โครงการ

การเรียนการสอนเพื่อเสริมประสบการณ์

ชื่อโครงการ การปรับปรุงเครือข่ายประสาทเทียมตามหลักการของระบบแนะนำบนข้อมูลที่มีลำดับโดยใช้ความสัมพันธ์ของผู้ใช้ในส่วนของกระบวนการกรองแบบร่วม

Improving Neural Network based Recommendation System on Temporal data using user relation in Collaborative Filtering part

ชื่อนิสิต นายศุภพัฒน์ นิรัตติวงศกรณ์ 583 36620 23

นางสาวปาณิสรา ศโรภาส 583 36425 23

ภาควิชา คณิตศาสตร์และวิทยาการคอมพิวเตอร์

สาขาวิชา วิทยาการคอมพิวเตอร์

ปีการศึกษา 2561

คณะวิทยาศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

บทคัดย่อและแฟ้มข้อมูลฉบับเต็มของโครงงานทางวิชาการที่ให้บริการในคลังปัญญาจุฬาฯ (CUIR)

เป็นแฟ้มข้อมูลของนิสิตเจ้าของโครงงานทางวิชาการที่ส่งผ่านทางคณะที่สังกัด

The abstract and full text of senior projects in Chulalongkorn University Intellectual Repository(CUIR)

are the senior project authors' files submitted through the faculty.

การปรับปรุงเครือข่ายประสาทเทียมตามหลักการของระบบแนะนำบนข้อมูลที่มีลำดับโดยใช้ความสัมพันธ์ของผู้ใช้ในส่วนของกระบวนการกรองแบบร่วม

นายศุภพัฒน์ นิรัตติวงศกรณ์
นางสาวปาณิสรา ศโรภาส

โครงงานนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรวิทยาศาสตรบัณฑิต
สาขาวิชาวิทยาการคอมพิวเตอร์ ภาควิชาคณิตศาสตร์และวิทยาการคอมพิวเตอร์
คณะวิทยาศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย
ปีการศึกษา 2561
ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

Improving Neural Network based Recommendation System on Temporal data using user relation in Collaborative Filtering part

Mr.Suppapat Nirattiwongsakorn
Ms.Panisara Sarophas

A Project Submitted in Partial Fulfillment of the Requirements
for the Degree of Bachelor of Science Program in Computer Science
Department of Mathematics and Computer Science
Faculty of Science
Chulalongkorn University
Academic Year 2018
Copyright of Chulalongkorn University

หัวข้อโครงงาน	การปรับปรุงเครือข่ายประสาทเทียมตามหลักการของระบบแนะนำ บนข้อมูลที่มีลำดับ โดยใช้ความสัมพันธ์ของผู้ใช้ในส่วนของกระบวนการกรองแบบร่วม
โดย	นายศุภพัฒน์ นิรัตติวงศกรณ์ นางสาวปาณิสรา ศโรภาส
สาขาวิชา	วิทยาการคอมพิวเตอร์
อาจารย์ที่ปรึกษาโครงงานหลัก	ผู้ช่วยศาสตราจารย์ ดร.ศรันญา มณีโรจน์

ภาควิชาคณิตศาสตร์และวิทยาการคอมพิวเตอร์ คณะวิทยาศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้นับโครงงานฉบับนี้เป็นส่วนหนึ่ง ของการศึกษาตามหลักสูตรปริญญาบัณฑิต ในรายวิชา 2301499 โครงงานวิทยาศาสตร์ (Senior Project)

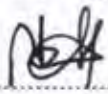

(ศาสตราจารย์ ดร.กฤษณะ เนียมมณี) หัวหน้าภาควิชาคณิตศาสตร์และวิทยาการคอมพิวเตอร์

คณะกรรมการสอบโครงงาน

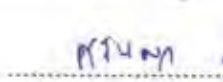

(ผู้ช่วยศาสตราจารย์ ดร.ศรันญา มณีโรจน์) อาจารย์ที่ปรึกษาโครงงานหลัก

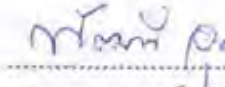

(ศาสตราจารย์ ดร.พัฒนี อุดมกะวานิช) กรรมการ

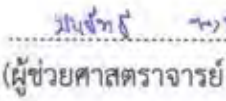

(ผู้ช่วยศาสตราจารย์ ดร.มนนัทธ์ พงษ์พานิช) กรรมการ

ศุภพัฒน์ นิรัตติวงศกรณ์, ปาณิสรา ศโรภาส: การปรับปรุงเครือข่ายประสาทเทียมตามหลักการของระบบแนะนำ บนข้อมูลที่มีลำดับ โดยใช้ความสัมพันธ์ของผู้ใช้ในส่วนของกระบวนการกรองแบบร่วม. (Improving Neural Network based Recommendation System on Temporal data using user relation in Collaborative Filtering part) อ.ที่ปรึกษาโครงงานหลัก : ผศ.ดร.ศรันญา มณีโรจน์, 50 หน้า.

ในปัจจุบันระบบแนะนำได้เข้ามามีส่วนช่วยในการแนะนำสินค้า และบริการต่าง ๆ ให้กับผู้ใช้ เพื่อให้ผู้ขายสินค้าสามารถนำเสนอสินค้าที่ตนมีได้ดียิ่งขึ้น และช่วยให้ผู้ซื้อได้สินค้าที่เหมาะกับตนเอง โดยทั่วไปวิธีการที่ใช้ในระบบแนะนำสามารถจำแนกได้เป็นสองวิธีพื้นฐานคือเทคนิคการคัดกรองแบบอิงเนื้อหา (Content-based) และเทคนิคการคัดกรองแบบร่วม (Collaborative Filtering) สำหรับวิธีเทคนิคการคัดกรองแบบอิงเนื้อหา (Content-based) จะเลือกแนะนำโดยพิจารณาจากการนำคุณลักษณะของสินค้าที่ผู้ใช้เคยเห็นหรือเคยใช้ ซึ่งจะมีข้อจำกัดที่จะไม่มีการแนะนำสินค้าประเภทอื่นที่ผู้ใช้ไม่เคยใช้ ส่วนเทคนิคการคัดกรองแบบร่วม (Collaborative Filtering) จะเลือกแนะนำโดยการนำข้อมูลของเพื่อน (ผู้ใช้รายอื่น ๆ ในระบบที่มีมาลักษณะความชอบที่คล้ายคลึงกับผู้ใช้เป้าหมาย) นั่นคือการนำคะแนนความชอบต่อสินค้าของเพื่อนในระบบที่ได้ให้ไว้ค่อนข้างสูงมาช่วยในการวิเคราะห์ จากนั้นจึงทำการแนะนำสินค้าใหม่ที่มีความหลากหลายให้แก่ผู้ใช้เป้าหมาย แต่ข้อกำจัดของเทคนิคนี้คือในระบบจะต้องมีจำนวนผู้ใช้ที่เพียงพอเพื่อให้ระบบสามารถค้นหาเพื่อนที่มีลักษณะความชอบที่ใกล้เคียงกับผู้ใช้เป้าหมายได้

ปัจจุบันมีงานวิจัยที่มีการนำ Neural network หรือเครือข่ายประสาทเทียมเข้ามาช่วยทำการวิเคราะห์และทำนายผล เนื่องจากเครือข่ายประสาทเทียมนี้ช่วยเพิ่มความสามารถให้คอมพิวเตอร์สามารถวิเคราะห์ข้อมูลที่มีความซับซ้อนได้ มาใช้ในระบบแนะนำ โดยระบบแนะนำบนเครือข่ายประสาทเทียมส่วนใหญ่จะแบ่งออกเป็นสองฝั่งคือฝั่งผู้ใช้และฝั่งสินค้า โดยทางฝั่งผู้ใช้เลือกใช้เทคนิคการกรองแบบอิงเนื้อหาเพื่อค้นหาสินค้าที่ผู้ใช้เป้าหมายมีแนวโน้มว่าจะชอบต่อไปจากสินค้าที่ผู้ใช้เป้าหมายเคยใช้ และทางฝั่งสินค้าเลือกใช้เทคนิคการกรองแบบร่วมเพื่อค้นหาสินค้าที่ผู้ใช้เป้าหมายมีแนวโน้มว่าจะชอบต่อไปจากการข้อมูลการใช้สินค้าของเพื่อน แต่ในปัจจุบันเครือข่ายประสาทเทียมบนระบบแนะนำมีข้อจำกัดคือในฝั่งของสินค้าไม่มีการนำความสัมพันธ์ (Relation) ระหว่างผู้ใช้เป้าหมายและเพื่อนมาวิเคราะห์จึงอาจส่งผลให้ผลลัพธ์คลาดเคลื่อนได้ ดังนั้นในโครงงานนี้จะเสนอเครือข่ายประสาทเทียมตามหลักการของระบบแนะนำแบบใหม่โดยการปรับปรุงเครือข่ายประสาทเทียมในส่วนของการคัดกรองแบบร่วม โดยการนำค่าความสัมพันธ์ (Relation) ระหว่างผู้ใช้เข้ามาพิจารณา เพื่อให้ระบบแนะนำสามารถทำนายคะแนนความชอบของผู้ใช้ต่อสินค้าให้มีความคลาดเคลื่อนน้อยลง

ภาควิชา คณิตศาสตร์และวิทยาการคอมพิวเตอร์ ลายมือชื่อนิสิต ศุภพัฒน์ นิรัตติวงศกรณ์

ลายมือชื่อนิสิต ปาณิสรา ศโรภาส

สาขาวิชา วิทยาการคอมพิวเตอร์ ลายมือชื่อ อ.ที่ปรึกษาโครงงานหลัก ศรันญา มณีโรจน์

ปีการศึกษา 2561

5833662023, 5833642523: MAJOR COMPUTER SCIENCE
KEYWORDS : RECOMMENDATION SYSTEM / NEURAL NETWORK / USER RELATION / COLLABORATIVE FILTERING / CONTENT-BASED FILTERING

SUPPAPAT NIRATTIWONGSAKORN, MS.PANISARA SAROPHAS: IMPROVING NEURAL NETWORK BASED RECOMMENDATION SYSTEM ON TEMPORAL DATA USING USER RELATION IN COLLABORATIVE FILTERING PART. ADVISOR : ASST. PROF. SARANYA MANEEROJ, Ph.D., 50 pp.

In recent years, the recommendation systems have been widely used to help users discover items which they may like. Generally, recommendation systems have two types of filtering methods which are content-based filtering and collaborative filtering. Content-based filtering recommends the similar items which the users liked in the past by matching the attributes of a user profile and item profile. However, it still has limitations that it has never recommended items outside the past user preference. Another type of method is collaborative filtering which recommends items by using opinion of neighbors (users who have similar taste with the target user). Then the items liked by neighbors and the target user has never seen before can be recommended. But the limitations of this method are that it needs sufficient users and it can not recommend any item to someone with unique preference.

Nowadays, some recent works have applied Neural Network (NN) which is one of the machine learning algorithms and can handle with complicated data. Neural Network based recommendation usually has two sides. One is the user's side using content-based filtering to find the next interesting items based on target user's past preference. The other is a item's side using collaborative filtering to find the next interesting items that neighbors liked. However, the current Neural Network based recommendation methods have disadvantages that in the item's side they do not consider the relation between the target user and neighbors. This leads the results trend to be incorrect. In this work, we propose a new Neural Network based recommendation method by improving Neural Network on Collaborative Filtering part using additional information which is user relations.

Department : Mathematics and Computer Science Student's Signature สุภาพัฒน์ นิรัติวงศากร

Student's Signature ปานิสรา สโรภาส

Field of Study : Computer Science Advisor's Signature Saranya Maneeroj

Academic Year : 2018

กิตติกรรมประกาศ

การดำเนินงานวิจัยนี้สามารถประสบความสำเร็จลุล่วงไปได้ด้วยดี เนื่องจากผู้วิจัยได้รับความอนุเคราะห์ช่วยเหลือจากคณาจารย์ และบุคลากรต่าง ๆ หลายท่าน

ขอขอบพระคุณคณาจารย์ทุกท่านที่ได้ประสิทธิ์ประสาทวิชาความรู้ ให้คำสั่งสอนและคำชี้แนะต่าง ๆ จนส่งผลให้ผู้วิจัยสามารถดำเนินงานจนประสบความสำเร็จได้ด้วยดี นอกจากนั้นความรู้นี้ยังสามารถนำไปปรับใช้ได้ในการทำงาน หรือในการศึกษาต่อในอนาคตอีกด้วย

ขอขอบพระคุณผู้ช่วยศาสตราจารย์ ดร.ศรันญา มณีโรจน์ ซึ่งเป็นอาจารย์ที่ปรึกษาโครงงานวิจัยนี้ ที่ได้ให้คำปรึกษาในการทำโครงงานนี้

ขอขอบพระคุณคุณชารินทร์ พลภาณุมาศ ที่ได้ให้คำปรึกษาในการ Implement เครือข่ายประสาทเทียมเป็นอย่างดี

ขอขอบพระคุณศาสตราจารย์ ดร.พัฒนี อุดมกะวานิช และผู้ช่วยศาสตราจารย์ ดร.มนนัทธ์ พงษ์พานิช กรรมการของโครงงานวิจัยนี้ ที่ได้ให้คำแนะนำที่มีประโยชน์ยิ่งต่องานวิจัย

และที่ขาดไม่ได้ขอขอบพระคุณคุณพ่อ คุณแม่ และญาติพี่น้องทุกคน ที่ได้คอยดูแล และให้กำลังใจตลอดการศึกษาเล่าเรียนอยู่เสมอมา

ท้ายที่สุดนี้ ขอขอบคุณเพื่อน ๆ พี่ ๆ และน้อง ๆ ทุกคนที่คอยให้กำลังใจ รวมทั้งให้คำปรึกษาและช่วยแก้ไขปัญหาในเรื่องต่างๆ รวมถึงขอขอบคุณทุกท่านที่ไม่ได้กล่าวถึง ณ ที่นี้ ที่มีส่วนร่วมในการให้ความช่วยเหลือจนกระทั่งโครงงานนี้สำเร็จลุล่วงไปได้ด้วยดี

สารบัญ

หน้า

บทคัดย่อภาษาไทย ..... ง

บทคัดย่อภาษาอังกฤษ ..... จ

กิตติกรรมประกาศ ..... ฉ

สารบัญ ..... ช

สารบัญตาราง ..... ฌ

สารบัญภาพ ..... ญ

บทที่ 1 บทนำ 1

1.1 หลักการและเหตุผล 1

1.2 วัตถุประสงค์ของโครงงาน 4

1.3 ขอบเขตของโครงงาน 4

1.4 วิธีการดำเนินงาน 4

1.5 ประโยชน์ที่คาดว่าจะได้รับ 6

1.6 โครงสร้างของรายงาน 6

บทที่ 2 งานวิจัยที่เกี่ยวข้อง 7

2.1 ระบบการแนะนำ (Recommender System) 7

2.1.1 เทคนิคการกรองแบบร่วม (Collaborative Filtering) 7

2.1.2 เทคนิคการกรองแบบอิงเนื้อหา (Content-based Filtering) 9

2.2 การวิเคราะห์จัดกลุ่ม (Cluster Analysis) 10

2.2.1 เทคนิคการจัดกลุ่มแบบไม่เป็นขั้นตอน (K – Means Cluster Analysis) 10

2.3 โมเดลเครือข่ายประสาทเทียม (Neural network model) 11

2.4 เครือข่ายประสาทเทียม (Neural Network) บนระบบแนะนำ 13

2.4.1 Neural Collaborative Filtering 13

2.4.2 Interacting Attention-gated for Recommendation 13

บทที่ 3 วิธีการวิจัย 15

3.1 แผนการวิจัย 15

3.2 การศึกษาการ implement ระบบแนะนำบน Neural Network ด้วยไลบลารี่ Pytorch 16
3.2.1 คุณสมบัติหลักของ PyTorch 16
3.2.2 PyTorch Tensor 16
3.3 เสนอวิธีการ 16
3.3.1 ขั้นตอนที่ 1 สกัดหา Embeddings vector ของแต่ละ User และ Item เพื่อนำมาหา Charecteristic ของ User และ Item โดยใช้เครือข่ายประสาทเทียม 18
3.3.2 ขั้นตอนที่ 2 ทำการแบ่งกลุ่มผู้ใช้จากเวกเตอร์คุณลักษณะของผู้ใช้แต่ละคน 22
3.3.3 ขั้นตอนที่ 3 ทำการนำความสัมพันธ์ระหว่างผู้ใช้เข้ามาร่วมฝึกโมเดล 23
บทที่ 4 ผลการวิจัย 25
4.1 ชุดข้อมูล 25
4.2 วิธีที่ใช้ในการประเมินผล 26
4.2.1 ค่าเฉลี่ยของกำลังสองของความคลาดเคลื่อน (Mean Square Error, MSE) 26
4.2.2 ค่าเฉลี่ยของรากที่สองของกำลังสองของความคลาดเคลื่อน (Root Mean Square Error, RMSE) 26
4.3 ผลการทดลอง 27
4.3.1 ผลการทดลองจากชุดข้อมูล MovieLens 100K Dataset 27
4.3.2 ผลการทดลองจากชุดข้อมูล MovieLens 1m Dataset 28
บทที่ 5 ข้อสรุปและข้อเสนอแนะ 30
5.1 ข้อสรุป 30
5.2 ข้อเสนอแนะ 30
รายการอ้างอิง 31
ภาคผนวก ก แบบเสนอหัวข้อโครงงาน รายวิชา 2301399 Project Proposal ปีการศึกษา 2561 . 33
ประวัติผู้เขียน 40

สารบัญตาราง

หน้า

ตารางที่ 1.1 ตารางเวลาการดำเนินงาน 5
ตารางที่ 2.1 ตารางข้อดีและข้อเสียของเทคนิคที่ใช้ในระบบแนะนำ 9
ตารางที่ 3.1 ตารางแผนการดำเนินการ 15
ตารางที่ 4.1 ตารางข้อมูลของชุดข้อมูล 25
ตารางที่ 4.2 ตารางผลการทดลองจากชุดข้อมูล MovieLens 100K Dataset 27
ตารางที่ 4.3 ตารางผลการทดลองจากชุดข้อมูล MovieLens 1m Dataset 28

สารบัญภาพ

หน้า

ภาพที่ 1.1 แสดงตัวอย่างโครงสร้างของเครือข่ายประสาทเทียม 2
ภาพที่ 1.2 แสดงตัวอย่างโครงสร้างของเครือข่ายประสาทเทียมแบบย้อนกลับ 3
ภาพที่ 2.1 แสดงเทคนิคการกรองแบบร่วม (Collaborative Filtering) 8
ภาพที่ 2.2 แสดงเทคนิคการกรองแบบอิงเนื้อหา (Content-based Filtering) 9
ภาพที่ 2.3 แสดงตัวอย่างข้อมูลที่ทำการแบ่งกลุ่มโดยใช้ k-mean clustering 11
ภาพที่ 2.4 แสดงตัวอย่างข้อมูลที่ทำการแบ่งกลุ่มโดยใช้ k-mean clustering 11
ภาพที่ 2.5 แสดงตัวอย่างโครงสร้างของเครือข่ายประสาทเทียม 12
ภาพที่ 2.6 แสดงโมเดลการนำเครือข่ายประสาทเทียมมาใช้กับระบบแนะนำ 13
ภาพที่ 2.7 แสดงโมเดลการนำเครือข่ายประสาทเทียมมาใช้กับระบบแนะนำ
โดยมีการนำค่าความสัมพันธ์ระหว่างผู้ใช้กับสินค้ามาพิจารณา 14
ภาพที่ 3.1 แสดงภาพรวมของโมเดลที่เสนอ 17
ภาพที่ 3.2 แสดงภาพของโมเดลในขั้นตอนที่ 1 18
ภาพที่ 3.3 แสดงตัวอย่างข้อมูลจากชุดข้อมูล MovieLens 1m 18
ภาพที่ 3.4 แสดงสมการความสัมพันธ์แบบเชิงเส้น (Linear) 19
ภาพที่ 3.5 แสดงตัวอย่างฟังก์ชัน ReLU 20
ภาพที่ 3.6 แสดง Dropout layer 20
ภาพที่ 3.7 แสดงตัวอย่างฟังก์ชัน Sigmoid 21
ภาพที่ 3.8 แสดงตัวอย่างเวกเตอร์คุณลักษณะของผู้ใช้ 1 คน 21
ภาพที่ 3.9 แสดงตัวอย่างเวกเตอร์คุณลักษณะของภาพยนตร์ 1 เรื่อง 22
ภาพที่ 3.10 แสดงตัวอย่างค่าคะแนนของการแบ่งกลุ่มจาก เวกเตอร์ Embeddings
ของผู้ใช้ ตามจำนวนกลุ่ม 22
ภาพที่ 3.11 แสดงตัวอย่างของการแบ่งกลุ่มผู้ใช้ออกเป็น 5 กลุ่ม 23
ภาพที่ 3.12 แสดงภาพของโมเดลที่เสนอในขั้นตอนที่ 3 24
ภาพที่ 4.2 แสดงการทดลองจากชุดข้อมูล MovieLens 100K Dataset
โดยไม่นำความสัมพันธ์ระหว่างผู้ใช้มาพิจารณา 27
ภาพที่ 4.3 แสดงการทดลองจากชุดข้อมูล MovieLens 100K Dataset
โดยนำความสัมพันธ์ระหว่างผู้ใช้มาพิจารณา 28

บทที่ 1
บทนำ

1.1 หลักการและเหตุผล

ในปัจจุบันเทคโนโลยีต่าง ๆ ได้เข้ามามีบทบาทช่วยให้การซื้อขายสินค้าสะดวกมากยิ่งขึ้นและการซื้อขายสินค้าทางอินเตอร์เน็ตเกิดขึ้นอย่างแพร่หลาย ทำให้มีการเก็บประวัติการซื้อและการขายสินค้าอย่างเป็นระบบ ดังนั้นระบบแนะนำ (Recommender System) จึงเกิดขึ้นโดยมีจุดประสงค์เพื่อให้ผู้ขายสินค้า (หรือบริการ) สามารถนำเสนอสินค้าที่ตนมีได้ดียิ่งขึ้น และให้ผู้ซื้อได้สินค้าที่เหมาะกับตนเอง และในปัจจุบัน ระบบการแนะนำ (Recommender System) จึงเข้ามามีบทบาทเพื่อให้ผู้ขายสินค้าและผู้ซื้อได้รับผลประโยชน์สูงสุดทั้งสองฝ่าย นั่นคือผู้ขายสินค้าสามารถเสนอขายสินค้าของตนได้มากขึ้น และผู้ซื้อได้สินค้าที่ตรงกับความต้องการของตน

โดยทั่วไปวิธีการแนะนำที่ใช้ในระบบแนะนำสามารถจำแนกได้เป็นสองวิธีพื้นฐานคือเทคนิคการคัดกรองแบบอิงเนื้อหา (Content-based) และเทคนิคการคัดกรองแบบร่วม (Collaborative Filtering) สำหรับวิธีเทคนิคการคัดกรองแบบอิงเนื้อหา (Content-based) จะเลือกแนะนำโดยพิจารณาจากการนำคุณลักษณะของสินค้าที่ผู้ใช้เคยเห็นหรือเคยใช้มาก่อนมาทำการวิเคราะห์ว่าผู้ใช้รายนี้มีความสนใจสินค้าประเภทใด จากนั้นระบบจะทำการแนะนำสินค้าใหม่ที่มีคุณลักษณะตรงกับความสนใจของผู้ใช้รายนั้น ส่วนเทคนิคการคัดกรองแบบร่วม (Collaborative Filtering) จะเลือกแนะนำโดยการนำข้อมูลของผู้ใช้รายอื่น ๆ ในระบบที่มีลักษณะความชอบที่คล้ายคลึงกับผู้ใช้เป้าหมาย ซึ่งจะเรียกผู้ใช้รายอื่นว่าเพื่อน แล้วจึงนำคะแนนความชอบต่อสินค้าของเพื่อนที่ได้ให้ไว้ค่อนข้างสูงมาช่วยในการวิเคราะห์และทำการแนะนำสินค้าใหม่ให้แก่ผู้ใช้เป้าหมาย

ในการสร้างระบบการแนะนำ (Recommender System) มักนำการจำแนกประเภทของข้อมูล (Classification) ซึ่งมีป้ายกำกับ (Label) เพื่อทำการจำแนกข้อมูลลงในประเภทที่กำหนดไว้ เช่น ในระบบแนะนำเราสามารถจำแนกประเภทของผู้ใช้ที่มีต่อสินค้านั้นได้เป็นชอบและไม่ชอบ เป็นต้น

ที่ผ่านมาระบบจะนำคะแนนความชอบจากผู้ใช้มาทำการวิเคราะห์ แต่เนื่องจากต้องการสกัดหาคุณลักษณะของผู้ใช้และสินค้า (User and Item Characteristic) เพื่อนำมาหาความสัมพันธ์ (Relation) ระหว่างผู้ใช้และสินค้า เพราะฉะนั้นจึงมีผู้วิจัยทำการสร้างเวกเตอร์ (Embeded) เพื่อแสดงลักษณะของผู้ใช้และลักษณะของสินค้าขึ้น หลังจากได้เวกเตอร์ลักษณะของผู้ใช้และสินค้าแล้ว เวกเตอร์ดังกล่าวจะถูกนำมาเป็นข้อมูลนำเข้าของเครือข่ายประสาทเทียม (Neural Network)

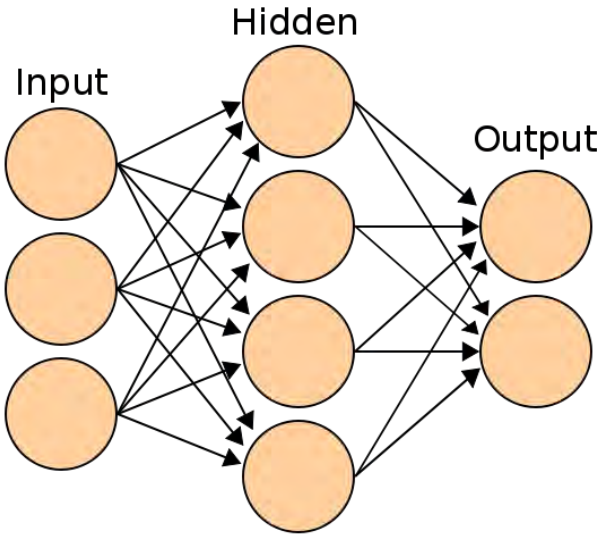

ภาพที่ 1.1 แสดงตัวอย่างโครงสร้างของเครือข่ายประสาทเทียม

การทำงานของเครือข่ายประสาทเทียม (Neural Network) คือเมื่อมี input เข้ามายังเครือข่าย (Network) ก็นำ input มาคูณกับค่าน้ำหนัก (Weight) ของแต่ละขา ผลที่ได้จาก input ทุก ๆ ขาของเซลล์ประสาท (Neuron) จะเอามารวมกันแล้วก็เอามาเทียบกับ Threshold ที่กำหนดไว้ ถ้าผลรวมมีค่ามากกว่า Threshold แล้วเซลล์ประสาท (Neuron) ก็จะส่ง output ออกไป output นี้ก็จะถูกส่งไปยัง input ของเซลล์ประสาท (Neuron) อื่น ๆ ที่เชื่อมกันในเครือข่าย (Network) ถ้าค่าน้อยกว่า Threshold ก็จะไม่เกิด output สิ่งสำคัญคือเราต้องทราบค่าน้ำหนัก (Weight) และ Threshold สำหรับสิ่งที่เราต้องการเพื่อให้คอมพิวเตอร์รู้จำ ซึ่งเป็นค่าที่ไม่แน่นอน แต่สามารถกำหนดให้คอมพิวเตอร์ปรับค่าเหล่านั้นได้โดยการสอนให้มันรู้จัก pattern ของสิ่งที่เราต้องการให้มันรู้จำ เรียกว่า "back propagation" ซึ่งเป็นกระบวนการย้อนกลับของการรู้จำ ในการฝึก feed-forward Neural Networks จะมีการใช้อัลกอริทึมแบบ back-propagation เพื่อใช้ในการปรับปรุงน้ำหนักคะแนนของเครือข่าย (Network Weight) หลังจากใส่รูปแบบข้อมูลสำหรับฝึกให้แก่เครือข่ายในแต่ละครั้งแล้ว ค่าที่ได้รับ (output) จากเครือข่ายจะถูกนำไปเปรียบเทียบกับผลที่คาดหวัง แล้วทำการคำนวณหาค่าความผิดพลาด ซึ่งค่าความผิดพลาดนี้จะถูกส่งกลับเข้าสู่เครือข่ายเพื่อใช้แก้ไขค่าน้ำหนักคะแนนต่อไป

เครือข่ายประสาทเทียมแบบย้อนกลับ (Recurrent neural network หรือ RNN) เป็นเครือข่ายประสาทเทียมที่เชื่อมต่อระหว่างโหนดเป็นกราฟที่มีลำดับ ซึ่งทำให้สามารถแสดงพฤติกรรมตามลำดับเวลาได้แบบชั่วขณะ RNN สามารถใช้ประมวลผลลำดับของข้อมูล ซึ่งเหมาะสำหรับข้อมูลที่เป็นลำดับ เช่น การจดจำลายมือหรือการจดจำเสียงพูด

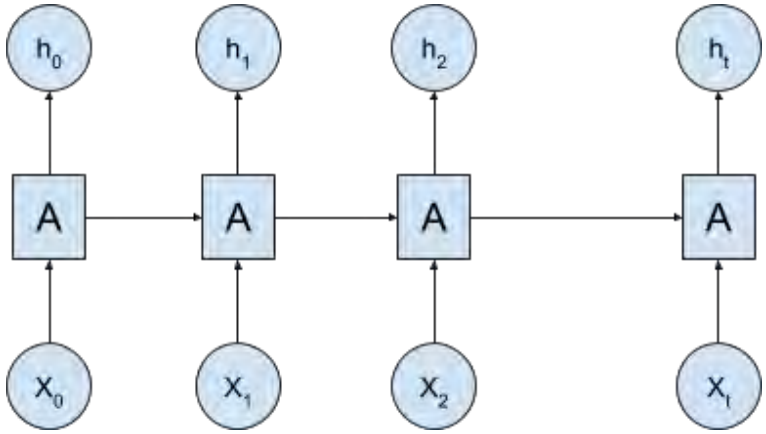

ภาพที่ 1.2 แสดงตัวอย่างโครงสร้างของเครือข่ายประสาทเทียมแบบย้อนกลับ

การทำงานคือเอาผลลัพธ์ที่ได้จากการคำนวณย้อนกลับมาใช้เป็นข้อมูลขาเข้าอีกครั้ง ในแต่ละ node ของ RNN จะมีข้อมูลขาเข้าสองอย่างอันได้แก่ input ณ node นั้น ๆ และผลลัพธ์ที่ได้จากการคำนวณใน node ก่อนหน้า ซึ่งทั้งสองข้อมูลจะถูกนำมารวมเข้าด้วยกันและออกผลลัพธ์มาเป็นสองทางคือ ผลลัพธ์ที่ออก ณ node นั้น ๆ และออกเพื่อไปเข้าเป็นข้อมูลขาเข้าใน node ถัดไป

โดยปกติการนำ RNN มาใช้ในระบบแนะนำ มักจะเป็น content based คือการเปรียบเทียบลำดับของสินค้าที่ผู้ใช้เป้าหมายเคยใช้เท่านั้น ซึ่งจะมีข้อเสีย คือ ไม่หลากหลาย เพราะข้อมูลที่นำมาแนะนำผู้ใช้มีเพียงของผู้ใช้เป้าหมายรายเดียวเท่านั้น ไม่ได้นำข้อมูลของผู้ใช้รายอื่นๆมาวิเคราะห์ด้วย

เนื่องจากการเก็บประวัติของผู้ใช้มักมีการเก็บข้อมูลแบบจัดลำดับ หรือเก็บข้อมูลตามเวลาที่ใช้งาน ดังนั้นเครือข่ายประสาทเทียมแบบวนซ้ำ (Recurrent Neural Network) จึงเหมาะที่จะนำมาวิเคราะห์ข้อมูลที่มีการจัดข้อมูลตามลำดับเวลา และสามารถนำเสนอข้อมูลต่างๆ ตามช่วงเวลาได้ แต่การนำประวัติของผู้ใช้แต่ละรายมาทำการวิเคราะห์อย่างเดียวมีข้อเสียคือทำให้ไม่มีความหลากหลาย ยกตัวอย่างเช่น หากผู้ใช้ซื้อแต่สินค้าประเภทเครื่องใช้ไฟฟ้า ระบบแนะนำก็จะแนะนำเฉพาะสินค้าประเภทนี้เท่านั้น เช่น x_0 คือตู้เย็น x_1 คือพัดลม x_2 คือไมโครเวฟ output คือออกมาย่อมเป็นสินค้าประเภทเครื่องใช้ไฟฟ้า ส่วนสินค้าประเภทอื่นเช่น อุปกรณ์ตกแต่งบ้าน จะไม่ปรากฏออกมาเป็นค่า output จึงมีงานวิจัยพยายามแก้ไขปัญหานี้คือต้องการให้การแนะนำนั้นมีความหลากหลายมากขึ้น นักวิจัยเหล่านั้นจึงพยายามรวมเทคนิคการคัดกรองแบบอิงเนื้อหา (Content-based) และเทคนิคการคัดกรองแบบร่วม (Collaborative Filtering) โดยได้แบ่งเครือข่ายประสาทเทียมแบบวนซ้ำ (recurrent nueral network) ออกเป็น 2 ฝั่งเพื่อทำการวิเคราะห์หาคุณลักษณะของผู้ใช้ (characteristic of user) โดยใช้เทคนิคการคัดกรองแบบอิงเนื้อหา (Content-based) คือนำสินค้าที่ผู้ใช้เป้าหมายเคยใช้โดยเรียงลำดับตามเวลามาวิเคราะห์ตามลำดับเวลา และหาคุณลักษณะของสินค้า (Feature of item) โดยใช้เทคนิคการคัดกรองแบบร่วม (Collaborative Filtering) คือนำคะแนนที่ผู้ใช้ทั้งหมดในระบบเคยให้คะแนนสินค้านั้นมาวิเคราะห์ เนื่องจากแต่ละฝั่งถูกคำนวณแยกจึงทำให้ไม่สามารถหาความสัมพันธ์ระหว่างผู้ใช้กับสินค้าได้

ดังนั้นงานวิจัยของ Weijie pei, et al.[7] จึงได้เสนอวิธีการหาความสัมพันธ์ระหว่างผู้ใช้กับสินค้าขึ้นมา เพื่อทำให้ผู้ใช้ได้สินค้าที่ตรงกับลักษณะความชอบได้ดียิ่ง โดยมองค่าน้ำหนัก (weight)

เป็นค่าความสนใจ (attention) หากผู้ใช้มีแนวโน้มสนใจสินค้าประเภทนั้นค่าน้ำหนักจะสูงขึ้น ในทำนองเดียวกันหากผู้ใชมีแนวโน้มว่าไม่ค่อยสนใจสินค้าประเภทนั้นค่าน้ำหนักจะต่ำลง และในการหาค่าความสนใจนี้ควรนำค่าความสนใจที่ได้ในแต่ละฝั่งมาทำการวิเคราะห์ร่วมกัน ทำให้ระบบสามารถบอกได้ว่าในแต่ละช่วงเวลาผู้ใช้มีความชอบหรือสนใจสินค้าประเภทใด แต่ข้อเสียของงานนี้คือในฝั่งเทคนิคการคัดกรองแบบร่วม (Collaborative Filtering) นั้นมีการนำคะแนนความชอบของทุกคนมาวิเคราะห์ โดยไม่มีการคำนึงว่าผู้ใช้อื่นๆ ที่ให้คะแนนสินค้านี้มีลักษณะความชอบคล้ายคลึงกับผู้ใช้เป้าหมายหรือไม่ ยกตัวอย่างเช่น ผู้ใช้ a ให้คะแนนสินค้านี้ไว้สูงมาก ซึ่งจะเห็นได้ว่าผู้ใช้ a กับผู้ใช้เป้าหมายมีความพึงพอใจในสินค้าในลักษณะตรงข้ามกัน ดังนั้นถ้ามีการนำคะแนนของผู้ใช้ a มาคำนวณด้วย จะทำให้ผลลัพธ์คลาดเคลื่อน

ดังนั้นทางทีมวิจัยจึงสนใจที่จะทำการศึกษาวิธีการที่สามารถคัดกรองเพื่อนเพื่อให้เพื่อนคือกลุ่มของคนที่มีความพึงพอใจในสินค้าคล้ายกับผู้ใช้เป้าหมายมาวิเคราะห์ โดยทางทีมวิจัยจะคำนึงถึงค่าระดับ (Level) ของความสัมพันธ์ (Relation) ระหว่างเพื่อนและผู้ใช้เป้าหมายมาวิเคราะห์สำหรับการปรับค่าและฝึนฝนเครือข่ายประสาทเทียม

1.2 วัตถุประสงค์ของโครงงาน

เพื่อทำการศึกษาและวิเคราะห์ผลของการใช้เครือข่ายประสาทเทียม โดยมีการหาความสัมพันธ์ระหว่างผู้ใช้เป้าหมายกับผู้ใช้รายอื่นในระบบ เพื่อให้การแนะนำสินค้ามีความหลากหลายและสามารถแนะนำสินค้าแก่ผู้ใช้ได้ตรงกับความต้องการ ด้วยการทดลองและปรับปรุงเครือข่ายประสาทเทียมตามหลักการของระบบแนะนำบนข้อมูลที่มีลำดับ โดยใช้ความสัมพันธ์ของผู้ใช้ในส่วนของกระบวนการกรองแบบร่วม

1.3 ขอบเขตของโครงงาน

ทดสอบระบบแนะนำโดยใช้ชุดข้อมูลการให้คะแนนความชอบของผู้ใช้ที่มีต่อภาพยนตร์ชื่อ MovieLens ขนาด 100,000 รายการ และ 1,000,209 รายการ โดยรายการหมายถึงการที่ผู้ใช้ให้คะแนนสินค้าต่อครั้ง

1.4 วิธีการดำเนินงาน

การปรับปรุงเครือข่ายประสาทเทียมตามหลักการของระบบแนะนำ บนข้อมูลที่มีลำดับ โดยใช้ความสัมพันธ์ของผู้ใช้ในส่วนของกระบวนการกรองแบบร่วม มีขั้นตอนการดำเนินการดังต่อไปนี้

1. ศึกษาการงานวิจัยที่เกี่ยวข้องกับระบบแนะนำ
2. ศึกษาการทำงานของระบบแนะนำ
3. วิเคราะห์หาจุดเด่นจุดด้อยจากงานวิจัยที่เกี่ยวข้องกับระบบแนะนำ
4. ศึกษาเครื่องมือในการพัฒนาระบบแนะนำ
5. วิเคราะห์และออกแบบระบบแนะนำ
6. พัฒนาระบบแนะนำ
7. ตรวจสอบความถูกต้องของระบบและแก้ไขข้อผิดพลาด
8. ประเมินผลที่ได้จากการพัฒนา
9. สรุปและจัดทำเอกสาร

ตารางเวลาการดำเนินงาน

เริ่มดำเนินงานตั้งแต่เดือนสิงหาคม 2561 ถึงเดือนเมษายน 2562 โดยมีตารางเวลาการดำเนินงาน ดังนี้

ตารางที่ 1.1 ตารางเวลาการดำเนินงาน

ปี	2561					2562			
เดือน	8	9	10	11	12	1	2	3	4
1. ศึกษาการงานวิจัยที่เกี่ยวข้องกับระบบแนะนำ	◄	►							
2. ศึกษาการทำงานของระบบแนะนำ		◄	►						
3. วิเคราะห์หาจุดเด่นจุดด้อยจากงานวิจัยที่เกี่ยวข้องกับระบบแนะนำ			◄	►					
4. ศึกษาเครื่องมือในการพัฒนาระบบแนะนำ			◄	►					
5. วิเคราะห์และออกแบบระบบแนะนำ			◄	►	►				
6. พัฒนาระบบแนะนำ				◄	►	►	►		
7. ตรวจสอบความถูกต้องของระบบและแก้ไขข้อผิดพลาด					◄	►	►		
8. ประเมินผลที่ได้จากการพัฒนา						◄	►	►	
9. สรุปและจัดทำเอกสาร								◄	►

1.5 ประโยชน์ที่คาดว่าจะได้รับ

ประโยชน์ที่ได้รับจากการปรับปรุงเครือข่ายประสาทเทียมตามหลักการของระบบแนะนำ บนข้อมูลที่มีลำดับ โดยใช้ความสัมพันธ์ของผู้ใช้ในส่วนของกระบวนการกรองแบบร่วมในครั้งนี้มีดังนี้

1. ประโยชน์ต่อผู้ใช้งาน
   - 1.1 ผู้ซื้อสินค้าจะได้รับการแนะนำสินค้าที่มีความหลากหลายและแม่นยำมากยิ่งขึ้น
   - 1.2 ผู้ซื้อสินค้าจะเพลิดเพลินกับการเลือกซื้อสินค้าที่มีเหมาะสมและตรงกับความสนใจ
   - 1.3 ผู้ขายสินค้าสามารถนำเสนอสินค้าที่ตรงกับความสนใจของผู้ซื้อได้ดียิ่งขึ้น
   - 1.4 ผู้ขายสินค้าสามารถเพิ่มยอดขายได้จากการแนะนำสินค้าที่ตรงกับความต้องการของผู้ซื้อ

2.ประโยชน์ต่อผู้พัฒนาระบบ
   - 2.1 ได้เรียนรู้การทำระบบแนะนำสินค้า
   - 2.2 ได้เรียนรู้เทคนิคต่างๆ ที่ใช้สำหรับการทำระบบแนะนำ
   - 2.3 ได้ฝึกวางแผนการทำงานอย่างมีขั้นตอน
   - 2.4 ได้ฝึกรับมือและแก้ไขปัญหาที่เกิดขึ้นระหว่างดำเนินงาน
   - 2.5 ได้ฝึกการใช้เครื่องมือต่าง ๆ ที่นำมาวิเคราะห์ข้อมูล

1.6 โครงสร้างของรายงาน

บทที่ 2 จะกล่าวถึงงานวิจัยที่เกี่ยวข้อง

บทที่ 3 จะกล่าวถึงวิธีการวิจัย ซึ่งจะประกอบไปด้วยการขั้นตอนการวิจัย การศึกษาการ Implement และการเสนอขั้นตอนวิธี

บทที่ 4 จะกล่าวถึงการทดสอบประสิทธิภาพของวิธีที่เสนอ

บทที่ 5 จะกล่าวถึงข้อสรุป และข้อเสนอแนะ

บทที่ 2
งานวิจัยที่เกี่ยวข้อง

ในบทนี้จะกล่าวถึงงานที่เกี่ยวข้องโดยเริ่มจากการอธิบายเกี่ยวกับระบบแนะนำ (Recommender System หรือ RS) ซึ่งจะพูดถึงแนวคิดที่ใช้ในการสร้างระบบแนะนำ จากนั้นจะอธิบายเรื่องการจัดแบ่งประเภทของข้อมูล (Cluster Analysis) ต่อด้วยโมเดลเครือข่ายประสาทเทียม (Neural Network model) ซึ่งเป็นโมเดลที่กำลังเป็นที่นิยมในการนำมาวิเคราะห์ข้อมูลในปัจจุบัน ตามด้วยงานวิจัยที่เกี่ยวข้องซึ่งเป็นการนำโมเดลเครือข่ายประสาทเทียมมาประยุกต์กับเทคนิคการคัดกรองแบบร่วมของระบบแนะนำ

2.1 ระบบการแนะนำ (Recommender System)

การแนะนำสินค้ามีจุดประสงค์เพื่อให้ผู้ขายสินค้า (หรือบริการ) สามารถนำเสนอสินค้าที่ตนมีได้ให้ตรงกับความต้องการของผู้ซื้อได้ดียิ่งขึ้น ระบบการแนะนำจึงเข้ามามีบทบาทเพื่อให้ผู้ขายสินค้าและผู้ซื้อได้รับผลประโยชน์สูงสุดทั้งสองฝ่าย โดยทั่วไปวิธีการแนะนำที่ใช้ในระบบแนะนำสามารถจำแนกได้เป็นสองวิธีพื้นฐานคือเทคนิคการคัดกรองแบบร่วม (Collaborative Filtering) และเทคนิคการกรองแบบอิงเนื้อหา (Content-based Filtering) ซึ่งจะอธิบายด้านล่างดังนี้

2.1.1 เทคนิคการกรองแบบร่วม (Collaborative Filtering)

เป็นกระบวนการกรองที่ใช้ความคิดเห็นหรือคะแนนความพึงพอใจของผู้ใชหลาย ๆ คนมาช่วยทำการวิเคราะห์ โดยจะมีการค้นหากลุ่มผู้ใช้รายอื่นๆ ที่มีความชอบที่ใกล้เคียงกันกับผู้ใช้เป้าหมายที่ระบบต้องการทำการแนะนำสินค้าให้ ซึ่งมีการทำงานคือ ระบบจะเลือกแนะนำสินค้าโดยการนำข้อมูลของผู้ใช้รายอื่น ๆ ในระบบที่มีลักษณะความชอบคล้ายคลึงกับผู้ใช้เป้าหมายซึ่งจะเรียกผู้ใช้รายอื่นนี้ว่าเพื่อน (Neighbor) จากนั้นระบบจะเลือกนำคะแนนความชอบที่เพื่อนได้เคยให้คะแนนไว้ โดยเลือกเฉพาะคะแนนต่อสินค้าที่มีคะแนนค่อนข้างสูงมาช่วยในการวิเคราะห์และทำการแนะนำสินค้าใหม่ให้แก่ผู้ใช้เป้าหมาย

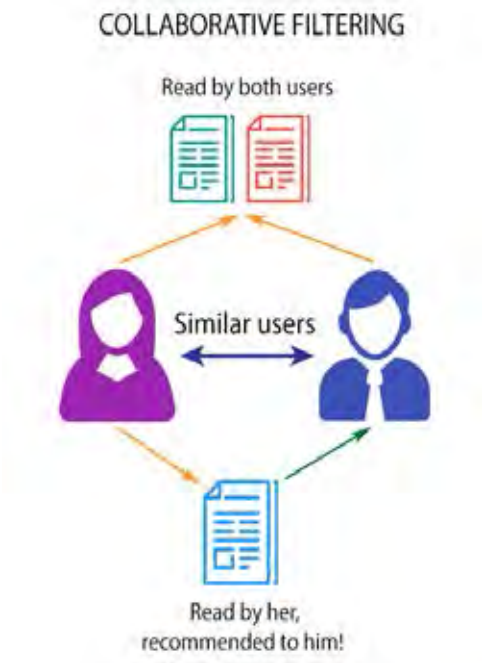

ภาพที่ 2.1 แสดงเทคนิคการกรองแบบร่วม (Collaborative Filtering)
(ที่มา: https://towardsdatascience.com/prototyping-a-recommender-system-step-by-step-part-1-knn-item-based-collaborative-filtering-637969614ea)

ความชอบที่ใกล้เคียงกันระหว่างผู้ใช้สามารถคำนวณได้จากความคล้ายคลึงสหสัมพันธ์ของเพียร์สัน(Pearson's Correlation) หรือความคล้ายคลึงโคไซน์ (cosine similarity) การหาค่าความสัมพันธ์ทั้งสองวิธีนั้น จะใช้ข้อมูลการให้คะแนนในอดีตของผู้ใช้ทั้งสอง โดยนำสินค้าที่ทั้งสองคนเคยให้คะแนนมาทำการคำนวณเพื่อดูว่าผู้ใช้ทั้งสองรายนี้ มีลักษณะความชอบคล้ายกันหรือไม่ ซึ่งความคล้ายคลึงสหสัมพันธ์ของเพียร์สัน (Pearson's Correlation) [2] สามารถหาได้จากสมการ

$$Corr(x,y) = \frac{\sum_{i=1}^{n}(x_i - \bar{x})\,(y_i - \bar{y})}{\sqrt{\sum_{i=1}^{n}(x_i - \bar{x})^2}\sqrt{\sum_{i=1}^{n}(y_i - \bar{y})^2}}$$

โดยที่ x คือ เวกเตอร์ของผู้ใช้หรือสินค้าที่ 1
y คือ เวกเตอร์ของผู้ใช้หรือสินค้าที่ 2

และการหาความคล้ายคลึงโคไซน์ (cosine similarity) สามารถหาได้จากสมการ

$$\cos(\theta) = \frac{A \cdot B}{\|A\|\|B\|} = \frac{\sum_{i=1}^{n} A_i \times B_i}{\sqrt{\sum_{i=1}^{n}(A_i)^2} \times \sqrt{\sum_{i=1}^{n}(B_i)^2}}$$

โดยที่ x คือ เวกเตอร์ของผู้ใช้หรือสินค้าที่ 1
y คือ เวกเตอร์ของผู้ใช้หรือสินค้าที่ 2

2.1.2 เทคนิคการกรองแบบอิงเนื้อหา (Content-based Filtering)

เป็นการบวนการกรองที่ให้ความสนใจกับเนื้อหาตามคุณลักษณะของข้อมูลของสินค้าเป็นหลัก โดยพิจารณาจากการนำคุณลักษณะของสินค้าที่ผู้ใช้เคยเห็นหรือเคยใช้มาก่อนมาทำการวิเคราะห์เพื่อดูว่าผู้ใช้เป้าหมายรายนี้มีความสนใจสินค้าในประเภทใด จากนั้นระบบจะทำการแสดงผลแนะนำสินค้าใหม่ที่มีคุณลักษณะตรงกับความสนใจของผู้ใช้รายนั้น ดังนั้นวิธีการนี้จึงเป็นการคำนวณหาคาความคล้ายคลึงกันระหว่างข้อมูลของสินค้ากับข้อมูลส่วนบุคคลของผู้ใช้ โดยการจับคู่ข้อมูลของสินค้ากับข้อมูลส่วนบุคคลของผู้ใช้นั้นเอง [6]

ภาพที่ 2.2 แสดงเทคนิคการกรองแบบอิงเนื้อหา (Content-based Filtering)

(ที่มา: https://towardsdatascience.com/prototyping-a-recommender-system-step-by-step-part-1-knn-item-based-collaborative-filtering-637969614ea)

ตารางแสดงข้อดีและข้อเสียของเทคนิคที่ใช้ในระบบแนะนำ

ตารางที่ 2.1 ตารางข้อดีและข้อเสียของเทคนิคที่ใช้ในระบบแนะนำ

	ข้อดี	ข้อเสีย
เทคนิคการกรองแบบร่วม (Collaborative Filtering)	1.ไม่จำเป็นต้องมีข้อมูลของสินค้า เช่น ประเภทหรือลักษณะของสินค้า เป็นต้น 2.ทำให้เกิดความหลากหลายในการแนะนำ	ต้องการผู้ใช้ในจำนวนที่เพียงพอ เนื่องจากระบบต้องทำการค้นหาเพื่อนที่มีความชอบคล้ายกับผู้ใช้
เทคนิคการคัดกรองแบบอิงเนื้อหา (Content-based Filtering)	1. สามารถแนะนำสินค้าได้ตรงกับลักษณะความชอบที่มีความเฉพาะกับผู้ใช้ 2. สามารถแนะนำสินค้าที่ไม่ค่อยได้รับความนิยมหรือสินค้าใหม่ได้ หากสินค้านั้นมีลักษณะตรงกับความชอบของผู้ใช้	ไม่สามารถแนะนำสินค้าที่มีลักษณะนอกเหนือจากประวัติที่ผู้ใช้เคยซื้อได้

2.2 การวิเคราะห์จัดกลุ่ม (Cluster Analysis)

Cluster Analysis เป็นเทคนิคที่ใช้จำแนกหรือแบ่ง Case หรือแบ่งตัวแปรออกเป็นกลุ่มย่อย ๆ ตั้งแต่ 2 กลุ่มขึ้นไป Case ที่อยู่ในกลุ่มเดียวกันจะมีลักษณะที่เหมือนกันหรือคล้ายกัน ส่วน Case ที่อยู่ต่างกลุ่มกัน จะมีลักษณะที่แตกต่างกัน ถ้านำเทคนิค Cluster Analysis มาใช้ในการแบ่งกลุ่มตัวแปร จะให้ตัวแปรอยู่ในกลุ่มเดียวกันมีความสัมพันธ์กันมากกว่าตัวแปรที่อยู่ต่างกลุ่มกัน ตัวแปรที่อยู่ต่างกลุ่มกันมีความสัมพันธ์กันน้อยหรือไม่มีความสัมพันธ์กันเลย โดยเทคนิค Cluster Analysis ที่นิยมใช้กันมากคือการวิเคราะห์กลุ่มแบบไม่เป็นขั้นตอน (Nonhierarchical Cluster Analysis หรือบางครั้งเรียกว่า K – Means Cluster Analysis) [6]

2.2.1 เทคนิคการจัดกลุ่มแบบไม่เป็นขั้นตอน (K – Means Cluster Analysis)

K-means Cluster Analysis คือ หนึ่งในอัลกอริทึมเทคนิคการเรียนรู้โดยไม่มีผู้สอนที่ง่ายที่สุด เพราะเป็นการแก้ปัญหาการจัดกลุ่มที่รู้จักกันทั่วไป โดยอัลกอริทึม K-Means จะตัดแบ่ง (Partition) วัตถุออกเป็น K กลุ่ม โดยแทนแต่ละกลุ่มด้วยค่าเฉลี่ยของกลุ่ม ซึ่งใช้เป็นจุดศูนย์กลาง (centroid) ของกลุ่มในการวัดระยะห่างของข้อมูลในกลุ่มเดียวกัน ในขั้นแรกของการจัดกลุ่มโดยการกำหนดจำนวนกลุ่ม (K) ที่ต้องการ และกำหนดจุดศูนย์กลางเริ่มต้นจำนวน K จุด สิ่งสำคัญในการกำหนดจุดศูนย์กลางเริ่มต้นของแต่ละกลุ่มนี้ ควรจะถูกกำหนดด้วยวิธีที่เหมาะสม เพราะตำแหน่งจุดศูนย์กลางเริ่มต้นที่แตกต่างกันทำให้ได้ผลลัพธ์สุดท้ายแตกต่างกัน ดังนั้นในทางที่ดีควรจะกำหนดจุดศูนย์กลางนี้ให้ห่างจากจุดศูนย์กลางอื่นๆ ขั้นตอนต่อไปคือสร้างกลุ่มข้อมูลและความสัมพันธ์กับจุดศูนย์กลางที่ใกล้มากที่สุด โดยแต่ละจุดจะถูกกำหนดไปยังจุดศูนย์กลางที่ใกล้เคียงที่สุดจนครบหมดทุกจุด และคำนวณจุดศูนย์กลางใหม่ โดยการหาค่าเฉลี่ยทุกวัตถุที่อยู่ในกลุ่ม หากจุดศูนย์กลางในแต่ละกลุ่มถูกเปลี่ยนตำแหน่ง จะได้จุดมีความสัมพันธ์กับกลุ่มใหม่และใกล้กับจุดศูนย์กลางใหม่ ทำซ้ำแบบนี้ไปเรื่อย ๆ จะสังเกตเห็นว่าผลลัพธ์จากการทำซ้ำแบบนี้ทำให้จุดศูนย์กลางเปลี่ยนตำแหน่งทุกรอบจนกระทั่งจุดศูนย์กลางจำนวน K จุด ไม่มีการเปลี่ยนแปลงจึงจะสิ้นสุด

ขั้นตอนการจัดกลุ่มโดย K-means

1. กำหนดจำนวนกลุ่ม K กลุ่ม และกำหนดจุดศูนย์กลางเริ่มต้นจำนวน K จุด
2. นำวัตถุทั้งหมดจัดเข้ากลุ่มที่มีจุดศูนย์กลางที่อยู่ใกล้วัตถุนั้นมากที่สุดโดยคำนวณจากการวัดระยะห่างระหว่างจุดที่น้อยที่สุด
3. คำนวณจุดศูนย์กลาง K จุดใหม่ โดยหาจากค่าเฉลี่ยทุกวัตถุที่อยู่ในกลุ่ม
4. ทำซ้ำในข้อ 2. จนกระทั่งจุดศูนย์กลางไม่เปลี่ยนแปลง

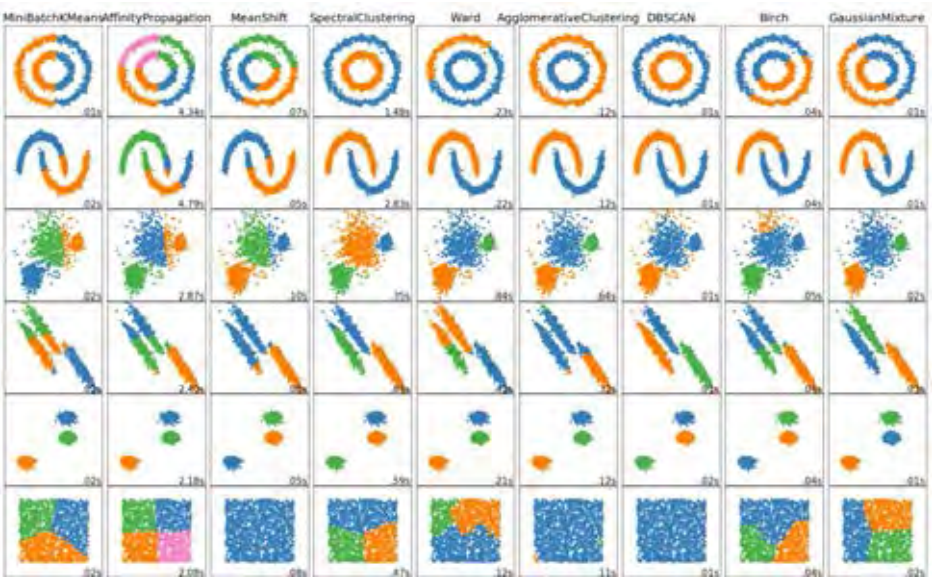

ภาพที่ 2.3 แสดงตัวอย่างข้อมูลที่ทำการแบ่งกลุ่มโดยใช้ k-mean clustering

(ที่มา: https://towardsdatascience.com/the-5-clustering-algorithms-data-scientists-need-to-know-a36d136ef68)

2.3 โมเดลเครือข่ายประสาทเทียม (Neural network model)

คือโมเดลที่จำลองการทำงานของเครือข่ายประสาทในสมองมนุษย์ด้วยวัตถุประสงค์ที่จะสร้างเครื่องมือซึ่งมีความสามารถในการเรียนรู้การจดจำรูปแบบ (Pattern Recognition) และการสร้างความรู้ใหม่ โดยในเครือข่ายประสาทในสมองของมนุษย์นั้นในประกอบด้วยเซลล์ประสาท (Nodes) แต่ละเซลล์ประสาทประกอบด้วยปลายในการรับกระแสประสาท เรียกว่า "เดนไดรท์" (Dendrite) ซึ่งเป็นข้อมูลขาเข้า (input) และปลายในการส่งกระแสประสาทเรียกว่า "แอคซอน" (Axon) ซึ่งเป็นเหมือนข้อมูลขาออก (output) ของเซลล์ [4]

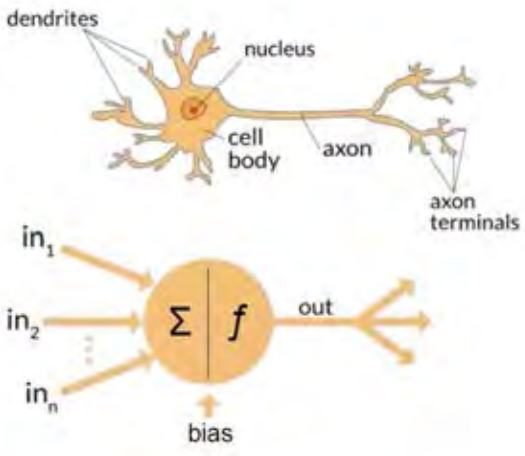

ภาพที่ 2.4 แสดงตัวอย่างข้อมูลที่ทำการแบ่งกลุ่มโดยใช้ k-mean clustering

(ที่มา: https://towardsdatascience.com/the-differences-between-artificial-and-biological-neural-networks-a8b46db828b7)

การทำงานของโมเดลเครือข่ายประสาทเทียมมีดังนี้ เมื่อมีข้อมูลขาเข้า (input) เข้ามายังเครือข่ายประสาทเทียม (network) เครือข่ายนี้จะนำข้อมูลขาเข้ามาคูณกับค่าน้ำหนัก (weight) ของแต่ละขา ผลลัพท์ที่ได้จากทุก ๆ ขาของเซลล์ประสาทจะเอามารวมกันแล้วก็เอามาเทียบกับที่กำหนดขึ้น (threshold) ถ้าผลรวมมีค่ามากกว่าค่าที่กำหนด เซลล์ประสาทจะส่งข้อมูลออกไปยังข้อมูลขาเข้าของเซลล์ประสาทอื่น ๆ ที่เชื่อมกันในเครือข่ายประสาทเทียม ถ้าค่าน้อยกว่าค่าที่กำหนดจะไม่มีการส่งข้อมูลออกไป ดังนั้นสิ่งสำคัญคือต้องทราบค่าน้ำหนัก (weight) และกำหนดค่า (threshold) ให้เหมาะสมกับสิ่งที่เราต้องการเพื่อให้คอมพิวเตอร์ และสามารถกำหนดให้คอมพิวเตอร์ปรับค่าเหล่านั้นได้โดยการสอนให้มันรู้จักรูปแบบ (pattern) ของสิ่งที่เราต้องการให้มันรู้จำ เรียกว่า "back propagation" ซึ่งเป็นกระบวนการเรียนรู้แบบย้อนกลับ ในการฝึกให้คอมพิวเตอร์มีการเรียนรู้แบบไปข้างหน้า (feed-forward Neural Networks) จะมีการใช้อัลกอริทึมแบบกระบวนการย้อนกลับของการรู้จำ เพื่อใช้ในการปรับค่าน้ำหนักคะแนนของเครือข่าย (Network Weight) หลังจากใส่รูปแบบข้อมูลสำหรับฝึกให้แก่เครือข่ายในแต่ละครั้งแล้ว ค่าที่ได้รับ (output) จากเครือข่ายจะถูกนำไปเปรียบเทียบกับผลที่คาดหวัง แล้วทำการคำนวณหาค่าความผิดพลาด ซึ่งค่าความผิดพลาดนี้จะถูกส่งกลับเข้าสู่เครือข่ายเพื่อใช้ในการปรับค่าน้ำหนักต่อไป

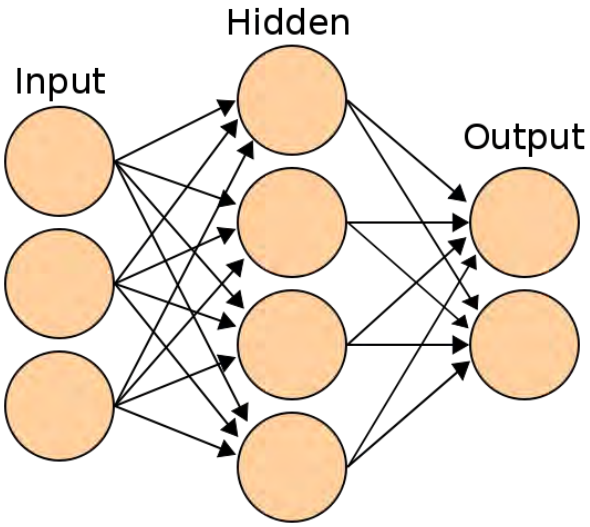

ภาพที่ 2.5 แสดงตัวอย่างโครงสร้างของเครือข่ายประสาทเทียม

2.4 เครือข่ายประสาทเทียม (Neural Network) บนระบบแนะนำ

ปัจจุบันมีงานวิจัยหลายงานที่ได้ทำการเสนอวิธีการโดยการนำระบบเครือข่ายประสาทเทียม (Neural Network) เข้ามาใช้กับระบบแนะนำ ตัวอย่างงานวิจัยเหล่านั้น เช่น

2.4.1 Neural Collaborative Filtering

งานวิจัยของ Xiangnan He, et al. [8] ได้เสนอการนำ Neural Network มาทำการวิเคราะห์บนระบบแนะนำโดยนำเทคนิคพื้นฐาน คือ เทคนิค Matrix Factorization ซึ่งทำให้สามารถหาคุณลักษณะของผู้ใช้และสินค้าได้ดีขึ้นกว่าการทำนายโดยใช้เทคนิค Matrix Factorization เพียงอย่างเดียว ดังภาพที่ 2.6 แต่ข้อจำกัดของงานวิจัยนี้คือยังไม่มีการนำประวัติการซื้อของผู้ใช้เข้ามาร่วมวิเคราะห์ด้วย จึงทำให้ระบบแนะนำอาจทำการแนะนำสินค้าที่ไม่มีความเฉพาะเจาะจงกับคุณลักษณะของผู้ใช้ (Characteristic of User) ส่งผลให้ผลการทดสอบโมเดลยังมีความคลาดเคลื่อนอยู่

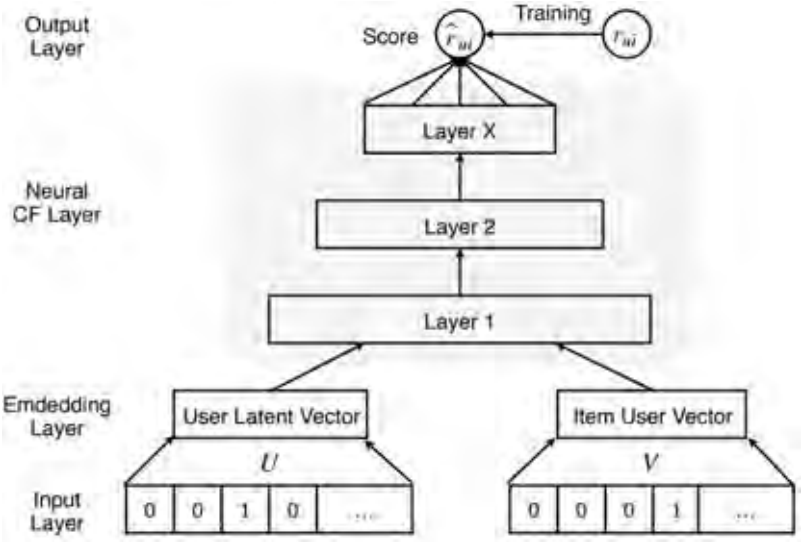

ภาพที่ 2.6 แสดงโมเดลการนำเครือข่ายประสาทเทียมมาใช้กับระบบแนะนำ

(ที่มา: https://www.researchgate.net/figure/Illustration-of-a-Neural-Collaborative-Filtering-b-CCCFNet-c-Wide-Deep_fig20_318671349?fbclid=IwAR2JkIZbiFaT9xA2PPuAJ1Lg3a_e3VTXOAbw5DjHZwpyLeawn_kmxy1_HBQ)

2.4.2 Interacting Attention-gated for Recommendation

จากข้อเสียจากงานวิจัยที่ยกตัวอย่างมาข้างต้น ทางทีมวิจัยของ Weijie pei, et al.[7] ได้เล็งเห็นว่าหากสามารถหาค่าความสัมพันธ์ระหว่างผู้ใช้กับสินค้าได้น่าจะช่วยให้โมเดลสามารถทำนายได้แม่นยำขึ้น ดังนั้นจึงได้เสนอโมเดลใหม่โดยใช้เทคนิคการคัดกรองแบบอิงเนื้อหา (Content-based) เข้ามาผสมกับเทคนิคการคัดกรองแบบร่วม (Collaborative Filtering) ดังนั้นเพื่อทำให้ระบบสามารถแนะนำภาพยนตร์ที่ตรงกับลักษณะความชอบได้ดียิ่ง นักวิจัยท่านนี้จึงมองค่าน้ำหนัก (weight) เป็นค่าความสนใจ (attention) และเสนอโมเดลดังภาพที่ 2.7 หากผู้ใช้มีแนวโน้มสนใจภาพยนตร์ประเภทนั้น

ค่าน้ำหนักจะสูงขึ้น ในทำนองเดียวกันหากผู้ใชมีแนวโน้มว่าไม่ค่อยสนใจภาพยนตร์ประเภทนั้นค่าน้ำหนักจะต่ำลง ทำให้ระบบสามารถบอกได้ว่าผู้ใช้มีความชอบหรือสนใจภาพยนตร์ประเภทใด

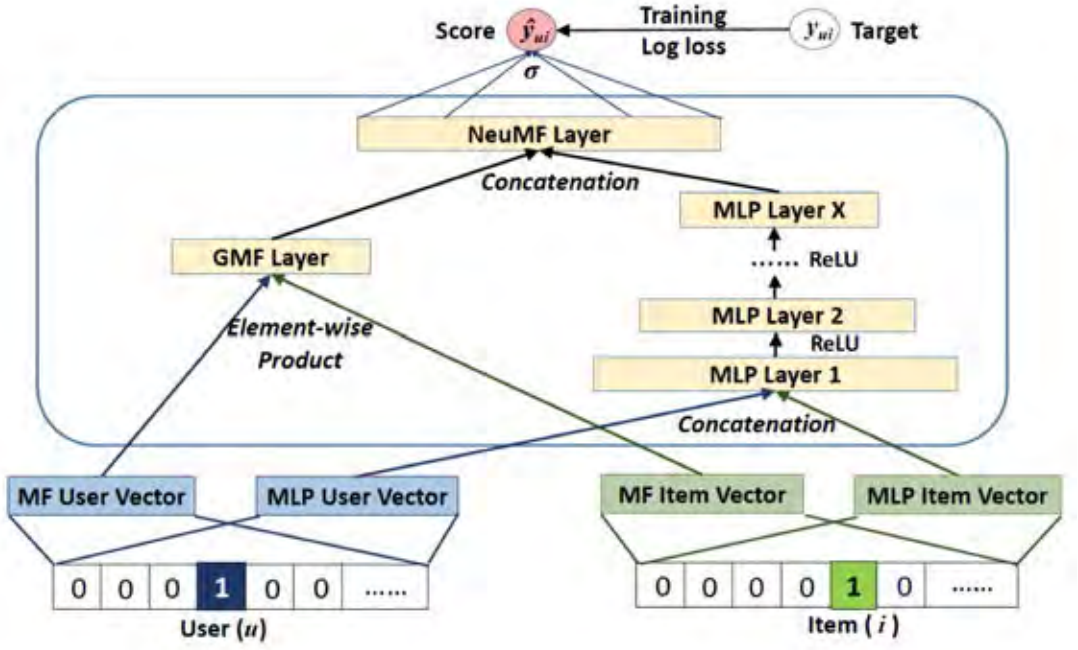

ภาพที่ 2.7 แสดงโมเดลการนำเครือข่ายประสาทเทียมมาใช้กับระบบแนะนำโดยมีการนำค่าความสัมพันธ์ระหว่างผู้ใช้กับสินค้ามาพิจารณา

(ที่มา: https://towardsdatascience.com/paper-review-neural-collaborative-filtering-explanation-implementation-ea3e031b7f96?fbclid=IwAR0zQ9ANKMxuxZ7cdDTiWaW5zW5ta8HkIqPYS8oHSXqJid5FmlsCsit3_K8)

ข้อจำกัดของ Neural Network in Recommendation จากงานวิจัยที่กล่าวไปข้างต้นนั้นคือในฝั่งเทคนิคการคัดกรองแบบร่วม (Collaborative Filtering) นั้นมีการนำคะแนนความชอบของทุกคนมาวิเคราะห์ โดยไม่มีการคำนึงว่าผู้ใช้อื่นๆ ที่ให้คะแนนความชอบต่อภาพยนตร์นี้มีลักษณะความชอบคล้ายคลึงกับผู้ใช้เป้าหมายหรือไม่ ยกตัวอย่างเช่น ผู้ใช้ a ให้คะแนนภาพยนตร์นี้ไว้สูงมาก แต่ผู้ใช้เป้าหมายให้คะแนนภาพยนตร์นี้ต่ำมาก จะเห็นได้ว่าผู้ใช้ a กับผู้ใช้เป้าหมายมีความพึงพอใจในภาพยนตร์ซึ่งมีรูปแบบที่แตกต่างกัน ดังนั้นหากมีการนำคะแนนของผู้ใช้ a มาร่วมคำนวณด้วย อาจทำให้ผลลัพธ์คลาดเคลื่อนได้ ดังนั้นผู้วิจัยจึงข้อเสนอวิธีปรับปรุงเครือข่ายประสาทเทียมโดยใช้ความสัมพันธ์ของผู้ใช้ในส่วนของกระบวนการกรองแบบร่วม โดยวิธีดังกล่าว จะขอกล่าวในบทที่ 3

บทที่ 3
วิธีการวิจัย

จากงานวิจัยทางด้าน Neuron Network Recommendation System พบว่ายังมีข้อเสียคือ ไม่มีการคำนึงว่าผู้ใช้อื่นๆ ที่ให้คะแนนสินค้านี้มีลักษณะความชอบคล้ายคลึงกับผู้ใช้เป้าหมายหรือไม่ ดังนั้นทางทีมวิจัยจึงสนใจที่จะทำการศึกษาวิธีการที่สามารถนำเฉพาะกลุ่มผู้ใช้ที่มีความเป็นเพื่อนนั้น คือกลุ่มของคนที่มีความพึงพอใจในสินค้าคล้ายกับผู้ใช้เป้าหมายมาวิเคราะห์ โดยทางทีมวิจัยจะคำนึงถึงค่าระดับ (Level) ของความสัมพันธ์ (Relation) ระหว่างเพื่อนและผู้ใช้เป้าหมายมาวิเคราะห์สำหรับการปรับค่าและฝึนฝนเครือข่ายประสาทเทียม

3.1 แผนการวิจัย

การดำเนินการวิจัยได้มีการกำหนดแผนการวิจัยเบื้องต้นดังตารางที่ 1 คือ

ตารางที่ 3.1 ตารางแผนการดำเนินการ

กิจกรรม	ผลผลิต
ศึกษางานวิจัยที่เกี่ยวข้อง	เข้าใจในระบบแนะนำ เครือข่ายประสาทเทียม และอื่น ๆ ที่เกี่ยวข้อง
ศึกษาการ implement ระบบแนะนำบน Neural Network	สามารถ implement เครือข่ายประสาทเทียมบนไลบลารี่ PyTorch ได้
สำรวจชุดข้อมูล	เข้าใจชุดข้อมูล
สร้างระบบแนะนำที่ไม่นำความสัมพันธ์ระหว่างผู้ใช้มาพิจารณา	ระบบแนะนำที่สามารถทำนายระดับคะแนนของผู้ใช้ต่อสินค้าได้
สร้างระบบแนะนำที่มีการนำความสัมพันธ์ระหว่างผู้ใช้มาพิจารณา	
เปรียบเทียบผล	ความแตกต่างของประสิทธิภาพจากระบบแนะนำทั้งสองประเภท

3.2 การศึกษาการ implement ระบบแนะนำบน Neural Network ด้วยไลบลารี่ Pytorch

PyTorch เป็น Deep Learning Library พัฒนาโดย Facebook บนภาษา Python จุดเด่นอยู่ที่การทำ Dynamic Computation และระบบการหาอนุพันธ์แบบ Automatic Differentiation [5]

3.2.1 คุณสมบัติหลักของ PyTorch

- การคำนวณ Tensor อย่างรวดเร็วด้วย GPU หรือกราฟฟิกการ์ด แทนการใช้งาน NumPy
- ความยืดหยุ่น และ ประมวลผลได้เร็วเพื่อนำไปใช้ทำ Deep Learning

3.2.2 PyTorch Tensor

ตัวแปรหลักที่ต้องใช้ในการคำนวณภายใน pytorch ทั้งหมดคือตัวแปรชนิดที่เรียกว่าเทนเซอร์ (Tensor) ซึ่งเทียบเท่าได้กับอาเรย์ภายใน numpy โดยสามารถมองตัวเลขให้อยู่ในรูปของเมทริกซ์ / ในรูปของตัวเลขได้

3.3 เสนอวิธีการ

ทางผู้วิจัยต้องการเสนอวิธีการใช้เครือข่ายประสาทเทียม ในระบบแนะนำ โดยการนำความสัมพันธ์ระหว่างผู้ใช้มาพิจารณา โดยแบ่งเป็น 3 ขั้นตอนหลัก ได้แก่

ขั้นตอนที่ 1 ขั้นตอนที่ 1 สกัดหา Embeddings vector ของแต่ละ User และ Item เพื่อนำมาหา Charecteristic ของ User และ Item โดยใช้เครือข่ายประสาทเทียม

ขั้นตอนที่ 2 ทำการแบ่งกลุ่มผู้ใช้จากเวกเตอร์คุณลักษณะของผู้ใช้แต่ละคน

ขั้นตอนที่ 3 ทำการนำความสัมพันธ์ระหว่างผู้ใช้เข้ามาร่วมฝึกโมเดล

ดังภาพที่ 3.1

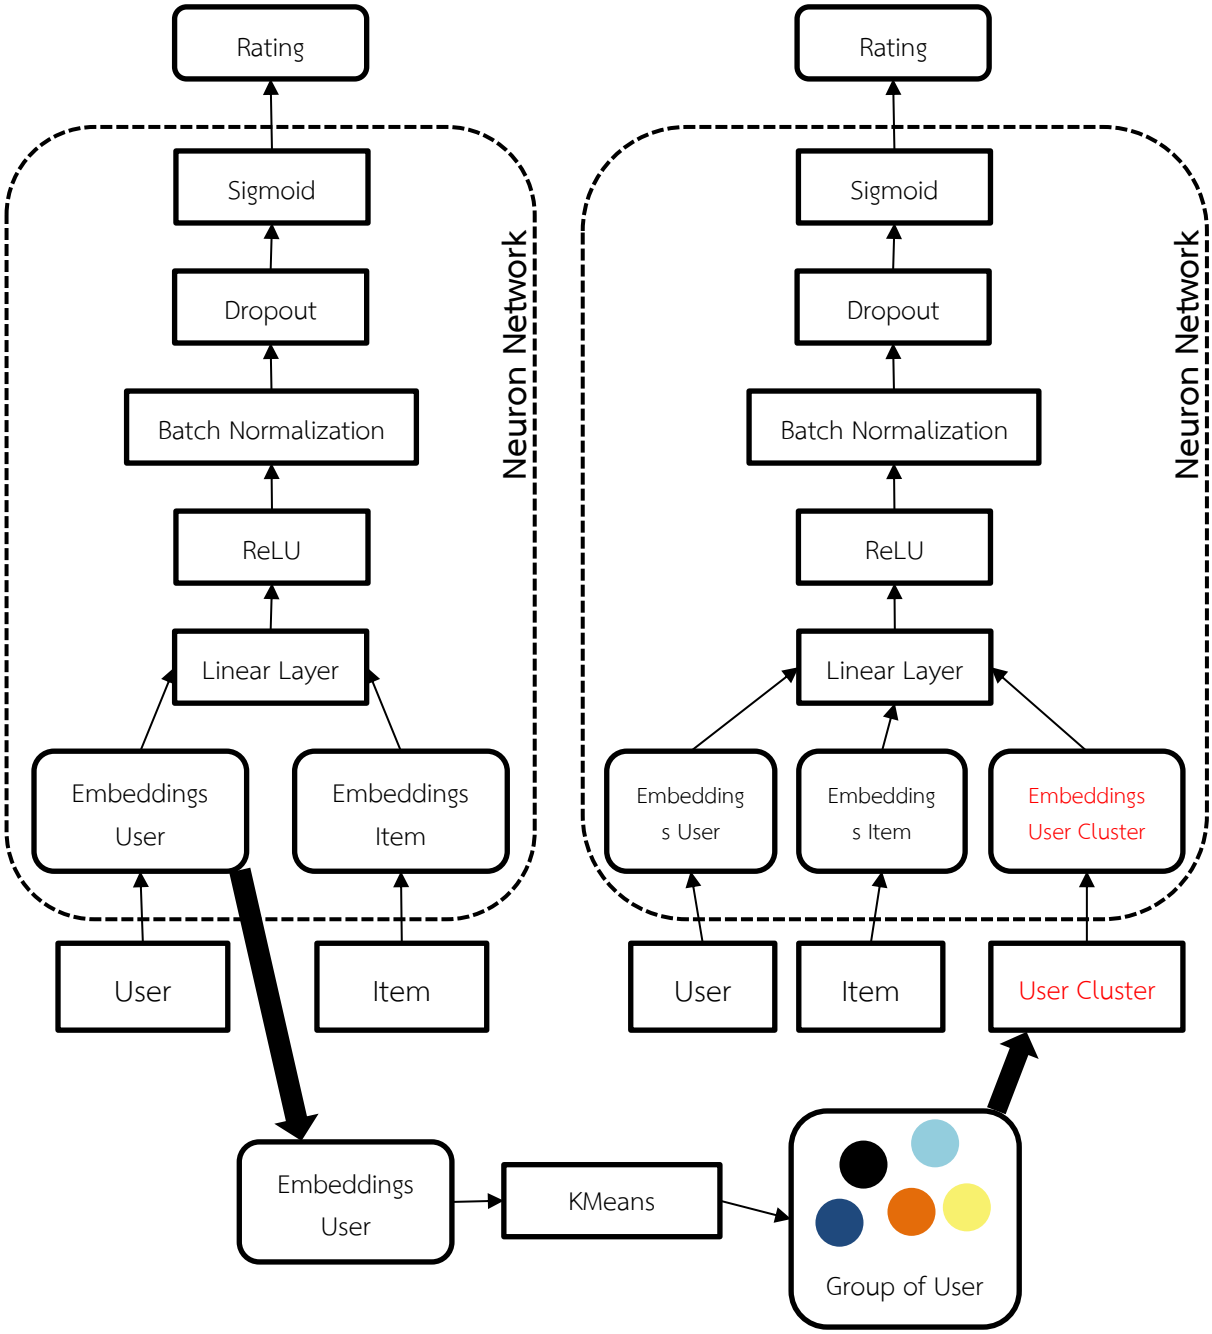

ภาพที่ 3.1 แสดงภาพรวมของโมเดลที่เสนอ

3.3.1 ขั้นตอนที่ 1 สกัดหา Embeddings vector ของแต่ละ User และ Item เพื่อนำมาหา Charecteristic ของ User และ Item โดยใช้เครือข่ายประสาทเทียม

มีวิธีการดังต่อไปนี้

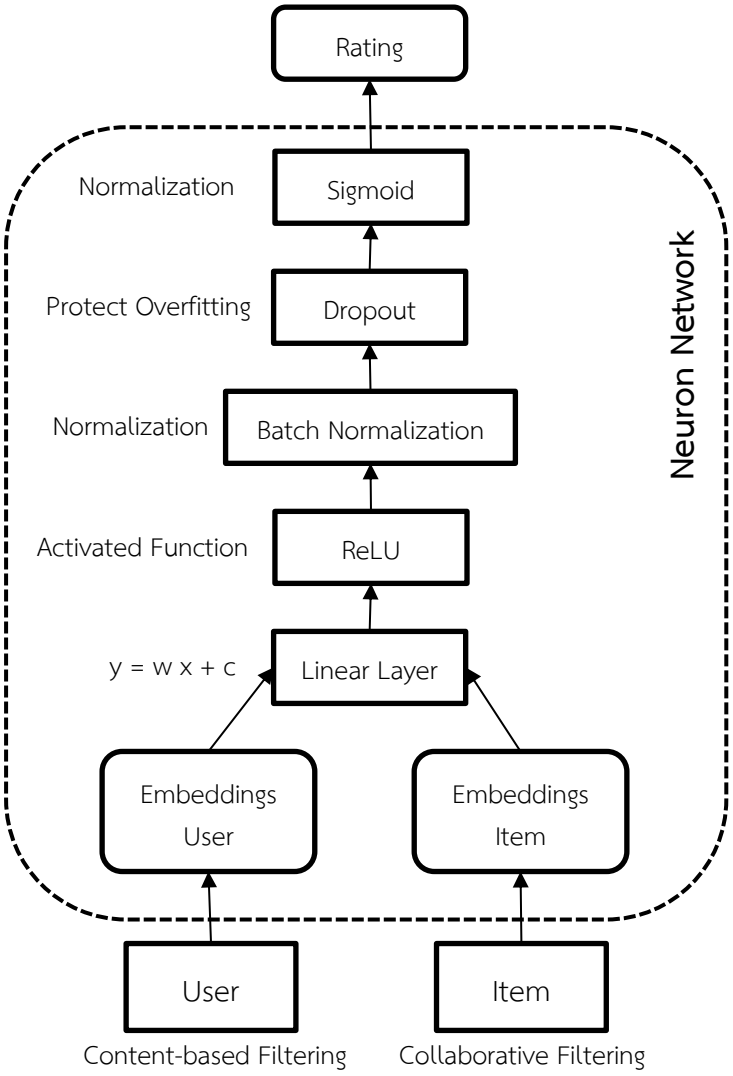

ภาพที่ 3.2 แสดงภาพของโมเดลในขั้นตอนที่ 1

3.3.1.1 นำเข้าข้อมูลจากชุดข้อมูล Movielens (Input Layers)

นำชุดข้อมูล Movielens จากไฟล์ข้อมูล ดังภาพที่ 3.3 มาสร้างเป็น Tensor ของผู้ใช้และภาพยนตร์เพื่อเตรียมข้อมูลให้พร้อมสำหรับการฝึกฝนเครือข่ายประสาทเทียมบนไลบารี่ Pytorch

	userId	movieId	rating	timestamp
0	1	1193	5	978300760
1	1	661	3	978302109
2	1	914	3	978301968
3	1	3408	4	978300275
4	1	2355	5	978824291

ภาพที่ 3.3 แสดงตัวอย่างข้อมูลจากชุดข้อมูล MovieLens 1m

3.3.1.2 สร้างเวกเตอร์ลักษณะเบื้องต้นของผู้ใช้และภาพยนตร์ (Embedding Layers)

ใน Layers นี้จะนำข้อมูลจาก 3.3.1.1 มาแปลงให้อยู่ในรูปเวกเตอร์ประจำตัวของผู้ใช้และภาพยนตร์ โดยกำหนดให้แต่ละเวกเตอร์มีขนาด 50 มิติ ซึ่งเวกเตอร์ดังกล่าวจะเป็นตัวบอกลักษณะของผู้ใช้ (User Characteristic) และ ลักษณะของภาพยนตร์ (Item Characteristic) โดยระบบจะนำเวกเตอร์ดังกล่าวมาใช้เพื่อปรับค่า ในช่วงฝึกข้อมูล (Trainning) บนเครือข่ายประสาทเทียม (Neural Network) จากนั้นนำเวกเตอร์ของผู้ใช้และภาพยนตร์มารวมกัน (Concatenate Layer) พร้อมทั้งกำหนดมิติของข้อมูลนำออกเป็นสเกลาร์ เพื่อส่งไปเป็นข้อมูลนำเข้าของ Layer ถัดไป

3.3.1.3 สร้างสมการเพื่อหาแนวโน้มของผู้ใช้ที่มีต่อภาพยนตร์ (Linear Layer)

โครงงานนี้เลือกใช้สมการความสัมพันธ์แบบเชิงเส้น (Linear) มาใช้ในการหาแนวโน้มคะแนนความชอบของผู้ใช้มีต่อภาพยนตร์ ซึ่งมาสมการดังนี้ $y = mx + c$ เมื่อ y คือค่าทำนายคะแนนความชอบของผู้ใช้มีต่อภาพยนตร์ x คือค่าสเกลาร์จาก 3.3.1.2 และ c คือค่า bias

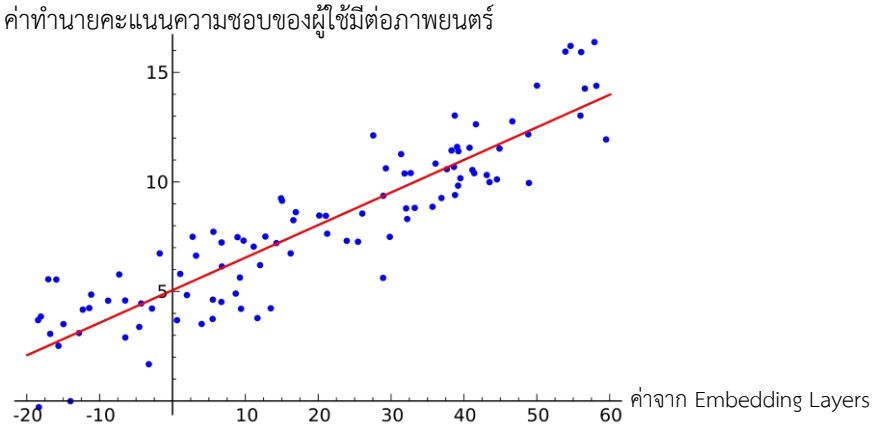

ภาพที่ 3.4 แสดงสมการความสัมพันธ์แบบเชิงเส้น (Linear)

(ที่มา: https://www.tailieu123.org/nhung-thuat-toan-machine-learning-ma-lap-trinh-vien-can-biet.html)

3.3.1.4 ปรับค่าเพื่อให้ได้ผลลัพท์เข้าใกล้กันกับค่าจริงมากที่สุด

การที่จะปรับให้ผลลัพท์ใกล้เคียงค่าจริงมากที่สุดนั้น ผู้วิจัยใช้ขั้นตอนการปรับค่าทั้งหมด 4 ขั้นตอน คือ 1) Rectified Linear Unit (ReLU) 2) Batch Normalization 3) Dropout 4) Sigmoid function

1) Rectified Linear Unit (ReLU)

นำค่าค่าทำนายคะแนนความชอบของผู้ใช้มีต่อภาพยนตร์ (y ที่ได้จาก3.3.1.3) มาทำการปรับค่าโดยหากค่านั้นน้อยกว่า 0 ผลลัพธ์จะออกมาเป็น 0 แต่ถ้ามีค่านั้นมากกว่า 0 จะยังคงค่านั้นไว้ไม่ทำการปรับค่าแต่อย่างใด โดยภาพที่ 3.5 แสดงตัวอย่างการปรับค่าโดยใช้ ReLU [1]

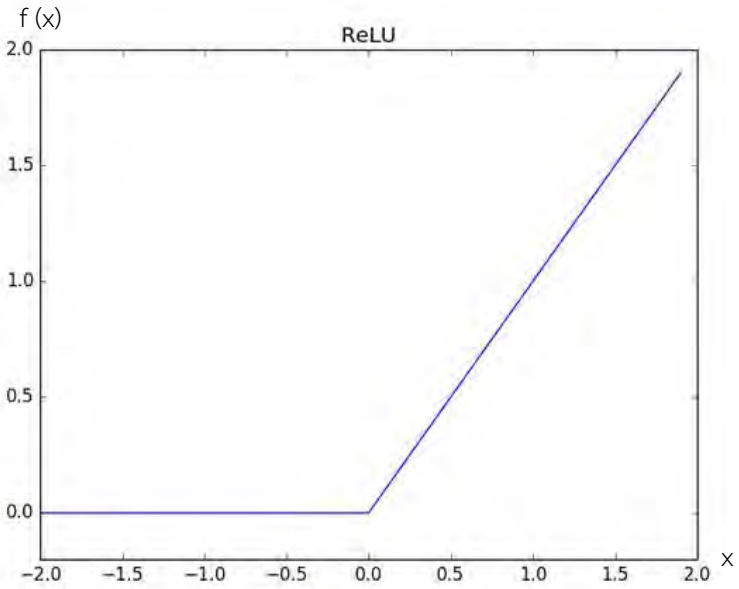

ภาพที่ 3.5 แสดงตัวอย่างฟังก์ชัน ReLU

(ที่มา: https://medium.com/@dopplerz/ bayesian-neural-network-ตอนที่-3-อะไรคือ-deep-learning-และอะไรคือ-neural-network-ฉบับมือใหม่-cce9227ab599)

2) Batch Normalization layer

Batch Normalization เป็นเทคนิคสำหรับการปรับปรุงประสิทธิภาพและความเสถียรของเครือข่ายประสาทเทียม ด้วยการปรับค่าให้อยู่ในช่วงที่กำหนด ช่วยเพิ่มความเร็วในการฝึกโมเดลและลดการเกิด overfitting

3) Dropout layer

Dropout เป็นเทคนิคที่จดสิทธิบัตรโดย Google เพื่อลดการ overfitting ในเครือข่ายประสาทเทียม และลดเวลาในการฝึกโมเดล คือการไม่สนใจบาง node ในระหว่างขั้นตอนการฝึก ดังภาพที่ 3.6 ซึ่งเลือกโดยการสุ่มแล้วทำการฝึกฝนเพื่อทำนายค่าให้ใกล้เคียงค่าจริงให้ได้มากที่สุด

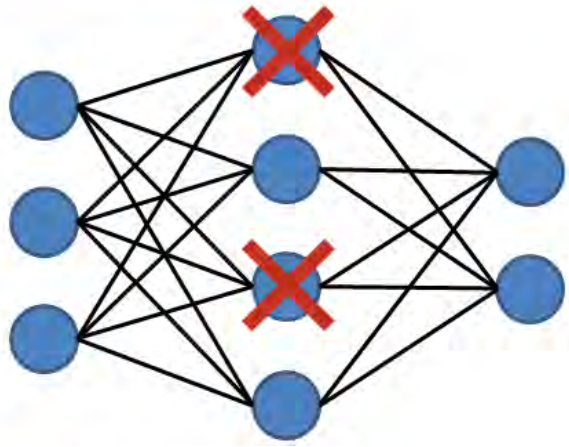

ภาพที่ 3.6 แสดง Dropout layer

(ที่มา: https://gitbook.cn/gitchat/geekbook/5b0277bdedd0d46379a7d31d/topic/5b027f7fedd0d46379a7e439)

4) Sigmoid function เปลี่ยนค่าให้มีค่าอยู่ระหว่าง 0-1 [1]

ฟังก์ชัน Sigmoid จะนำค่าที่ได้จาก Dropout Layer มาทำการปรับค่าให้มีค่าอยู่ระหว่าง 0-1 ดังภาพที่ 3.7

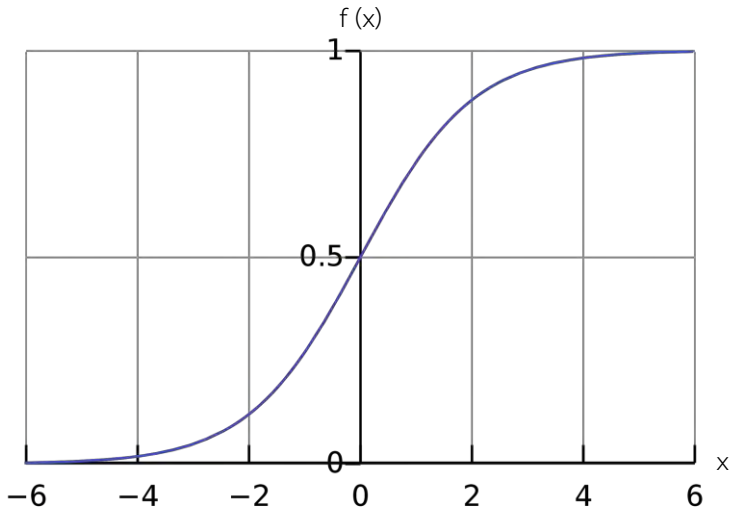

ภาพที่ 3.7 แสดงตัวอย่างฟังก์ชัน Sigmoid

(ที่มา: https://link.springer.com/chapter/10.1007/978-3-319-95810-1_1)

3.3.1.5 สร้างสมการทำนายคะแนนความชอบของผู้ใช้ที่มีต่อภาพยนตร์

ขั้นตอนนี้จะทำนายคะแนนความชอบของผู้ใช้ที่มีต่อภาพยนตร์ผ่านสมการ y = x * (max - min) + min เมื่อ y คือ ค่าทำนายคะแนนความชอบของผู้ใช้ที่มีต่อภาพยนตร์ x คือ ค่าที่ได้จากฟังก์ชัน Sigmoid, max คือ ค่าคะแนนสูงสุด และ min คือ ค่าคะแนนต่ำสุด โดยเมื่อได้ค่าทำนายคะแนนความชอบของผู้ใช้ที่มีต่อภาพยนตร์ แล้วโมเดลจะนำค่านั้นมาเทียบกับค่าจริงจากชุดข้อมูล เพื่อหาค่าความคลาดเคลื่อน จากนั้นโมเดลจะ backpropagation กลับไปฝึกฝนใหม่จนกว่าค่าความคลาดเคลื่อนเริ่มคงที่โมเดลจึงจะหยุด นั่นคือผลลัพท์ได้ถูกปรับให้เข้าใกล้ค่าจริงมากที่สุดนั่นเอง

หลังจากเสร็จสิ้นในขั้นตอนที่ 3.3.1 จะได้เวกเตอร์ที่แสดงถึง Characteristic ของ user และ item ดังตัวอย่างในภาพที่ 3.8 และ Characteristic item ดังตัวอย่างในภาพที่ 3.9 ซึ่งเวกเตอร์ของผู้ใช้จะถูกนำมาทำการแบ่งกลุ่มในขั้นตอนถัดไป

```
tensor([ 0.0296,  0.1719, -0.0065,  0.3606, -0.1281,  0.0326, -0.1708, -0.1777,
        -0.0834, -0.3409, -0.2705,  0.0300, -0.1240, -0.0659, -0.2705,  0.2168,
         0.2193,  0.0803,  0.2930, -0.0731,  0.3124,  0.0335,  0.1061,  1.1145,
         0.1861, -0.0991,  0.0766,  0.2946, -0.2169,  0.0456,  0.1860,  0.0030,
         0.4815,  0.1602,  0.0833, -0.1652, -0.1362,  0.1509,  0.1603,  0.1249,
        -0.0918, -0.0629,  0.1047,  0.0985, -0.1580,  0.0369, -0.5104, -0.0975,
         0.1089,  0.2520])
```

ภาพที่ 3.8 แสดงตัวอย่างเวกเตอร์คุณลักษณะของผู้ใช้ 1 คน

```
tensor([ 0.0233, -0.2483,  0.2807,  0.8832,  0.5351, -0.3629,  0.4474,  0.0514,
        -0.6663,  0.7806,  0.0891,  0.0741, -0.0196, -0.0301, -0.2105,  0.1017,
        -0.3669, -0.3182,  0.1510, -0.2114,  0.0348, -0.2396,  0.3363, -0.0126,
         0.2330, -0.1608,  0.4120, -0.1379, -0.0674, -0.0270, -0.4770, -0.1240,
        -0.2699, -0.2272,  0.3998, -0.2804, -0.7270,  0.1908, -0.5582, -0.0152,
         0.2550, -0.5309,  0.2532, -0.0208, -0.1361,  0.1311,  0.3953, -0.2951,
        -0.0493, -0.5524])
```

ภาพที่ 3.9 แสดงตัวอย่างเวกเตอร์คุณลักษณะของภาพยนตร์ 1 เรื่อง

3.3.2 ขั้นตอนที่ 2 ทำการแบ่งกลุ่มผู้ใช้จากเวกเตอร์คุณลักษณะของผู้ใช้แต่ละคน

หลังจากผ่านการฝึกโมเดลเรียบร้อยแล้วใน 3.3.1 นำเวกเตอร์คุณลักษณะของผู้ใช้แต่ละคนที่ได้มาแบ่งกลุ่มด้วย KMeans Cluster โดยลำดับแรก ทำการหาจำนวนกลุ่มที่เหมาะสมจากการพิจารณาจากคะแนนผลรวมระยะห่างระหว่างข้อมูลกับจุดศูนย์กลางของกลุ่มที่ทำการแบ่งในแต่ละจำนวนกลุ่ม โดยการนำมาสร้างกราฟ ดังภาพที่ 3.10 โดยพิจารณาเลือกจำนวนกลุ่มที่เหมาะสมจากกลุ่มที่อยู่ในช่วงที่ค่าคะแนนยังคงลดลงอย่างมีนัยสำคัญอยู่ และทำการแบ่งกลุ่มให้ผู้ใช้ด้วยขนาดที่เลือกมา ซึ่งจากภาพที่ 3.10 เลือกแบ่งประมาณ 4-7 กลุ่มเพราะเป็นช่วงที่ผลรวมระยะห่างระหว่างข้อมูลกับจุดศูนย์กลางของกลุ่มยังลดลงอยู่ซึ่งหมายถึงข้อมูลเกาะกลุ่มกันดี ในขณะที่หากเลือกจำนวนกลุ่มที่มากจนเกินไปจะทำให้กลุ่มที่ได้มีขนาดเล็กและเฉพาะเจาะจงกับผู้ใช้แต่ละรายจนเกินไป

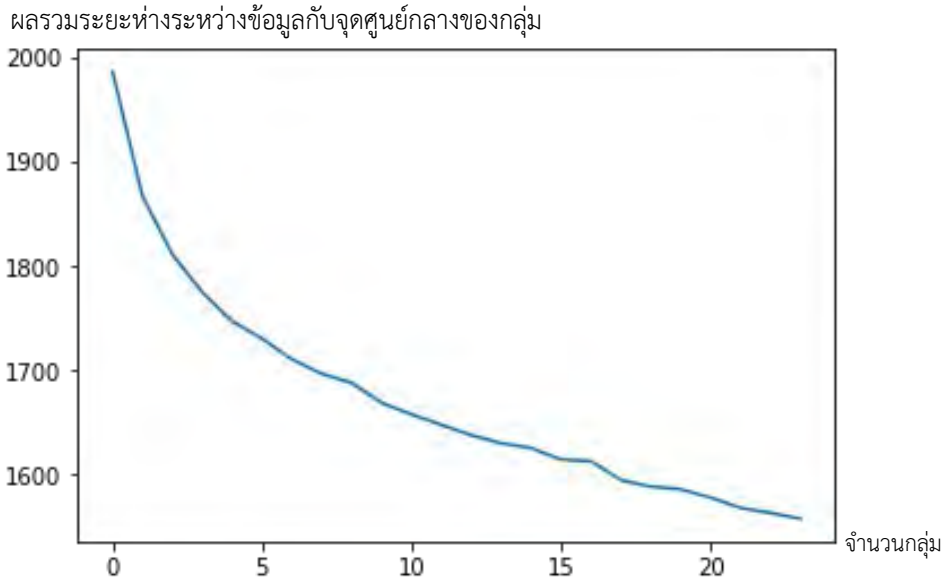

ภาพที่ 3.10 แสดงตัวอย่างค่าคะแนนของการแบ่งกลุ่มจาก เวกเตอร์ Embeddings ของผู้ใช้ตามจำนวนกลุ่ม

จากกราฟในภาพที่ 3.10 จะได้ช่วงของจำนวนกลุ่มที่เหมาะสมอยู่ที่ 4-7 เพื่อเป็นการทดสอบว่าจำนวนกลุ่มใดที่เหมาะสมที่สุดจึงทำการตรวจสอบการแบ่งกลุ่มด้วยการทำ PCA ลดมิติของข้อมูลให้เหลือ 2 มิติ เพื่อการแสดงผลให้เห็นได้อย่างชัดเจน และพบว่าหากแบ่งข้อมูลออกเป็น 5 กลุ่มจะได้ผลลัพท์ที่ดีที่สุด ดังภาพที่ 3.11

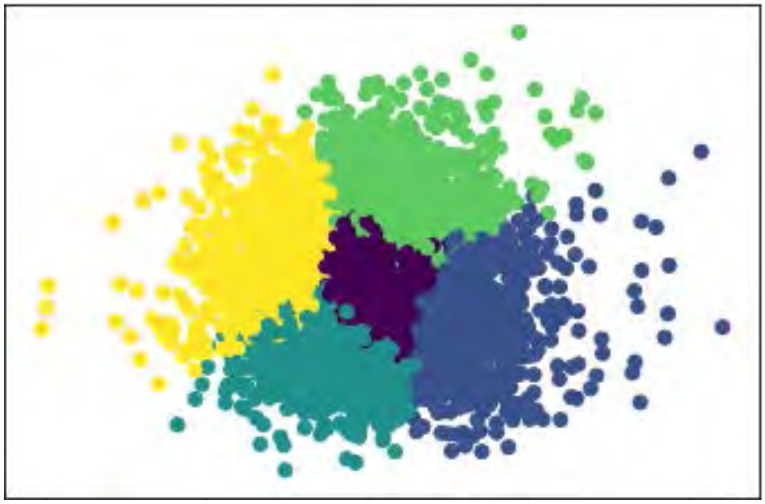

ภาพที่ 3.11 แสดงตัวอย่างของการแบ่งกลุ่มผู้ใช้ออกเป็น 5 กลุ่ม

หลังจากการแบ่งกลุ่มผู้ใช้จากเวกเตอร์คุณลักษณะของผู้ใช้แต่ละคน ใน 3.3.2 จะได้ข้อมูลกลุ่มที่ผู้ใช้แต่ละคนว่าอยู่ในกลุ่มใด

3.3.3 ขั้นตอนที่ 3 ทำการนำความสัมพันธ์ระหว่างผู้ใช้เข้ามาร่วมฝึกโมเดล

เนื่องจากโมเดลในขั้นตอนที่ 3.3.1 จะสังเกตได้ว่า ข้อมูลนำเข้ามีเฉพาะข้อมูลผู้ใช้ และข้อมูลภาพยนตร์เท่านั้น ไม่มีการคำนึงว่าผู้ใช้รายอื่นได้ให้คะแนนสินค้านี้มีลักษณะความชอบคล้ายคลึงกับผู้ใช้เป้าหมายหรือไม่ ทางผู้วิจัยจึงได้ทำการทดลองด้วยการนำเข้าข้อมูลการแบ่งกลุ่มผู้ใช้ที่ได้จากขั้นตอนที่ 3.3.2 นำมา Concatenate ต่อจากข้อมูลผู้ใช้และข้อมูลภาพยนตร์ เพื่อช่วยในการฝึกโมเดล จึงกล่าวได้ว่าในขั้นตอนนี้เป็นการนำความสัมพันธ์ระหว่างผู้ใช้มาคิด และมีลำดับขั้นตอนการฝึกโมเดลเช่นเดียวกับขั้นตอนที่ 3.3.1 ดังภาพที่ 3.12

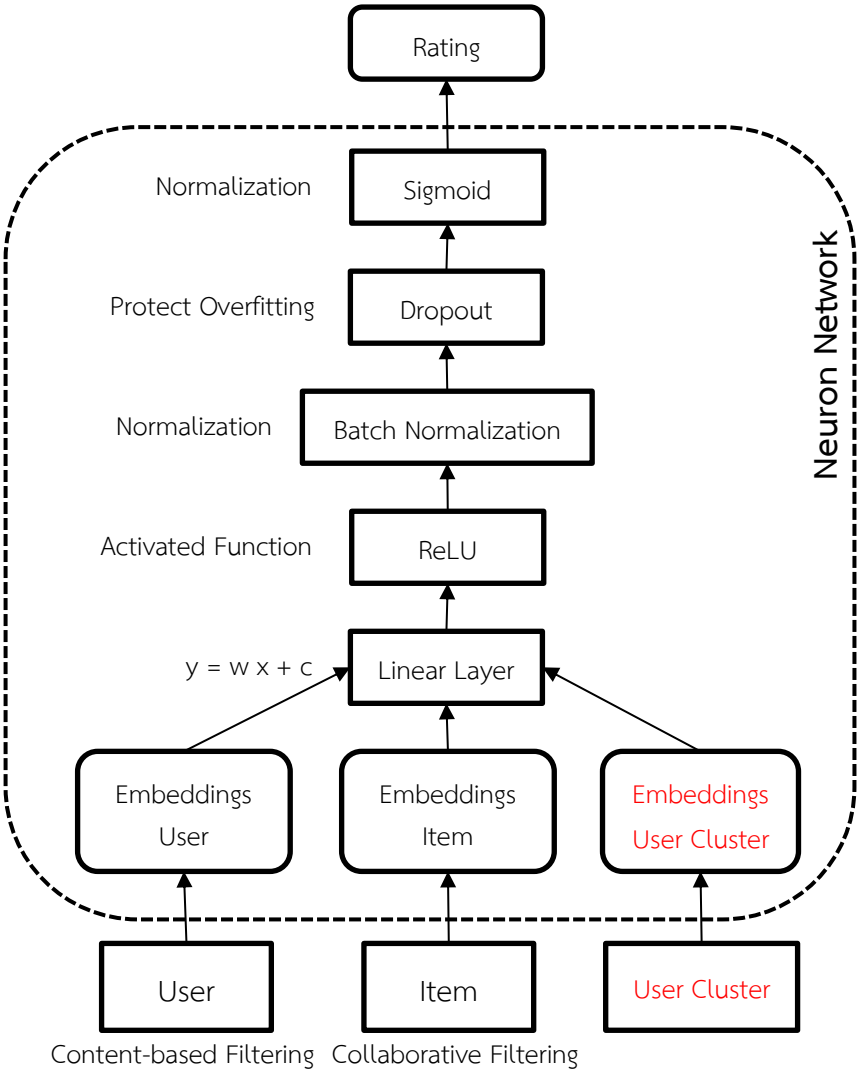

ภาพที่ 3.12 แสดงภาพของโมเดลที่เสนอในขั้นตอนที่ 3

หลังจากการพัฒนาโมเดลโดยการนำความสัมพันธ์ระหว่างผู้ใช้มาพิจารณาดังส่วนของ User Cluster ในภาพที่ 3.12 พบว่าสามารถทำนายค่าคะแนนความชอบของผู้ใช้ที่มีต่อภาพยนตร์ได้แม่นยำยิ่งขึ้น

บทที่ 4
ผลการวิจัย

เนื่องจากผู้วิจัยเสนอการเพิ่มความสัมพันธ์ในเครือข่ายประสาทเทียมบนระบบแนะนำ ซึ่งมีสมมติฐานว่าจะทำให้ได้ผลลัพธ์ในการทำนายที่ดีขึ้น โดยในบทนี้จึงทำการทดสอบประสิทธิภาพของระบบ โดยทำการเทียบผลการทดสอบระหว่างโมเดลที่ไม่นำความสัมพันธ์ระหว่างผู้ใช้มาพิจารณา และโมเดลที่นำความสัมพันธ์ระหว่างผู้ใช้มาพิจารณา

4.1 ชุดข้อมูล

ชื่อชุดข้อมูล: MovieLens
คำอธิบายของชุดข้อมูล: ชุดข้อมูล MovieLens ถูกรวบรวมโดยโครงการวิจัย GroupLens ที่มหาวิทยาลัย Minnesota
โครงสร้างของชุดข้อมูลหลัก: user id | item id | rating | timestamp

ตารางที่ 4.1 ตารางข้อมูลของชุดข้อมูล

	MovieLens 100K Dataset	MovieLens 1m Dataset
จำนวนการให้คะแนน	100,000	1,000,209
ระดับคะแนน	1-5	1-5
จำนวนผู้ใช้ (คน)	943	6040
จำนวนภาพยนตร์ (ภาพยนตร์)	1682	3900
เวลาที่เก็บข้อมูล	ระยะเวลา 7 เดือนตั้งแต่วันที่ 19 กันยายน ค.ศ.1997 ถึง 22 เมษายน ค.ศ.1998	ค.ศ. 2000
หมายเหตุ	- ผู้ใช้ผู้ที่มีการให้คะแนนน้อยกว่า 20 รายการหรือมีข้อมูลส่วนบุคคลไม่สมบูรณ์ถูกลบออกจากชุดข้อมูลนี้ - ข้อมูลถูกรวบรวมผ่านเว็บไซต์ MovieLens (movielens.umn.edu) - ชุดข้อมูลมีการแบ่งข้อมูลสำหรับฝึกโมเดล และประเมินผลไว้แล้วเป็นอัตราส่วน 80% : 20%	ชุดข้อมูลยังไม่มีการแบ่งข้อมูลสำหรับฝึก Model และประเมินผล
ตัวอย่างข้อมูล	1 1 5 874965758 1 2 3 876893171	1::1193::5::978300760 1::661::3::978302109

4.2 วิธีที่ใช้ในการประเมินผล

การเปรียบเทียบประสิทธิภาพของผลการทดลองระหว่างงานวิจัย คณะผู้จัดทำเลือกวิธีการทดสอบโดยใช้ 2 วิธีการประเมินผลดังนี้

4.2.1 ค่าเฉลี่ยของกำลังสองของความคลาดเคลื่อน (Mean Square Error, MSE)

ค่าเฉลี่ยของกำลังสองของความคลาดเคลื่อน (Mean Square Error, MSE) ซึ่งเป็นการวัดค่าความถูกต้องของโมเดลที่สร้างขึ้น โดยค่า MSE จะแปรผันตรงกับค่า RMSE (Root Mean Square Error) ในทำนองเดียวกันหากค่า MSE น้อย แสดงว่าผลที่ได้มีความใกล้เคียงกับข้อมูลจริงมากที่สุด หมายถึงค่าความคลาดเคลื่อนน้อยที่สุดนั้นเอง โดยมีสูตรดังนี้

$$MSE = \frac{1}{n} * \sum (prediction - actual)^2$$

เมื่อ n = จำนวนข้อมูลทั้งหมด
predicted = ค่าที่ได้จากการทำนาย
actual = ค่าจริงที่อยู่บนชุดข้อมูล

ในขณะฝึกโมเดลเพื่อให้ผลลัพท์เข้าใกล้กันกับค่าจริงมากที่สุด ผู้วิจัยจึงนำค่า MSE มาวัดค่าความคลาดเคลื่อนระหว่างค่าจริงกับค่าที่โมเดลทำนาย โดยโมเดลจะหยุดทำนายเมื่อค่า MSE เริ่มคงที่

4.2.2 ค่าเฉลี่ยของรากที่สองของกำลังสองของความคลาดเคลื่อน (Root Mean Square Error, RMSE)

ค่าเฉลี่ยของรากที่สองของกำลังสองของความคลาดเคลื่อน (Root Mean Square Error, RMSE) ซึ่งเป็นการวัดค่าความถูกต้องของโมเดลที่สร้างขึ้น โดยหากค่า RMSE น้อย แสดงว่าค่าทำนายที่ได้มีค่าใกล้เคียงกับข้อมูลจริงมากที่สุด หรือค่าทำนายที่ได้มีค่าความคลาดเคลื่อนน้อยที่สุดนั่นเอง โดยมีสมการดังนี้

$$RMSE = \sqrt{\frac{\sum_{i=1}^{N} (Predicted_i - Actual_i)^2}{N}}$$

เมื่อ N = จำนวนข้อมูลทั้งหมด
predicted = ค่าที่ได้จากการทำนาย
actual = ค่าจริงที่อยู่บนชุดข้อมูล

เมื่อสิ้นสุดการฝึกโมเดลจะทำการประเมินผลลัพท์สุดท้ายโดยใช้ค่า RMSE เพื่อหาค่าความคลาดเคลื่อนระหว่างค่าจริงกับค่าที่โมเดลทำนาย ซึ่งหมายถึงว่าโดยเฉลี่ยแล้วโมเดลทำนายค่าคาดเคลื่อน +/- ไปจากข้อมูลจริงเท่าใด

4.3 ผลการทดลอง

ในหัวข้อนี้ ผลลัพธ์ที่ได้จากทดลองด้วยชุดข้อมูล MovieLens บนโมเดลที่ไม่นำข้อมูลการแบ่งกลุ่มของผู้ใช้มาพิจารณา และโมเดลที่นำข้อมูลการแบ่งกลุ่มของผู้ใช้มาพิจารณา

4.3.1 ผลการทดลองจากชุดข้อมูล MovieLens 100K Dataset

ตารางที่ 4.2 ตารางผลการทดลองจากชุดข้อมูล MovieLens 100K Dataset

	MSE loss	RMSE loss
Normal Model	0.8961749206542968	0.946665157621372
Model with Cluster by user Embeddings	0.8713689086914063	0.933471428963633

จากผลการทดลองพบว่าโมเดลที่มีการนำข้อมูลการแบ่งกลุ่มของผู้ใช้มาพิจารณามีค่า RMSE loss ประมาณ 0.9467 ซึ่งต่ำกว่าโมเดลที่ไม่มีการนำข้อมูลการแบ่งกลุ่มของผู้ใช้มาพิจารณาที่มีค่า RMSE loss ประมาณ 0.9335 กล่าวคือโมเดลที่มีการนำข้อมูลการแบ่งกลุ่มของผู้ใช้มาพิจารณาสามารถทำนายผลได้ดีกว่า โดยมีค่า RMSE loss ต่างกันประมาณ 0.0132

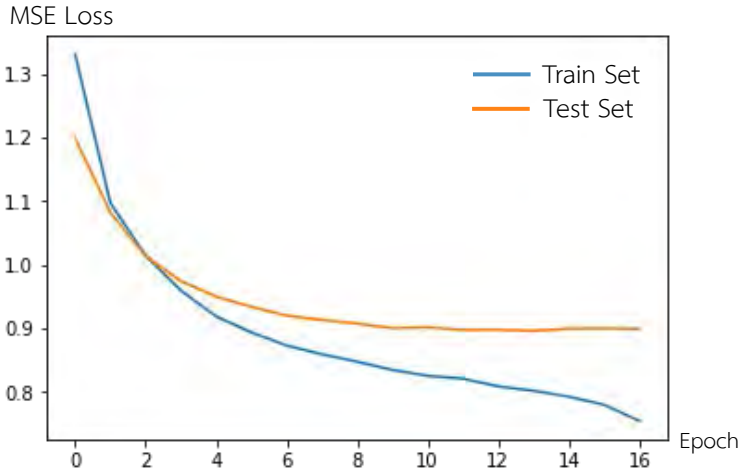

ภาพที่ 4.2 แสดงการทดลองจากชุดข้อมูล MovieLens 100K Dataset โดยไม่นำความสัมพันธ์ระหว่างผู้ใช้มาพิจารณา

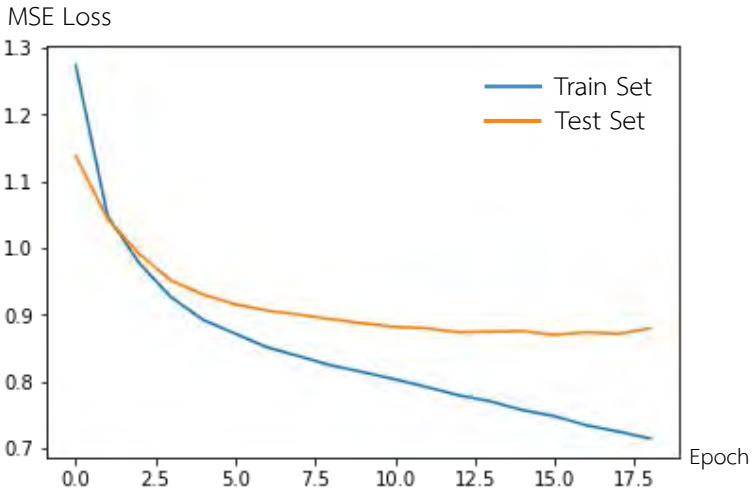

ภาพที่ 4.3 แสดงการทดลองจากชุดข้อมูล MovieLens 100K Dataset โดยนำความสัมพันธ์ระหว่างผู้ใช้มาพิจารณา

จากภาพที่ 4.2 และ 4.3 แสดงค่า MSE loss ระหว่างการฝึกโมเดล โดยสีน้ำเงินจะเป็นค่าของชุดข้อมูลในส่วนของการฝึกโมเดล และสีส้มจะเป็นค่าของชุดข้อมูลในส่วนของการทดสอบโมเดล โดยจะหยุดการฝึกโมเดลเมื่อค่า MSE loss ของชุดข้อมูลในส่วนของการทดสอบโมเดลเริ่มคงที่หรือไม่เปลี่ยนแปลงแล้ว

4.3.2 ผลการทดลองจากชุดข้อมูล MovieLens 1m Dataset

ตารางที่ 4.3 ตารางผลการทดลองจากชุดข้อมูล MovieLens 1m Dataset

	MSE loss	RMSE loss
Normal Model	0.8848449369705067	0.940661967430653
Model with Cluster by user Embeddings	0.8863554137278773	0.941464504762594

จากผลการทดลองพบว่าโมเดลที่มีการนำข้อมูลการแบ่งกลุ่มของผู้ใช้มาพิจารณามีค่า RMSE loss ประมาณ 0.9415 ซึ่งสูงกว่าโมเดลที่ไม่มีการนำข้อมูลการแบ่งกลุ่มของผู้ใช้มาพิจารณาที่มีค่า RMSE loss ประมาณ 0.9401 กล่าวคือโมเดลที่ไม่มีการนำข้อมูลการแบ่งกลุ่มของผู้ใช้มาพิจารณาสามารถทำนายผลได้ดีกว่า โดยมีค่า RMSE loss ต่างกันประมาณ 0.0014

จากข้อมูลผลการวิจัยพบว่า เมื่อพิจารณาชุดข้อมูล MovieLens 100K โมเดลที่ทำการปรับปรุงให้ทางฝั่งที่ใช้เทคนิคกระบวนการกรองแบบร่วมที่คำนึงถึงค่าระดับความสัมพันธ์ระหว่างเพื่อนและผู้ใช้เป้าหมายนั้นสามารถวิเคราะห์และทำนายคะแนนความชอบของผู้ใช้ได้แม่นยำกว่าโมเดลที่ไม่มีการคำนึงถึงระดับค่าความสัมพันธ์

และชุดข้อมูล MovieLens 1m โมเดลที่ทำการปรับปรุงให้ทางฝั่งที่ใช้เทคนิคกระบวนการกรองแบบร่วมที่คำนึงถึงค่าระดับความสัมพันธ์ระหว่างเพื่อนและผู้ใช้เป้าหมายนั้นสามารถวิเคราะห์และทำนายคะแนนความชอบของผู้ใช้ได้แม่นยำน้อยกว่าโมเดลที่ไม่มีการคำนึงถึงระดับค่าความสัมพันธ์

เมื่อมาพิจารณาชุดข้อมูลทั้งสองแล้วพบว่า ชุดข้อมูล MovieLens 100K มีจำนวนผู้ใช้ : จำนวนภาพยนตร์ เป็น 943 :1682 และมีการยืนยันว่าผู้ใช้แต่ละคนให้คะแนนภาพยนตร์อย่างน้อย 20 เรื่อง แต่ชุดข้อมูล MovieLens 1m มีจำนวนผู้ใช้ : จำนวนภาพยนตร์ เป็น 6040:3900 ซึ่งเมื่อจำนวนผู้ใช้มากกว่าจำนวนภาพยนตร์ และไม่ได้มีการยืนยันการให้คะแนนของผู้ใช้ นั้นหมายถึงการให้คะแนนของผู้ใช้อาจเบาบาง ทำให้แบ่งกลุ่มจาก Embeddings Vector ไม่ดีเท่าที่ควร จึงส่งผลให้โมเดลที่ทำการปรับปรุงสามารถทำนายได้แม่นยำน้อยกว่าโมเดลที่ไม่มีการคำนึงถึงระดับค่าความสัมพันธ์

บทที่ 5
ข้อสรุปและข้อเสนอแนะ

5.1 ข้อสรุป

ผู้วิจัยได้เสนอโมเดลโดยการนำค่าระดับความสัมพันธ์เข้ามาร่วมวิเคราะห์ในเครือข่ายประสาทเทียม (Neural Network) ซึ่งมีทั้งฝั่งเทคนิคการกรองร่วม (Collaborative Filtering) และเทคนิคการกรองแบบอิงเนื้อหา (Content-based Filtering) โดยค่าระดับความสัมพันธ์สามารถหาได้จากการทำ clutering คือการนำผู้ใช้ทั้งหมดมาทำการจัดกลุ่ม ปรากฏว่าโมเดลสามารถทำนายผลได้แม่นยำมากขึ้นกว่าโมเดลที่ไม่มีการคำนึงถึงระดับค่าความสัมพันธ์

5.2 ข้อเสนอแนะ

โมเดลที่ทำการปรับปรุงให้ทางฝั่งที่ใช้เทคนิคกระบวนการกรองแบบร่วมที่คำนึงถึงค่าระดับความสัมพันธ์ระหว่างเพื่อนและผู้ใช้เป้าหมายนั้นสามารถทำนายผลได้แม่นยำก็ต่อเมื่อชุดข้อมูลที่นำมาฝึกนั้น ต้องมีปริมาณที่เพียงพอและมีประสิทธิภาพ กล่าวคือ ในขั้นตอนของการ preprocessing นั้นต้องมีการคัดและเลือกเฉพาะผู้ใช้ที่ให้คะแนนความชอบต่อภาพยนตร์จำนวนมากมาใช้ในการฝึก

รายการอ้างอิง

[1] Arunava. (2018). “Derivative of the Sigmoid function.” [Online], Available: https://towardsdatascience.com/derivative-of-the-sigmoid-function-536880cf918e?fbclid=IwAR16G4gfDzI1OZ12bMHm1BA2wTFa4bUWrFD6FvO_PMLv5Q0oa_LKdSCh9Ls (2019, 10 February).

[2] Doshi, Sanket. (2019). “Brief on Recommender Systems Different types of recommendation methods used in industries.” [Online], Available: https://towardsdatascience.com/brief-on-recommender-systems-b86a1068a4dd?fbclid=IwAR3qz9nigJmWENrCeWPVTZZR2CjH0ufX1r_Khy-XBume2wb2V6om2AqoBZs (2019, 14 March).

[3] Ruizendaal, Rutger. (2017). “Deep Learning #4: Why You Need to Start Using Embedding Layers.” [Online], Available: https://towardsdatascience.com/deep-learning-4-embedding-layers-f9a02d55ac12?fbclid=IwAR1nJfq5bUngAnRqw2-_ni9lbZ6Ngp6Z-lld3HjQP7Ez82Jsl5WocXNSnOA (2018, 1 November).

[4] Nielsen, M. “Neural Networks and Deep Learning, ” Y Combinator Research, pp, Distill journal.

[5] Toopiroh, Paripol. (2017). “PyTorch 01 : ทดสอบการจัดการ Tensor ด้วย torch ตัวแทน NumPy โดยใช้ Google Colab + free GPU และโลกความจริงอันโหดร้าย.” [Online], Available: https://medium.com/@paripoltoopiroh/pytorch-ทดสอบการใช้งาน-tensor-torch-ตัวแทน-numpy-ด้วย-google-colab-with-free-5b58b1836369 (2018, 12 December).

[6] Tran, Viet-Trung. (2015). “Recommender systems: Content-based and collaborative filtering.” [Online], Available: https://www.slideshare.net/microlife/recommender-systems-contentbased-and-collaborative-filtering (2019, 3 January).

[7] W. Pei et al. (2017). “Interacting Attention-gated Recurrent Networks for Recommendation, ” 2017 ACM on Conference on Information and Knowledge Management (CIKM '17), pp. 1459-1468, Singapore

[8] X. He et al. (2017). “Neural Collaborative Filtering, ” 2017 International World Wide Web Conference Committee(IW3C2), Perth, Australia

ภาคผนวก

ภาคผนวก ก
แบบเสนอหัวข้อโครงงาน รายวิชา 2301399 Project Proposal
ปีการศึกษา 2561

ชื่อโครงงาน (ภาษาไทย)	การปรับปรุงเครือข่ายประสาทเทียมตามหลักการของระบบแนะนำ บนข้อมูลที่มีลำดับ โดยใช้ความสัมพันธ์ของผู้ใช้ในส่วนของกระบวนการกรองแบบร่วม
ชื่อโครงงาน (ภาษาอังกฤษ)	Improving Neural Network based Recommendation System on Temporal data using user relation in Collaborative Filtering part
อาจารย์ที่ปรึกษา	ผู้ช่วยศาสตราจารย์ ดร.ศรันญา มณีโรจน์
ผู้ดำเนินการ	1. นายศุภพัฒน์ นิรัตติวงศกรณ์ เลขประจำตัวนิสิต 5833662023
	2. นางสาวปาณิสรา ศโรภาส เลขประจำตัวนิสิต 5833642523
	สาขาวิชาวิทยาการคอมพิวเตอร์
	ภาควิชาคณิตศาสตร์และวิทยาการคอมพิวเตอร์
	คณะวิทยาศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

หลักการและเหตุผล

เนื่องจากมนุษย์เริ่มเรียนรู้การในการแลกเปลี่ยนซื้อขายสิ่งต่างๆ จึงทำให้เกิดการแนะนำสินค้าขึ้นโดยจุดประสงค์ก็เพื่อให้ผู้ขายสินค้า (หรือบริการ) สามารถนำเสนอสินค้าที่ตนมีได้ดียิ่งขึ้น และให้ผู้ซื้อได้สินค้าที่เหมาะกับตนเอง และในปัจจุบันมีเทคโนโลยีต่างๆมากมาย เช่น อินเตอร์เน็ต (Internet) ซึ่งทำให้ร้านค้าและผู้รับบริการสามารถเชื่อมต่อกันมากขึ้น ระบบการแนะนำ (Recommender System) จึงเข้ามามีบทบาทเพื่อให้ผู้ขายสินค้าและผู้ซื้อได้รับผลประโยชน์สูงสุดทั้งสองฝ่าย นั้นคือผู้ขายสินค้าสามารถเสนอขายสินค้าของตนได้มากขึ้น และผู้ซื้อได้สินค้าที่ตรงกับความต้องการของตน

โดยทั่วไปวิธีการแนะนำที่ใช้ในระบบแนะนำสามารถจำแนกได้เป็นสองวิธีพื้นฐานคือเทคนิคการคัดกรองแบบอิงเนื้อหา (Content-based) และเทคนิคการคัดกรองแบบร่วม (Collaborative Filtering) สำหรับวิธีเทคนิคการคัดกรองแบบอิงเนื้อหา (Content-based) จะเลือกแนะนำโดยพิจารณาจากการนำคุณลักษณะของสินค้าที่ผู้ใช้เคยเห็นหรือเคยใช้มาก่อนมาทำการวิเคราะห์ว่าผู้ใช้รายนี้มีความสนใจสินค้าประเภทใด จากนั้นระบบจะทำการแนะนำสินค้าใหม่ที่มีคุณลักษณะตรงกับความสนใจของผู้ใช้รายนั้น ส่วนเทคนิคการคัดกรองแบบร่วม (Collaborative Filtering) จะเลือกแนะนำโดยการนำข้อมูลของผู้ใช้รายอื่น ๆ ในระบบที่มีมาลักษณะความชอบที่คล้ายคลึงกับผู้ใช้เป้าหมายซึ่งจะเรียกผู้ใช้รายอื่นว่าเพื่อน แล้วจึงนำคะแนนความชอบต่อสินค้าของเพื่อนที่ได้ให้ไว้ค่อนข้างสูงมาช่วยในการวิเคราะห์และทำการแนะนำสินค้าใหม่ให้แก่ผู้ใช้เป้าหมาย

ในการสร้างระบบการแนะนำ (Recommender System) มักนำการจำแนกประเภทของข้อมูล (Classification) ซึ่งมีป้ายกำกับ (Label) เพื่อทำการจำแนกข้อมูลลงในประเภทที่กำหนดไว้ เช่น ในระบบแนะนำเราสามารถจำแนกประเภทของผู้ใช้ที่มีต่อสินค้านั้นได้เป็นชอบและไม่ชอบ เป็นต้น

ที่ผ่านมาระบบจะนำคะแนนความชอบจากผู้ใช้มาทำการวิเคราะห์โดยตรงแต่เนื่องจากข้อมูลที่เก็บมาจากผู้ใช้มีความเบาบาง (Sparse) ตัวอย่างเช่น เว็บที่ขายสินค้ามักมีสินค้าจำนวนมากอยู่บนเว็บไซต์ แต่ผู้ใช้คนหนึ่งมักมีการให้คะแนนสินค้าเพียงแค่ส่วนน้อยเท่านั้น หากเทียบกับจำนวนสินค้าทั้งหมด ทำให้ข้อมูลที่เหลือเป็นค่าว่าง ในปัจจุบันมีการนำข้อมูลมาทำการฝัง (Embedding) เนื่องจากปัญหาที่ข้อมูลคะแนนมักมีมิติสูงและเบาบาง (Sparse) ก็คือข้อมูลจะมีขนาดใหญ่และไม่มีประสิทธิภาพ ทำให้ข้อมูลที่นำมาวิเคราะห์นั้นได้ผลออกมาไม่ตรงกับความต้องการของผู้ใช้ เพราะฉะนั้นจึงมีงานวิจัยที่แก้ปัญหาข้อมูลเบาบางโดยการฝัง (Embedding) เนื่องจากระบบการแนะนำมีข้อมูล 2 ส่วน คือ ผู้ใช้และสินค้า จึงฝัง (Embed) เพื่อให้ได้เวกเตอร์ลักษณะของผู้ใช้ (User Characteristic Vector) และ เวกเตอร์ลักษณะของสินค้า (Item Characteristic Vector) หลังจากได้ Embed ของข้อมูลเป็นเวกเตอร์ลักษณะของผู้ใช้และสินค้าแล้ว จะนำมาใช้เพื่อปรับค่า ในช่วงฝึกข้อมูล (Trainning) สำหรับ (Neural Network) โดยเวกเตอร์ที่มีการฝัง (Embedding) สามารถทำงานได้ดีบนเครือข่ายประสาทเทียม (Neural Network)

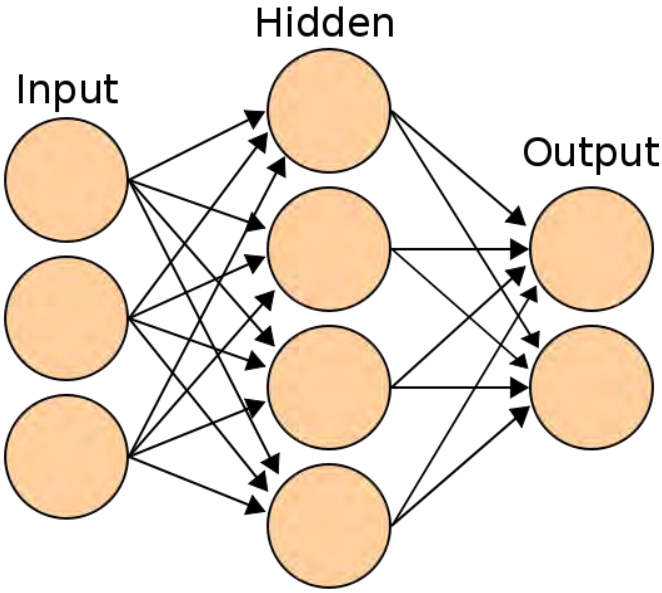

การทำงานของเครือข่ายประสาทเทียม (Neural Network) คือเมื่อมี input เข้ามายังเครือข่าย (Network) ก็นำ input มาคูณกับค่าน้ำหนัก (Weight) ของแต่ละขา ผลที่ได้จาก input ทุก ๆ ขาของเซลล์ประสาท (Neuron) จะเอามารวมกันแล้วก็เอามาเทียบกับ Threshold ที่กำหนดไว้ ถ้าผลรวมมีค่ามากกว่า Threshold แล้วเซลล์ประสาท (Neuron) ก็จะส่ง output ออกไป output นี้ก็จะถูกส่งไปยัง input ของเซลล์ประสาท (Neuron) อื่น ๆ ที่เชื่อมกันในเครือข่าย (Network) ถ้าค่าน้อยกว่า Threshold ก็จะไม่เกิด output สิ่งสำคัญคือเราต้องทราบค่าน้ำหนัก (Weight) และ Threshold สำหรับสิ่งที่เราต้องการเพื่อให้คอมพิวเตอร์รู้จำ ซึ่งเป็นค่าที่ไม่แน่นอน แต่สามารถกำหนดให้คอมพิวเตอร์ปรับค่าเหล่านั้นได้โดยการสอนให้มันรู้จัก pattern ของสิ่งที่เราต้องการให้มันรู้จำ เรียกว่า "back propagation" ซึ่งเป็นกระบวนการย้อนกลับของการรู้จำ ในการฝึก feed-forward Neural Networks จะมีการใช้อัลกอริทึมแบบ back-propagation

เพื่อใช้ในการปรับปรุงน้ำหนักคะแนนของเครือข่าย (Network Weight) หลังจากใส่รูปแบบข้อมูลสำหรับฝึกให้แก่เครือข่ายในแต่ละครั้งแล้ว ค่าที่ได้รับ (output) จากเครือข่ายจะถูกนำไปเปรียบเทียบกับผลที่คาดหวัง แล้วทำการคำนวณหาค่าความผิดพลาด ซึ่งค่าความผิดพลาดนี้จะถูกส่งกลับเข้าสู่เครือข่ายเพื่อใช้แก้ไขค่าน้ำหนักคะแนนต่อไป

เครือข่ายประสาทเทียมแบบย้อนกลับ (Recurrent neural network หรือ RNN) เป็นเครือข่ายประสาทเทียมที่เชื่อมต่อระหว่างโหนดเป็นกราฟที่มีลำดับ ซึ่งทำให้สามารถแสดงพฤติกรรมตามลำดับเวลาได้แบบชั่วขณะ RNN สามารถใช้ประมวลผลลำดับของข้อมูล ซึ่งเหมาะสำหรับข้อมูลที่เป็นลำดับ เช่น การจดจำลายมือหรือการจดจำเสียงพูด

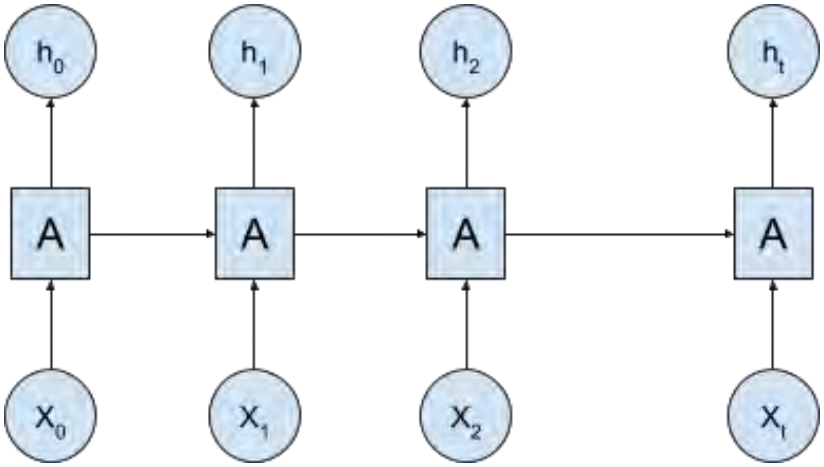

การทำงานคือเอาผลลัพธ์ที่ได้จากการคำนวณย้อนกลับมาใช้เป็นข้อมูลขาเข้าอีกครั้ง ในแต่ละ node ของ RNN จะมีข้อมูลขาเข้าสองอย่างอันได้แก่ input ณ node นั้น ๆ และผลลัพธ์ที่ได้จากการคำนวณใน node ก่อนหน้า ซึ่งทั้งสองข้อมูลจะถูกนำมารวมเข้าด้วยกันและออกผลลัพธ์มาเป็นสองทางคือ ผลลัพธ์ที่ออก ณ node นั้น ๆ และออกเพื่อไปเข้าเป็นข้อมูลขาเข้าใน node ถัดไป

โดยปกติการนำ RNN มาใช้ในระบบแนะนำ มักจะเป็น content based คือการเปรียบเทียบลำดับของสินค้าที่ผู้ใช้เป้าหมายเคยใช้เท่านั้น ซึ่งจะมีข้อเสีย คือ ไม่หลากหลาย เพราะข้อมูลที่นำมาแนะนำผู้ใช้มีเพียงของผู้ใช้เป้าหมายรายเดียวเท่านั้น ไม่ได้นำข้อมูลของผู้ใช้รายอื่นๆมาวิเคราะห์ด้วย

เนื่องจากการเก็บประวัติของผู้ใช้มักมีการเก็บข้อมูลแบบจัดลำดับ หรือเก็บข้อมูลตามเวลาที่ใช้งาน ดังนั้นเครือข่ายประสาทเทียมแบบวนซ้ำ (Recurrent Neural Network) จึงเหมาะที่จะนำมาวิเคราะห์ข้อมูลที่มีการจัดข้อมูลตามลำดับเวลา และสามารถนำเสนอข้อมูลต่างๆ ตามช่วงเวลาได้ แต่การนำประวัติของผู้ใช้แต่ละรายมาทำการวิเคราะห์อย่างเดียวมีข้อเสียคือทำให้ไม่มีความหลากหลาย ยกตัวอย่างเช่น หากผู้ใช้ซื้อแต่สินค้าประเภทเครื่องใช้ไฟฟ้า ระบบแนะนำก็จะแนะนำเฉพาะสินค้าประเภทนี้เท่านั้น เช่น x_0 คือตู้เย็น x_1 คือพัดลม x_2 คือไมโครเวฟ output คือออกมาย่อมเป็นสินค้าประเภทเครื่องใช้ไฟฟ้า ส่วนสินค้าประเภทอื่นเช่น อุปกรณ์ตกแต่งบ้าน จะไม่ปรากฏออกมาเป็นค่า output จึงมีงานวิจัยพยายามแก้ไขปัญหานี้คือต้องการให้การแนะนำนั้นมีความหลากหลายมากขึ้น นักวิจัยเหล่านั้นจึงพยายามรวมเทคนิคการคัดกรองแบบอิงเนื้อหา (Content-based) และเทคนิคการคัดกรองแบบร่วม (Collaborative Filtering) โดยได้แบ่งเครือข่ายประสาทเทียมแบบวนซ้ำ (recurrent nueral network) ออกเป็น 2 ฝั่งเพื่อทำการวิเคราะห์หาคุณลักษณะของผู้ใช้

(characteristic of user) โดยใช้เทคนิคการคัดกรองแบบอิงเนื้อหา (Content-based) คือนำสินค้าที่ผู้ใช้เป้าหมายเคยใช้โดยเรียงลำดับตามเวลามาวิเคราะห์ตามลำดับเวลา และหาคุณลักษณะของสินค้า (Feature of item) โดยใช้เทคนิคการคัดกรองแบบร่วม (Collaborative Filtering) คือนำคะแนนที่ผู้ใช้ทั้งหมดในระบบเคยให้คะแนนสินค้านั้นมาวิเคราะห์ เนื่องจากแต่ละฝั่งถูกคำนวณแยกจึงทำให้ไม่สามารถหาความสัมพันธ์ระหว่างผู้ใช้กับสินค้าได้

ดังนั้นงานวิจัยของ Weijie pei, et al.[1] จึงได้เสนอวิธีการหาความสัมพันธ์ระหว่างผู้ใช้กับสินค้าขึ้นมา เพื่อทำให้ผู้ใช้ได้สินค้าที่ตรงกับลักษณะความชอบได้ดียิ่ง โดยมองค่าน้ำหนัก (weight) เป็นค่าความสนใจ (attention) หากผู้ใช้มีแนวโน้มสนใจสินค้าประเภทนั้นค่าน้ำหนักจะสูงขึ้น ในทำนองเดียวกันหากผู้ใชมีแนวโน้มว่าไม่ค่อยสนใจสินค้าประเภทนั้นค่าน้ำหนักจะต่ำลง และในการหาค่าความสนใจนี้ควรนำค่าความสนใจที่ได้ในแต่ละฝั่งมาทำการวิเคราะห์ร่วมกัน ทำให้ระบบสามารถบอกได้ว่าในแต่ละช่วงเวลาผู้ใช้มีความชอบหรือสนใจสินค้าประเภทใด แต่ข้อเสียของงานนี้คือในฝั่งเทคนิคการคัดกรองแบบร่วม (Collaborative Filtering) นั้นมีการนำคะแนนความชอบของทุกคนมาวิเคราะห์ โดยไม่มีการคำนึงว่าผู้ใช้อื่นๆ ที่ให้คะแนนสินค้านี้มีลักษณะความชอบคล้ายคลึงกับผู้ใช้เป้าหมายหรือไม่ ยกตัวอย่างเช่น ผู้ใช้ a ให้คะแนนสินค้านี้ไว้สูงมาก ซึ่งจะเห็นได้ว่าผู้ใช้ a กับผู้ใช้เป้าหมายมีความพึงพอใจในสินค้าในลักษณะตรงข้ามกัน ดังนั้นถ้ามีการนำคะแนนของผู้ใช้ a มาคำนวณด้วย จะทำให้ผลลัพธ์คลาดเคลื่อน

ดังนั้นทางทีมวิจัยจึงสนใจที่จะทำการศึกษาวิธีการที่สามารถนำเฉพาะกลุ่มผู้ใช้ที่มีความเป็นเพื่อนนั้นคือกลุ่มของคนที่มีความพึงพอใจในสินค้าคล้ายกับผู้ใช้เป้าหมายมาวิเคราะห์ โดยทางทีมวิจัยจะคำนึงถึงค่าระดับ (Level) ของความสัมพันธ์ (Relation) ระหว่างเพื่อนและผู้ใช้เป้าหมายมาวิเคราะห์สำหรับการปรับค่าและฝึนฝนเครือข่ายประสาทเทียม

วัตถุประสงค์

เพื่อทำการศึกษาและวิเคราะห์ผลของการใช้เครือข่ายประสาทเทียม โดยมีการหาความสัมพันธ์ระหว่างผู้ใช้เป้าหมายกับผู้ใช้รายอื่นในระบบ เพื่อให้การแนะนำสินค้ามีความหลากหลายและสามารถแนะนำสินค้าแก่ผู้ใช้ได้ตรงกับความต้องการ ด้วยการทดลองและปรับปรุงเครือข่ายประสาทเทียมตามหลักการของระบบแนะนำบนข้อมูลที่มีลำดับ โดยใช้ความสัมพันธ์ของผู้ใช้ในส่วนของกระบวนการกรองแบบร่วม

ขอบเขตของโครงงาน

ข้อมูลที่นำมาทดสอบเป็นชุดข้อมูลที่มีการให้คะแนนสินค้าจากผู้ใช้ไม่เกิน 1,000 ราย และสินค้าไม่เกิน 1,000 รายการ

วิธีการดำเนินงาน

1. ศึกษาการงานวิจัยที่เกี่ยวข้องกับระบบแนะนำ
2. ศึกษาการทำงานของระบบแนะนำ
3. วิเคราะห์หาจุดเด่นจุดด้อยจากงานวิจัยที่เกี่ยวข้องกับระบบแนะนำ
4. ศึกษาเครื่องมือในการพัฒนาระบบแนะนำ
5. วิเคราะห์และออกแบบระบบแนะนำ
6. พัฒนาระบบแนะนำ
7. ตรวจสอบความถูกต้องของระบบและแก้ไขข้อผิดพลาด
8. ประเมินผลที่ได้จากการพัฒนา
9. สรุปและจัดทำเอกสาร

ตารางเวลาการดำเนินงาน

เริ่มดำเนินงานตั้งแต่เดือนสิงหาคม 2561 ถึงเดือนเมษายน 2562 โดยมีตารางเวลาการดาเนินงาน ดังนี้

ปี	2561					2562			
เดือน	8	9	10	11	12	1	2	3	4
1. ศึกษาการงานวิจัยที่เกี่ยวข้องกับระบบแนะนำ	←	→							
2. ศึกษาการทำงานของระบบแนะนำ		←	→						
3. วิเคราะห์หาจุดเด่นจุดด้อยจากงานวิจัยที่เกี่ยวข้องกับระบบแนะนำ			←	→					
4. ศึกษาเครื่องมือในการพัฒนาระบบแนะนำ			←	→					
5. วิเคราะห์และออกแบบระบบแนะนำ			←	—	→				
6. พัฒนาระบบแนะนำ				←	—	—	→		
7. ตรวจสอบความถูกต้องของระบบและแก้ไขข้อผิดพลาด					←	—	→		
8. ประเมินผลที่ได้จากการพัฒนา						←	—	→	
9. สรุปและจัดทำเอกสาร								←	→

ประโยชน์ที่คาดว่าจะได้รับ

1.ประโยชน์ต่อผู้ใช้งาน

1.1 ผู้ซื้อสินค้าจะได้รับการแนะนำสินค้าที่มีความหลากหลายและแม่นยำมากยิ่งขึ้น

1.2 ผู้ซื้อสินค้าจะเพลิดเพลินกับการเลือกซื้อสินค้าที่มีเหมาะสมและตรงกับความสนใจ

1.3 ผู้ขายสินค้าสามารถนำเสนอสินค้าที่ตรงกับความสนใจของผู้ซื้อได้ดียิ่งขึ้น

1.4 ผู้ขายสินค้าสามารถเพิ่มยอดขายได้จากการแนะนำสินค้าที่ตรงกับความต้องการของผู้ซื้อ

2.ประโยชน์ต่อผู้พัฒนาระบบ

2.1 ได้เรียนรู้การทำระบบแนะนำสินค้า

2.2 ได้เรียนรู้เทคนิคต่างๆ ที่ใช้สำหรับการทำระบบแนะนำ

2.3 ได้ฝึกวางแผนการทำงานอย่างมีขั้นตอน

2.4 ได้ฝึกรับมือและแก้ไขปัญหาที่เกิดขึ้นระหว่างดำเนินงาน

2.5 ได้ฝึกการใช้เครื่องมือต่าง ๆ ที่นำมาวิเคราะห์ข้อมูล

อุปกรณ์และเครื่องมือที่ใช้

1. ฮาร์ดแวร์

เครื่องคอมพิวเตอร์ ระบบปฏิบัติการ Windows® 10 แบบ 64 บิต
หน่วยประมวลผล Intel® Core™ i7-6700HQ หน่วยความจำ DDR4 ความจุ 16 กิกะไบต์
พื้นที่เก็บข้อมูล 512 กิกะไบต์

2. ซอฟต์แวร์

1. Python 3.6
2. Jupyter Notebook
3. Mozilla Firefox
4. PyTorch
5. Microsoft Office 365

งบประมาณ

1.	ค่าถ่ายเอกสารและจัดทำรูปเล่มรายงาน	ราคา 1,000 บาท
2.	ค่าแบตเตอรี่อุปกรณ์อิเล็กทรอนิกส์	ราคา 2,000 บาท
3.	ค่าผงหมึกสำหรับเครื่องพิมพ์	ราคา 1,900 บาท
4.	ฮาร์ดดิสก์แบบพกพา	ราคา 2,000 บาท
5.	ปลาย Apple Pencil	ราคา 790 บาท
6.	สาย Lightning (1 ม.)	ราคา 690 บาท
7.	USB-C Docking	ราคา 2,000 บาท
		รวม 10,380 บาท

<u>หมายเหตุ</u> งบประมาณถัวเฉลี่ยทุกรายการ

เอกสารอ้างอิง

[1] W. Pei et al. (2017). “Interacting Attention-gated Recurrent Networks for Recommendation, ” 2017 ACM on Conference on Information and Knowledge Management (CIKM '17), pp. 1459-1468, Singapore

[2] X. He et al. (2017). “Neural Collaborative Filtering” [Online], Available: https://arxiv.org/pdf/1708.05031.pdf (2018, 17 October).

[3] Ruizendaal, Rutger. (2017). “Deep Learning #4: Why You Need to Start Using Embedding Layers” [Online], Available: https://towardsdatascience.com/deep-learning-4-embedding-layers-f9a02d55ac12?fbclid=IwAR1nJfq5bUngAnRqw2-_ni9lbZ6Ngp6Z-lld3HjQP7Ez82Jsl5WocXNSnOA (2018, 1 November).

ประวัติผู้เขียน

นายศุภพัฒน์ นิรัตติวงศกรณ์
การศึกษา: 2558-ปัจจุบัน สาขาวิชา วิทยาการคอมพิวเตอร์
ภาควิชาคณิตศาสตร์และวิทยาการคอมพิวเตอร์
คณะวิทยาศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย
E-Mail: suppapat.n@student.chula.ac.th

นางสาวปาณิสรา ศโรภาส
การศึกษา: 2558-ปัจจุบัน สาขาวิชา วิทยาการคอมพิวเตอร์
ภาควิชาคณิตศาสตร์และวิทยาการคอมพิวเตอร์
คณะวิทยาศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย
E-Mail: panisara.sa@student.chula.ac.th