรงกัน จากนั้นทำการลบรายการที่ไม่มีข้อมูล Customer_id ออก เนื่องจากจะไม่สามารถระบุได้ว่าเป็นข้อมูลการซื้อขายของลูกค้าคนไหน

6.2.2 การแปลงข้อมูล (Data Transformation)

ในการแนะนำเมนูอาหารแบบเฉพาะบุคคลด้วยวิธีพิจารณาการกรอกร่วมกัน (Collaborative Filtering) จำเป็นที่จะต้องใช้อัลกอริทึมให้คะแนนความชื่นชอบของลูกค้า (Rating) แต่เนื่องจากในฐานข้อมูลไม่มีข้อมูลในส่วนนี้ จึงนำเอาประวัติการซื้อขายของลูกค้ามาใช้ เพื่อแสดงถึงความพึงพอใจของลูกค้าที่มีต่อเมนูนั้นๆ โดยหากลูกค้าซื้อเมนูหนึ่งซ้ำๆ เป็นการบ่งชี้ว่าลูกค้าคนนั้นมีแนวโน้มที่จะชอบเมนูนี้และคะแนนความชื่นชอบก็จะสูงตาม โดยมีขั้นตอนดังนี้

จากข้อมูลที่มีอยู่ ดังตารางที่ 6-1 จะทำการนับรวมจำนวนครั้งทั้งหมดของการซื้ออาหารแต่ละเมนูของลูกค้าแต่ละคน ดังในตารางที่ 6-2

ตารางที่ 6-1 ตัวอย่างข้อมูลรายการขายย้อนหลัง

Customer_id	Item	Quantity	Date
49292012	ข้าวหน้าปลาไหล	1	24/2/2018
49292012	ข้าวหน้าปลาไหล	1	01/6/2018
49292012	ข้าวหน้าปลาไหล	1	15/1/2019
26057538	ข้าวราดแกงกะหรี่	1	31/3/2019
26057538	ข้าวราดแกงกะหรี่	1	20/7/2019

ตารางที่ 6-2 ตัวอย่างจำนวนการซื้ออาหารแต่ละเมนูของลูกค้า

Customer_id	Item	Quantity
49292012	ข้าวหน้าปลาไหล	3
26057538	ข้าวราดแกงกะหรี่	2

จากนั้นนำข้อมูลที่ปรากฏในตารางที่ 6-2 มาสร้าง Pivot Table ที่มีแถว (Row) เป็นรายการเมนูอาหารทั้ง 164 รายการ และมีคอลัมน์ (Column) เป็น รหัสลูกค้า (Customer_id) ทั้ง 156 คน โดยค่าภายในคือ จำนวนครั้งทั้งหมดที่ลูกค้าซื้ออาหารแต่ละเมนู ดังตารางที่ 6-3

ตารางที่ 6-3 จำนวนครั้งที่ลูกค้าซื้ออาหารแต่ละเมนู

Customer_id	ข้าวหน้าปลาไหล	ข้าวราดแกงกะหรี่	ทาโกยากิ	เทมปุระ	หมึกย่างซอส
49292012	10	6	8	-	15
26057538	16	-	-	8	-
38387831	8	12	10	-	-
31421598	-	-	-	12	20
28986423	-	-	6	-	8

จากนั้นทำการแปลงข้อมูลภายในตารางที่ 6-3 ให้เป็นค่า Rating โดยใช้ Minmax Scaling Algorithm ในการปรับข้อมูลโดยมีสมการ ดังนี้

$$r_{ui} = \left[\left(\frac{f_{ui} - f_{min}}{f_{max} - f_{min}} \right) \times (r_{max} - r_{min}) \right] + r_{min}$$

เมื่อ f_{ui} คือ ความถี่ในซื้อสินค้าของลูกค้า u ที่ซื้อสินค้า i

f_{min} คือ จำนวนครั้งที่ซื้อสินค้าน้อยที่สุด

f_{max} คือ จำนวนครั้งที่ซื้อสินค้ามากที่สุด

r_{ui} คือ ค่า Rating ของผู้ใช้ u ที่มีต่อสินค้า i

r_{min} คือ ค่า Rating ที่ต่ำที่สุด

r_{max} คือ ค่า Rating ที่มากที่สุด

ตารางที่ 6-4 คะแนน Rating ของลูกค้าสำหรับอาหารแต่ละเมนู

Customer_id	ข้าวหน้าปลาไหล	ข้าวราดแกงกะหรี่	ทาโกยากิ	เทมปุระ	หมึกย่างซอส
49292012	2.5	1.5	2	0	4.5
26057538	4.8	0	0	2	0
3838783152	2	4	2.5	0	0
31421598	0	0	0	4	5
28986423	0	0	1.5	0	2

6.3. การสร้างระบบแนะนำ (Recommendation System)

6.3.1 ระบบแนะนำเมนูอาหารเฉพาะบุคคล (สำหรับลูกค้าที่เป็นสมาชิก)

ในการสร้างระบบแนะนำเมนูอาหารเฉพาะบุคคล (สำหรับลูกค้าที่เป็นสมาชิก) ด้วยวิธีพิจารณาการกรองร่วมกัน มีขั้นตอนดังนี้

1. การแบ่งข้อมูลที่ใช้ในการทดสอบ นำข้อมูลที่ผ่านมาขั้นตอนการแปลงข้อมูลมาแบ่งออกเป็น 2 ชุด สำหรับสร้างตัวแบบ (Training Data) และข้อมูลสำหรับทดสอบ (Testing Data) ในสัดส่วน 70% และ 30% ตามลำดับ
2. การหาค่าพารามิเตอร์ที่เหมาะสม โดยใช้เทคนิค GridSearch ในการปรับค่าพารามิเตอร์ที่เป็นไปได้ แล้วหาพารามิเตอร์ที่เหมาะสมที่สุดที่จะนำมาใช้ในการศึกษาครั้งนี้ เพื่อให้ Model ที่ได้มีประสิทธิภาพและมีค่าความคลาดเคลื่อนต่ำที่สุด ผลลัพธ์ที่ได้ดังตาราง 6-5

ตารางที่ 6-5 ค่าพารามิเตอร์ที่เหมาะสม

Model	Parameter	RMSE
K-NN	Method : als. K : 15 Similarity : Cosine	1.05889
SVD	N_epochs : 20 lr_all : 0.007 Reg_all : 0.4	1.04192

วิธีการกรองแบบร่วมกันโดยพิจารณาผู้ใช้เป็นหลัก (User-Based Collaborative Filtering) วิธีนี้จะใช้ประวัติการให้คะแนนของลูกค้ำที่เคยซื้อสินค้าในอดีต และข้อมูลของลูกค้ำคนอื่นมาพิจารณาร่วมด้วย ใช้เทคนิค K-Nearest Neighbors ในการหาลูกค้ำที่มีการให้คะแนนเมนูอาหารใกล้เคียงกันมากที่สุดมาพิจารณา โดยใช้ Cosine Similarity มาหาความเหมือนของข้อมูลจากเวกเตอร์การให้คะแนน Rating ของลูกค้ำแต่ละคน จะได้ค่า Similarity Score ที่บอกว่าข้อมูลมีความเหมือนกันเท่าไร จากนั้นหาค่า Predicted Rating โดยคำนวณจากลูกค้ำคนอื่นที่มีค่า Similarity Score สูง และแนะนำเมนูอาหารที่มีค่า Predicted Rating สูงตามลำดับ N ที่กำหนดให้กับลูกค้ำเป้าหมาย

วิธีการกรองแบบร่วมกันโดยพิจารณาสินค้าเป็นหลัก (Item-Based Collaborative Filtering) ใช้เทคนิค K-Nearest Neighbors ในการหาเมนูอาหารที่ถูกให้คะแนนใกล้เคียงกับเมนูที่ลูกค้ำเป้าหมายเคยให้คะแนนสูงไว้ในอดีต หรือมีความชื่นชอบมาก มาหาเมนูอาหารที่ลูกค้ำเป้าหมายน่าจะชอบ โดยใช้ Cosine Similarity มาหาความเหมือนกับเมนูอื่นทั้งหมด จากเวกเตอร์การให้ Rating เมนูที่ลูกค้ำเป้าหมายเคยให้คะแนนไว้สูง จะได้ค่า Similarity Score ที่บอกว่าเมนูมีความเหมือนกันเท่าไร จากนั้นหาค่า Predicted Rating โดยคำนวณจากเมนูอื่นที่มีค่า Similarity Score สูง และแนะนำเมนูที่มี Predicted Rating สูงตามลำดับ N ที่กำหนดให้กับลูกค้ำเป้าหมาย

Singular Value Decomposition (SVD) อัลกอริทึมนี้จะใช้หลักการ Matrix Factorization ในการหาค่า Predicted Rating โดยการแยกองค์ประกอบของเมทริกซ์ผู้ใช้ออกเป็นเมทริกซ์ย่อย ด้วย Matrix Factorization และหาค่าพารามิเตอร์ที่จะทำให้เมื่อทำการ Dot product กลับไปจะทำให้ได้ค่าใกล้เคียงกับเมทริกซ์ดั้งเดิมมากที่สุด โดยค่าที่ได้จะมีค่า Rating ของเมนูอาหารที่ลูกค้ำไม่เคยให้คะแนนมาก่อน และเลือกแนะนำเมนูที่มีค่า Predicted Rating สูงให้กับลูกค้ำเป้าหมาย

6.3.2 ระบบแนะนำเมนูแบบไม่เฉพาะบุคคล (สำหรับลูกค้าใหม่และลูกค้าทั่วไปที่ไม่ได้เป็นสมาชิก)

ในการแนะนำเมนูอาหารทั่วไปสำหรับลูกค้าใหม่และลูกค้าทั่วไปที่ไม่ได้เป็นสมาชิก จะใช้วิธีการกรองแบบร่วมกันโดยพิจารณาสินค้าเป็นหลัก (Item-Based Collaborative Filtering) โดยจะไม่นำคะแนน Rating มาใช้ในการวิเคราะห์ด้วย แต่จะเป็นการวิเคราะห์ความสัมพันธ์ของคู่เมนูอาหารที่ถูกสั่งภายในออเดอร์เดียวกัน โดยใช้ Cosine Similarity ในการวัด มีขั้นตอนดังนี้

1. เนื่องจากไม่ได้ใช้ข้อมูลคะแนน Rating จึงนำข้อมูล Receipt Number มาใช้ในการวิเคราะห์โดยทำการรวมจำนวนเมนูแต่ละรายการที่ถูกสั่งภายในออเดอร์นั้นๆ จำนวนทั้งสิ้น 14,401 รายการ
2. จากนั้นนำข้อมูลมาทำ Pivot Table โดยที่ Row ของข้อมูลคือ Receipt Number และ Column คือ เมนูอาหารทั้งหมด 164 รายการ และทำการตัด Receipt ที่ซ้ำ เนื่องจากเป็นการกรองแบบร่วมกันโดยพิจารณาสินค้าเป็นหลัก
3. ทำการสร้างเมทริกซ์เมนูอาหารโดยที่ทั้ง Row และ Column คือเมนูอาหารทั้งหมดที่มี จะได้เมทริกซ์ขนาด 164 x 164
4. จากนั้นคำนวณหาค่า Cosine Similarity และนำค่าที่ได้ใส่ไว้ในเมทริกซ์ที่เมนูอาหารที่สร้างไว้ในขั้นตอนก่อนหน้านี้ ผลลัพธ์ที่ได้คือค่าความเหมือน ของเมนูอาหารว่าใกล้เคียงกับเมนูใด
5. นำค่า Cosine Similarity มาเรียงลำดับจากมากไปหาน้อย โดยคู่เมนูที่มีค่ามาก จะหมายความว่า เมนู 2 ชนิดนี้มีความสัมพันธ์กันมาก โดยหากลูกค้าซื้อเมนูใดเมนูหนึ่ง จะแนะนำอีกเมนูหนึ่งให้กับลูกค้าด้วย

7. ผลการศึกษา

7.1. ระบบแนะนำเมนูอาหารเฉพาะบุคคล (สำหรับลูกค้าที่เป็นสมาชิก)

ผลลัพธ์ในการทดสอบ และเปรียบเทียบประสิทธิภาพระบบแนะนำเมนูอาหารเฉพาะบุคคล (สำหรับลูกค้าที่เป็นสมาชิก) แสดงได้ดังตารางที่ 7-1 เป็นการแสดงความแม่นยำในการแนะนำเมนูอาหาร โดยพิจารณาจากค่า MAP และ MAR ในการแนะนำเมนูอาหาร 5 อันดับ พบว่า วิธีการกรองแบบร่วมกันโดยพิจารณาสินค้าเป็นหลัก (User-Based Collaborative Filtering) โดยใช้อัลกอริทึม K-Nearest Neighbors เป็นการสร้างระบบแนะนำเมนูอาหารที่มีประสิทธิภาพมากที่สุด โดยพบว่าในแต่ละจำนวน k ที่แนะนำเมนูอาหารตั้งแต่ 1-5 อัลกอริทึมคัดกรองผู้ใช้จะให้ค่าเฉลี่ยของความแม่นยำเฉลี่ยสูงที่สุด ในส่วนของอัลกอริทึมคัดกรองสิ่งของ (Item Based Collaborative Filtering) และ Singular Value Decomposition (SVD) ค่าที่ได้ให้ผลที่ไม่แตกต่างกันมากนัก

ตารางที่ 7-1 ตารางเปรียบเทียบค่า MAP และ MAR ของระบบแนะนำด้วยวิธีการกรองแบบต่างๆ

Model	User-Based (KNN)		Item-Based (KNN)		Singular Value Decomposition (SVD)	
	MAP	MAR	MAP	MAR	MAP	MAR
1	0.2578	0.4388	0.0750	0.3679	0.1078	0.3480
2	0.1973	0.4434	0.1032	0.4031	0.1078	0.4023
3	0.1899	0.4899	0.1000	0.4122	0.1017	0.4173

4	0.1776	0.5059	0.097	0.4076	0.0960	0.4313
5	0.1723	0.5431	0.0889	0.4529	0.0963	0.4539

7.2. ระบบแนะนำเมนูอาหารแบบไม่เฉพาะบุคคล (สำหรับลูกค้าใหม่และลูกค้าทั่วไปที่ไม่ได้เป็นสมาชิก)

จากตารางที่ 7-2 พบว่า เมนูซูชิเซ็ตแซลมอนเบียร์นิกิริและSushi Set มีค่า Similarity Score สูงที่สุด คือ 0.7827 หมายความว่าเมนูทั้ง 2 ชนิดนี้ เป็นคู่เมนูที่มีความสัมพันธ์กันมาก สังเกตได้ว่าค่าที่ได้ในแต่ละลำดับนั้นไม่ได้ต่างกันมาก ผู้ประกอบการร้านอาหารอาจจะใช้ประโยชน์จากการจับคู่เมนูอาหารดังกล่าวในการแนะนำเมนูให้กับลูกค้าที่ยังไม่เคยมีประวัติกับทางร้าน หรือลูกค้าทั่วไป โดยเมื่อมีลูกค้าซื้อเมนูหนึ่ง เราก็สามารถแนะนำอีกเมนูหนึ่งให้กับลูกค้าได้เช่นกัน หรือการจัดกิจกรรมส่งเสริมการขายแบบ Bundle Promotion ซึ่งคู่ถูกกว่า โดยเอาคู่เมนูอาหารมาจัดโปรโมชั่นโดยดูจากค่าความสัมพันธ์กันหรือ Similarity Score ได้

ตารางที่ 7-2 ค่าความสัมพันธ์ของคู่เมนูอาหาร Top-5

ลำดับ	เมนูที่ 1	เมนูที่ 2	Similarity
1	ซูชิเซ็ตแซลมอนเบียร์นิกิริ	Sushi Set	0.7827
2	แซลมอนซาซิมิ L	Sushi Set	0.7631
3	ทาโกยากิ	Sushi Set	0.7466
4	ข้าวราดแกงกะหรี่	Sushi Set	0.7410
5	ข้าวไข่ข้น	Sushi Set	0.7304

8. สรุปและอภิปรายผลการศึกษา

ในการศึกษาครั้งนี้มีเป้าหมายเพื่อเป็นแนวทางในการสร้างและพัฒนาระบบแนะนำสำหรับร้านอาหาร โดยพยายามหาแนวทางใน 2 มิติ คือ 1.) การสร้างระบบแนะนำแบบเฉพาะบุคคล เพื่อให้สามารถแนะนำเมนูอาหารได้ตรงกับ ความชอบและรสนิยมของลูกค้าแต่ละคนได้ พบว่า อัลกอริทึมที่ใช้สำหรับระบบแนะนำด้วยวิธีการกรองแบบร่วมกันที่มี ประสิทธิภาพมากที่สุด คือ ระบบแนะนำแบบคัดกรองผู้ใช้ (User-Based Collaborative Filtering) โดยมีค่า MAP@5 เท่ากับ 0.1723 หมายความว่า ในการแนะนำเมนูอาหารแนะนำ 5 อันดับแรก โดยเฉลี่ยอัลกอริทึมสามารถแนะนำได้ตรงกับ เมนูอาหารที่ลูกค้าเป้าหมายน่าจะชอบในอนาคตตาม Testing data ได้ 17.23% และ MAR@5 เท่ากับ 0.5431 หมายความว่า ในบรรดาเมนูอาหารที่อยู่ใน Testing data อัลกอริทึมสามารถแนะนำได้ตรง 54.31% และ 2.) การสร้าง ระบบแนะนำแบบไม่เฉพาะบุคคล การศึกษาในส่วนนี้เพื่อเป็นแนวทางให้กับผู้ประกอบการร้านอาหาร ในการสร้าง กิจกรรมส่งเสริมการขายสำหรับลูกค้าที่ใหม่ไม่เคยมีประวัติสมาชิกกับทางร้าน โดยใช้ระบบแนะนำแบบคัดกรองผู้ใช้ (Item Based Collaborative Filtering) เพื่อหาความเหมือนของคู่เมนูอาหารภายในออเดอร์เดียวกัน ด้วยการหาค่า Cosine Similarity ผลลัพธ์ที่ได้พบว่า ซูชิเซ็ตแซลมอนเบียร์นิกิริและ Sushi Set มีค่า Similarity Score สูงที่สุด คือ 0.7827 หมายความว่าเมนูทั้ง 2 ชนิดนี้ เป็นคู่เมนูที่มีความสัมพันธ์กันมากที่สุด โดยสามารถสังเกตได้ว่าผลการศึกษามีความ เหมือนกันมากที่สุด 5 อันดับแรก จะพบเมนู Sushi Set อยู่ในทุกลำดับ ซึ่งหมายความว่า ลูกค้ามักจะซื้อ Sushi Set คู่กับ

เมนูอื่นๆ ซึ่งผลการศึกษาที่พบนี้ สามารถนำไปใช้เป็นแนวทางให้ผู้ประกอบการนำข้อมูลที่ได้ไปประยุกต์ใช้ในการแนะนำเมนูให้กับลูกค้า เช่น หากต้องการจัดโปรโมชั่นเพื่อกระตุ้นยอดขาย เมนูที่ควรนำมาพิจารณาใช้ทำโปรโมชั่นคือ Sushi Set ในการจับคู่กับเมนูอื่นๆ และขายในราคาพิเศษ หรือหากลูกค้าเลือกซื้อเมนูใดเมนูหนึ่ง ทางร้านสามารถแนะนำอีกเมนูให้กับลูกค้าโดยพิจารณาจากค่า Cosine Similarity ได้ ในการจัดกิจกรรมส่งเสริมการตลาดแบบนี้ เป็นการนำเอาพฤติกรรมของลูกค้าในอดีตมาสังเคราะห์ข้อมูลและสร้างเป็นโปรโมชั่นที่สามารถตอบสนองต่อความต้องการของลูกค้าที่แตกต่างกันไปในแต่ละกลุ่มหรือบุคคลได้ดีมากยิ่งขึ้น

9. ข้อเสนอแนะ

งานวิจัยนี้เป็นตัวอย่างในการประยุกต์แนวคิดทางด้านการวิเคราะห์ข้อมูลที่ใช้ในการแนะนำเมนูอาหาร เพื่อหาแนวทางที่มีประสิทธิภาพมากที่สุด เพื่อให้ผู้ประกอบการร้านอาหารได้มีแนวทางในการนำเอาข้อมูลการขายย้อนหลังมาวิเคราะห์เพื่อให้สามารถออกแบบกิจกรรมส่งเสริมการขายหรือการสร้างโปรโมชั่น ได้ตรงกับความต้องการของลูกค้าได้มากที่สุด

สำหรับงานวิจัยในอนาคต งานวิจัยนี้เป็นการใช้ Implicit Rating หรือ Rating จากการคาดเดาพฤติกรรมของลูกค้า เนื่องจากทางร้านไม่ได้มีการเก็บข้อมูลในส่วนนี้โดยตรง หากสามารถเก็บข้อมูลการให้คะแนนของลูกค้าที่มีต่อเมนูอาหารจานหนึ่งได้ตรงๆ ประสิทธิภาพของระบบแนะนำอาจสูงขึ้นได้ และจากผลการทดลองที่ได้ในครั้งนี้นั้น หากสามารถนำผลลัพธ์ที่ได้ไปทดลองแนะนำเมนูอาหารให้กับลูกค้าเป้าหมายได้จริง และสามารถวัดค่าการตอบสนองได้ จะทำให้งานวิจัยสมบูรณ์มากยิ่งขึ้น

10 .เอกสารอ้างอิง

Bayu Yudha Pratama, Indra Budi, Arlisa Yuliawati (2020). Product Recommendation in Offline Retail Industry by using Collaborative Filtering. (*IJACSA*) *International Journal of Advanced Computer Science and Applications*, Vol. 11, No. 9.

Sarwar, B., Karypis, G., Konstan, J., and Riedl, J. (2001). Incremental singular value decomposition algorithms for highly scalable recommender systems. *Proceedings of the 10th international conference on World Wide Web*, 285-295.

Sawtelle, S. (2020). Mean Average Precision (MAP) For Recommender Systems. Retrieved June 30, 2021, from <https://sdsawtelle.github.io/blog/output/mean-average-precision-MAP-for-recommender-systems.html>

Shani, G., Gunawardana A. (2011) Evaluating Recommendation Systems. In: Ricci F., Rokach L., Shapira B., Kantor P. (eds) *Recommender Systems Handbook*. Springer, Boston, MA. https://doi.org/10.1007/978-0-387-85820-3_8.

ศุจินทร ทรงสิทธิเดช, ณกร อินทร์พยุง (2019). การสังเคราะห์ข้อมูลสำหรับแนะนำเมนูอาหาร. คณะโลจิสติกส์ มหาวิทยาลัยบูรพา

ศูนย์วิจัยกสิกรไทย 2563. ธุรกิจร้านอาหารเผชิญกับโจทย์ท้าทายสูง และรูปแบบการแข่งขันที่เปลี่ยนไป. [ออนไลน์].
สืบค้นจาก https://www.kasikornresearch.com/th/analysis/k_econ/business/Pages/z3067.aspx (วันที่สืบค้น 30 มิถุนายน 2564).