



รายงานการปฏิบัติงานสหกิจศึกษา

ระบบแนะนำสินค้า

PRODUCT RECOMMENDATION SYSTEM

โดย

นายปรินทร์ กิตติโสภณธรรม 630500007

รายงานนี้เป็นส่วนหนึ่งของวิชา สหกิจศึกษา

ภาควิชาธุรกิจดิจิทัล

คณะเทคโนโลยีสารสนเทศ มหาวิทยาลัยสยาม

ภาคการศึกษาที่ 3 ปีการศึกษา 2565

หัวข้อโครงการ ระบบแนะนำสินค้า

Product Recommendation System

รายชื่อผู้จัดทำ นายปรินทร์ กิตติโสภณธรรม 6305000007

ภาควิชา ธุรกิจดิจิทัล

อาจารย์ที่ปรึกษา อาจารย์ศรีญธร มั่งมี

อนุมัติให้รายงานฉบับนี้เป็นส่วนหนึ่งของการปฏิบัติงานสหกิจศึกษา ภาควิชาธุรกิจดิจิทัล  
ประจำภาคการศึกษาที่ 3 ปีการศึกษา 2565



คณะกรรมการสอบโครงการ

*ศรีญธร มั่งมี*

(อาจารย์ ศรีญธร มั่งมี)

.....อาจารย์ที่ปรึกษา

*Phitavit Seer*

(คุณธิติวต์ สีม่วง)

.....พนักงานที่ปรึกษา

*ปิฟนท เลิศ*

.....กรรมการกลาง

(ผู้ช่วยศาสตราจารย์ ดร.พิชญากร เลิศ)

*มารุจ*

.....ผู้ช่วยอธิการบดีและผู้อำนวยการสำนักสหกิจศึกษา

(ผู้ช่วยศาสตราจารย์ ดร.มารุจ ลิ้มปะวัฒน์นะ)

## จดหมายนำส่งรายงาน

วันที่ 21 เดือน สิงหาคม พ.ศ. 2566

เรื่อง ขอส่งรายงานการปฏิบัติงานสหกิจศึกษา

เรียน อาจารย์ที่ปรึกษาสหกิจศึกษา ภาควิชาธุรกิจดิจิทัล

อาจารย์ศรัณูธร มั่งมี

ตามที่ ผู้จัดทำ นายปรินทร์ กิตติโสภณธรรม นักศึกษาภาควิชาธุรกิจดิจิทัล คณะเทคโนโลยีสารสนเทศ มหาวิทยาลัยสยาม ได้ไปปฏิบัติงานสหกิจศึกษา ระหว่างวันที่ 22 พฤษภาคม 2566 ถึงวันที่ 1 กันยายน 2566 ในตำแหน่ง IT ณ บริษัทยูไนเต็ดฟูดส์และได้รับมอบหมายงานจากพนักงานที่ปรึกษาให้ศึกษาทำรายงาน เรื่องระบบแนะนำสินค้าบัดนี้ การปฏิบัติงานสหกิจศึกษาได้สิ้นสุดแล้ว นายปรินทร์ กิตติโสภณธรรม จึงขอส่งรายงานดังกล่าวมาพร้อมกันนี้ จำนวน 1 เล่ม เพื่อขอรับคำปรึกษาต่อไป

จึงเรียนมาเพื่อโปรดพิจารณา

ขอแสดงความนับถือ

นายปรินทร์ กิตติโสภณธรรม

นักศึกษาสหกิจศึกษา

ภาควิชาธุรกิจดิจิทัล

คณะเทคโนโลยีสารสนเทศ มหาวิทยาลัยสยาม

## กิตติกรรมประกาศ (Acknowledgement)

การที่ผู้จัดทำได้มาปฏิบัติงานในโครงการสหกิจศึกษา ณ บริษัทยูไนเต็ดฟูดส์ ตั้งแต่วันที่ 22 พฤษภาคม 2566 ถึงวันที่ 1 กันยายน 2566 ส่งผลให้ผู้จัดทำรับรู้และประสบการณ์ต่างๆ ที่มีค่ามากมาย สำหรับรายงานสหกิจศึกษานี้ สำเร็จลงได้ด้วยดีจากความร่วมมือและสนับสนุนจากหลายฝ่าย ดังนี้

- |                   |                  |                  |
|-------------------|------------------|------------------|
| 1. คุณปรีชา       | ตั้งเกียรติคำจาย | ผู้จัดการฝ่าย IT |
| 2. คุณธิดิวฒ      | สีม่วง           | พนักงานที่ปรึกษา |
| 3. อาจารย์ศรัณุธร | มั่งมี           | อาจารย์ที่ปรึกษา |

และบุคคลท่านอื่นๆ ที่ไม่ได้กล่าวชื่อนามทุกท่านที่ได้ให้คำแนะนำช่วยเหลือในการจัดทำรายงาน

ผู้จัดทำ ขอขอบพระคุณผู้ที่มีส่วนเกี่ยวข้องทุกท่านที่มีส่วนร่วมในการให้ข้อมูลและเป็น  
ที่ปรึกษาในการทำรายงานฉบับนี้จนเสร็จสมบูรณ์ ตลอดจนให้การดูแลและให้ความเข้าใจกับชีวิต  
ของการทำงานจริง ซึ่งผู้จัดทำขอขอบพระคุณเป็นอย่างสูงไว้ ณ ที่นี้ด้วย

คณะผู้จัดทำ

นายปรินทร์ กิตติโสภณธรรม

21 สิงหาคม 2566

หัวข้อโครงการ	: ระบบแนะนำสินค้า
หน่วยกิต	: 5
คณะผู้จัดทำ	: นายปรินทร์ กิตติโสภณธรรม
อาจารย์ที่ปรึกษา	: อาจารย์ศรัญชร มั่งมี
ชื่อปริญญา	: บริหารธุรกิจบัณฑิต
ภาควิชา	: ธุรกิจดิจิทัล
คณะ	: เทคโนโลยีสารสนเทศ
ภาคการศึกษา / ปีการศึกษา	: 3/2565

### บทคัดย่อ

บริษัท ยูไนเต็ดฟุตส์ จำกัด (มหาชน) เป็นบริษัทชั้นนำในการผลิตขนม ของประเทศไทย โดยมีผลิตภัณฑ์ขนมชนิดต่างๆเช่น เวเฟอร์ เชิงไฮ้, ช็อกโกแลต อัลมอนต์, เยลลี่ โยโย่, โดว์ป้อปคอร์นและอื่นๆการเพิ่มยอดขายและนำเสนอสินค้าให้ตรงตามความต้องการของผู้บริโภคเป็นช่องทางที่ทำให้เพิ่มรายได้ให้กับผู้ประกอบการและเพิ่มความพึงพอใจให้กับผู้บริโภคที่มีต่อสินค้ามากยิ่งขึ้นวัตถุประสงค์ของงานวิจัยนี้คือการพัฒนาแบบจำลองการแนะนำสินค้ามาช่วยในการแนะนำสินค้าโดยใช้เทคนิคการกรองแบบอิงเนื้อหา (Content-Based Filtering) ซึ่งใช้หลักการความคล้ายคลึงแบบโคไซน์และเทคนิคการกรองข้อมูลแบบพึ่งพาผู้ใช้ร่วม (Collaborative Filtering) โดยนำไลบรารีของ Non-negative matrix factorization มาสร้างแบบจำลองทำให้แนะนำสินค้าให้กับลูกค้าได้อย่างเหมาะสม

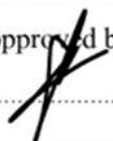
คำสำคัญ : ระบบแนะนำ, การกรองแบบอิงเนื้อหา, การกรองข้อมูลแบบพึ่งพาผู้ใช้ร่วม

**Project Title** : Product Recommendation System  
**Credits** : 5  
**By** : Mr. Parin Kittisophonham  
**Advisor** : Miss Sarathon Maungmee  
**Degree** : Bachelor of Business Administration  
**Major** : Digital Business  
**Faculty** : Information Technology  
**Semester / Academic year** : 3/2022

### Abstract

United Foods Public Company Limited is a leading confectionery manufacturing company in Thailand, offering a wide range of confectionery products such as Wafer Shanghai, Almond Chocolate, Yo-Yo Jelly and Toro Popcorn. Selling and presenting products to meet the needs of consumers is a way to increase revenue for entrepreneurs and increases consumer satisfaction with products. The objective of this research was to develop a product recommendation model to assist with content-based filtering techniques. Content-based filtering, uses the cosine similarity principle and user-dependent filtering techniques. Collaborative filtering uses a library of non-negative matrix factorization, that creates a model to appropriately recommend products to customers.

Keywords: recommendation system, content-based filtering, collaborative filtering

Approved by  
.....  


## สารบัญ

หน้า

จดหมายนำส่งรายงาน.....	ก
กิตติกรรมประกาศ.....	ข
บทคัดย่อ.....	ค
Abstract.....	ง
<b>บทที่ 1 บทนำ</b>	
1.1 ความเป็นมาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์.....	2
1.3 ขอบเขตของโครงการ.....	2
1.4 ประโยชน์ที่คาดว่าจะได้รับ.....	2
<b>บทที่ 2 การทบทวนวรรณกรรมที่เกี่ยวข้อง</b>	
2.1 ทฤษฎีที่เกี่ยวข้อง.....	3
2.2 งานวิจัยที่เกี่ยวข้อง.....	17
2.3 เว็บไซต์ที่เกี่ยวข้อง.....	21
<b>บทที่ 3 รายละเอียดการปฏิบัติงาน</b>	
3.1 ชื่อและที่ตั้งของสถานประกอบการ.....	23
3.2 ลักษณะการประกอบและการให้บริการหลัก.....	24
3.3 รูปแบบการจัดองค์การและการบริหารงานขององค์กร.....	24
3.4 ตำแหน่งและลักษณะงานที่ได้รับมอบหมาย.....	25
3.5 ชื่อและตำแหน่งงานของพนักงานที่ปรึกษา.....	25
3.6 ระยะเวลาปฏิบัติงาน.....	25
3.7 ขั้นตอนและวิธีการดำเนินงาน.....	25
3.8 อุปกรณ์และเครื่องมือที่ใช้.....	26
<b>บทที่ 4 รายละเอียดของโครงการ</b>	
4.1 ขั้นตอนการใช้งาน.....	27
4.2 ขั้นตอนการวิเคราะห์ข้อมูล.....	27
<b>บทที่ 5 สรุปผลและข้อเสนอแนะ</b>	
5.1 สรุปผลโครงการ.....	37
5.2 สรุปผลการปฏิบัติงานสหกิจศึกษา.....	37

## สารบัญ (ต่อ)

	หน้า
บรรณานุกรม.....	38
ภาคผนวก ก.....	40
ประวัตินักศึกษาสหกิจศึกษา .....	43





## สารบัญตาราง

หน้า

ตารางที่ 3.1 ระยะเวลาในการดำเนินงาน .....	25
-------------------------------------------	----



## สารบัญรูปภาพ

หน้า

รูปที่ 2.1 ระบบคำแนะนำของ Netflix .....	3
รูปที่ 2.2 วิธีการสำหรับระบบแนะนำ .....	4
รูปที่ 2.3 ตัวอย่างของเทคนิคการกรองแบบอิงเนื้อหา.....	4
รูปที่ 2.4 ตัวอย่างของคำแนะนำภาพยนตร์สำหรับผู้ใช้งาน Netflix .....	5
รูปที่ 2.5 การสร้าง User Vector .....	5
รูปที่ 2.6 เวกเตอร์รายการสำหรับภาพยนตร์ .....	6
รูปที่ 2.7 การคูณเวกเตอร์ 2 มิติ.....	6
รูปที่ 2.8 ตัวอย่างการแนะนำแบบ User-based .....	7
รูปที่ 2.9 ตัวอย่างการแนะนำแบบ Item-based .....	8
รูปที่ 2.10 เทคนิคการกรองข้อมูลแบบพึ่งพาผู้ใช้ร่วมแต่ละประเภท .....	8
รูปที่ 2.11 ความสัมพันธ์ระหว่างผู้ใช้งาน .....	9
รูปที่ 2.12 ความสัมพันธ์ระหว่างสินค้า.....	10
รูปที่ 2.13 เวกเตอร์แต่ละผู้ใช้งานที่ให้ความสำคัญกับคุณลักษณะของโรงแรม .....	10
รูปที่ 2.14 คุณลักษณะของโรงแรม .....	11
รูปที่ 2.15 ตัวอย่างการคัดเอาผู้ใช้งาน B จะมีความชื่นชอบโรงแรมใดระบบ .....	12
รูปที่ 2.16 เมทริกซ์ของผู้ใช้งานและการให้คะแนน .....	12
รูปที่ 2.17 ตัวอย่างการแยกตัวประกอบของเมทริกซ์ .....	13
รูปที่ 2.18 การหาเมทริกซ์ของผู้ใช้งาน X และเมทริกซ์ของสินค้า Y .....	14
รูปที่ 2.19 ตัวอย่างของระบบแนะนำแบบผสมผสาน .....	14
รูปที่ 2.20 การหาความคล้ายคลึงแบบโคไซน์ .....	15
รูปที่ 2.21 การประยุกต์ใช้การหาความคล้ายคลึงแบบโคไซน์ .....	16
รูปที่ 2.22 ตัวอย่างการลดมิติของวิธี Non-negative Matrix Factorization .....	16
รูปที่ 2.23 แดชบอร์ดของระบบแนะนำ .....	18
รูปที่ 2.24 ขั้นตอนระบบการแนะนำหลักสูตรแบบผสมผสาน .....	19
รูปที่ 2.25 โครงสร้างของระบบแนะนำแบบผสมผสาน .....	20
รูปที่ 2.26 <a href="https://www.w3schools.com/python/default.asp">https://www.w3schools.com/python/default.asp</a> .....	21
รูปที่ 2.27 <a href="https://colab.research.google.com/?hl=th">https://colab.research.google.com/?hl=th</a> .....	22
รูปที่ 2.28 <a href="https://www.w3schools.com/sql/default.asp">https://www.w3schools.com/sql/default.asp</a> .....	22
รูปที่ 3.1 แผนที่บริษัท ยูไนเต็ลฟุตส์ จำกัด (มหาชน) .....	23

## สารบัญรูปภาพ (ต่อ)

	หน้า
รูปที่ 3.2 โครงสร้างการจัดองค์การและการบริหารงานขององค์กร .....	24
รูปที่ 4.1 ข้อมูลลูกค้าและรายการสินค้าการกรองข้อมูลแบบพึ่งพาผู้ใช้ร่วม .....	28
รูปที่ 4.2 ข้อมูลลูกค้าการกรองแบบอิงเนื้อหา.....	28
รูปที่ 4.3 การสร้างเมทริกซ์และจัดรูปแบบข้อมูล .....	29
รูปที่ 4.4 แปลงข้อมูลที่ NaN ให้เป็นค่า 0.0 .....	30
รูปที่ 4.5 นำข้อมูลเข้าอัลกอริทึม NMF .....	30
รูปที่ 4.6 การคำนวณหาค่าเมทริกซ์ตัวที่ 1 .....	31
รูปที่ 4.7 การคำนวณหาค่าเมทริกซ์ตัวที่ 2 .....	31
รูปที่ 4.8 การคำนวณเมทริกซ์ตัวที่ 1 กับ เทร็กซ์ตัวที่ 2.....	32
รูปที่ 4.9 ผลลัพธ์ที่ได้จากเทคนิคการกรองข้อมูลแบบพึ่งพาผู้ใช้ร่วม .....	32
รูปที่ 4.10 เพิ่มข้อมูลลูกค้าที่จะนำมาทดสอบ .....	33
รูปที่ 4.11 จัดการสร้างเมทริกซ์และจัดรูปแบบข้อมูล .....	34
รูปที่ 4.12 ทำการคัดลอกตารางเดิมมาใช้งาน.....	34
รูปที่ 4.13 ทำการลบข้อมูลข้อมูลในแถว .....	35
รูปที่ 4.14 ทำการดึงข้อมูลลูกค้าที่สมมติมาใส่ในตาราง .....	35
รูปที่ 4.15 ผลลัพธ์ที่ได้จากเทคนิคการกรองข้อมูลแบบอิงเนื้อหา .....	36
รูปที่ ก.1 ออกแบบ UX UI หน้าเว็บไซต์ .....	40
รูปที่ ก.2 เขียนโค้ดระบบแนะนำสินค้า .....	41
รูปที่ ก.3 ลองใช้เครื่องมือต่างๆในการวิเคราะห์ข้อมูล .....	41
รูปที่ ก.4 เลือกข้อมูลจาก Database.....	42
รูปที่ ก.5 คัดเลือกข้อมูลลง Excel .....	42

## บทที่ 1

### บทนำ

#### 1.1 ความเป็นมาและความสำคัญของปัญหา

เนื่องจากบริษัทยูไนเต็คฟูดส์เป็นบริษัทในเครือที่ใช้สำหรับขายสินค้าของบริษัทยูไนเต็คในรูปแบบแคชแวนหรือพอยท์ ออฟ เซลล์ โดยการขับรถไปหาลูกค้า ซึ่งภายในหน่วยงานมีพนักงานและข้อมูลลูกค้า อยู่เป็นจำนวนมาก จากที่ได้ร่วมงานกับแผนก ไอที และได้พบปัญหา ต้องการเพิ่มยอดขาย เพื่อเป็นการเพิ่มยอดขายให้กับผู้ประกอบการและนำเสนอผลิตภัณฑ์ที่มีอยู่ให้ตรงตามความต้องการลูกค้าและช่วยให้ลูกค้าตัดสินใจซื้อผลิตภัณฑ์ได้ง่ายขึ้น ระบบแนะนำสินค้าจึงเป็นวิธีที่จะช่วยให้ผู้ประกอบการสามารถเพิ่มรายได้และช่วยให้ผู้บริโภคได้รับสินค้าตรงตามความชื่นชอบหรือสนใจ

ดังนั้นผู้จัดทำจึงมีแนวความคิดที่จะสร้างระบบแนะนำ (Recommendation System) คือระบบที่ทำการแนะนำสินค้าหรือบริการช่วยเพิ่มความสะดวกให้กับผู้ใช้งานในการเลือกซื้อสินค้าและบริการสามารถเพิ่มยอดขายให้กับทางบริษัท โดยระบบจะแนะนำสินค้าที่คาดว่าผู้ใช้ให้ความสนใจ ระบบแนะนำจึงมีความสำคัญในการกระตุ้นยอดขายซึ่งถูกนำมาใช้อย่างแพร่หลายบนเว็บไซต์หรือแอปพลิเคชัน

จากปัญหาที่กล่าวมาข้างต้นผู้จัดทำจึงนำเอา ระบบแนะนำสินค้า เข้ามาประยุกต์ใช้กับข้อมูลลูกค้าและข้อมูลสินค้าภายในบริษัทยูไนเต็คฟูดส์ ทำให้สามารถแนะนำสินค้าให้กับลูกค้าได้ง่าย สะดวกรวดเร็วยิ่งขึ้น ดังนั้นระบบแนะนำสินค้าจึงถูกสร้างขึ้นเพื่ออำนวยความสะดวกให้แก่พนักงานขายภายในบริษัทยูไนเต็คฟูดส์

## 1.2 วัตถุประสงค์ของโครงการ

1.2.1 เพื่อเพิ่มความสะดวกรสบายในการขายของพนักงานขาย แนะนำสินค้าให้ลูกค้าใหม่และเก่าได้อย่างรวดเร็ว

1.2.2 เพื่อเพิ่มยอดขายจากการแนะนำสินค้าที่ลูกค้าไม่เคยซื้อ

## 1.3 ขอบเขตของโครงการ

1.3.1 ผู้ใช้สามารถแนะนำสินค้าให้กับลูกค้าประจำได้

1.3.2 ผู้ใช้สามารถแนะนำสินค้าให้กับลูกค้าใหม่ได้

## 1.4 ประโยชน์ที่คาดว่าจะได้รับ

1.4.1 เพิ่มยอดขายให้กับบริษัทและพนักงานสามารถทำงานได้อย่างสะดวก และง่าย  
ขึ้นกว่าระบบเดิม

1.4.2 นำระบบแนะนำสินค้าไปประยุกต์ใช้ในการเพิ่มยอดขายสินค้าในรายการอื่นได้




## บทที่ 2

### แนวคิดทฤษฎี และงานวิจัยที่เกี่ยวข้อง

#### 2.1 แนวความคิด


##### 2.1.1 ระบบแนะนำ (Recommendation System)

ระบบแนะนำคือระบบที่มีไว้เพื่อแนะนำสินค้าหรือบริการให้กับผู้ใช้งานซึ่งจะช่วยแนะนำสินค้าให้กับผู้ใช้งานในการเลือกซื้อสินค้าและบริการต่าง ๆ ระบบจะทำหน้าที่ช่วยในการแนะนำสินค้าโดยอ้างอิงจากข้อมูลและประวัติการใช้งานของผู้ใช้บริการระบบจะทำการเรียนรู้จากพฤติกรรมประวัติการใช้งาน เพื่อที่จะทำการแนะนำสินค้าให้ตรงตามความต้องการของผู้ใช้งาน ทำให้เกิดประโยชน์ในด้านการใช้งาน โดยที่ผู้ใช้งานจะไม่เสียเวลาในการค้นหาสินค้าหรือบริการ ซึ่งระบบแนะนำได้ถูกนำมาใช้งานเพื่อแนะนำสินค้าและบริการอย่างมาก (Saniya Parveez, 2020)



ภาพประกอบ 2.1 ระบบคำแนะนำของ Netflix

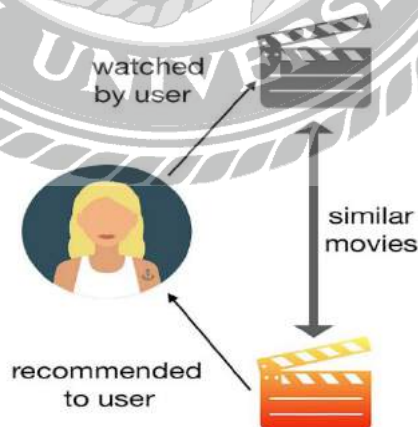
ที่มา : <https://pub.towardsai.net/recommendation-system-in-depth-tutorial-with-python-for-netflix-using-collaborative-filtering-533ff8a0e444>



ภาพประกอบ 2.2 วิธีการสำหรับระบบแนะนำ

### 2.1.2 การกรองแบบอิงเนื้อหา (Content-Based Filtering)

เทคนิคการกรองแบบอิงเนื้อหาคือการแนะนำสินค้าหรือบริการที่ได้มาจากการพิจารณาความคล้ายคลึงของพฤติกรรมจากประวัติการใช้งานของผู้ใช้งาน โดยจะดูจากลักษณะของสินค้าที่จะแนะนำและจะทำการแนะนำสินค้าที่มีลักษณะใกล้เคียงที่ผู้ใช้งานเคยใช้หรือชื่นชอบ จากภาพประกอบ 4 ระบบจะทำการแนะนำเนื้อหาของหนังที่มีความคล้ายคลึงกับหนังที่ผู้ใช้งานเคยดูมาก่อนหน้านั้น ซึ่งข้อดีของเทคนิคการกรองแบบอิงเนื้อหา นั้นคือไม่ต้องใช้ข้อมูลจำนวนมากในการประมวลผลเพื่อแนะนำสินค้า และการแนะนำสินค้าใหม่ที่ยังไม่มีข้อมูลสามารถทำได้เพราะจะพิจารณาจากความคล้ายคลึงกับลักษณะสินค้าประเภทเดิม ส่วนข้อเสียของเทคนิคการกรองแบบอิงเนื้อหาจะไม่สามารถแนะนำสินค้าที่มีความแตกต่างจากสินค้าประเภทที่ผู้ใช้งานเคยซื้อหรือใช้บริการทำให้ผู้ใช้งานไม่ได้รับการแนะนำสินค้าที่มีความหลากหลาย (Balu, 2019)



ภาพประกอบ 2.3 ตัวอย่างของเทคนิคการกรองแบบอิงเนื้อหา

ที่มา : <https://towardsdatascience.com/how-to-build-from-scratch-a-content-based-movie-recommender-with-natural-language-processing-25ad400eb243>






Movies	Reviews Given	Rating
Mission Impossible	✓	Good
James Bond	✓	Good
Toy Story	✓	Bad

ภาพประกอบ 2.4 ตัวอย่างของคำแนะนำภาพยนตร์สำหรับใช้งาน Netflix

ที่มา : <https://medium.com/@bindhubalu/content-based-recommender-system-4db1b3de03e>

จากภาพประกอบ 2.4 ตัวอย่างของคำแนะนำภาพยนตร์สำหรับใช้งานใน Netflix โดยใช้ชื่อโปรไฟล์ Nikhil ในกรณีที่ Nikhil ให้คะแนนที่ดีกับหนังเรื่อง Mission Impossible และ James Bond ที่ถูกจัดเป็นประเภทหนังบู๊ และให้คะแนนต่ำกับหนังเรื่อง Toy Story ที่ถูกจัดเป็นประเภทหนังสำหรับเด็ก ก็จะสามารถทำการสร้างเวกเตอร์ของใช้งานสำหรับ Nikhil ตามการให้คะแนน 3 อันดับ ดังภาพประกอบ 6 ในระดับคะแนน -10 ถึง 10 เนื่องจาก Nikhil ชอบภาพยนตร์ประเภทหนังบู๊ จึงได้กำหนดค่า 9 ให้กับ ประเภทหนังบู๊ และ Nikhil ยังไม่ได้ดูภาพยนตร์แอนิเมชัน จึงกำหนด 0 ให้กับประเภทแอนิเมชัน และเนื่องจาก Nikhil ได้ให้คำวิจารณ์ที่ไม่ดีสำหรับ ภาพยนตร์ที่ประเภทเด็กจึงกำหนด -6 ให้กับประเภทหนังสำหรับเด็ก (Prasad, 2020)




ภาพประกอบ 2.5 การสร้าง User Vector

ที่มา : <https://medium.com/@bindhubalu/content-based-recommender-system-4db1b3de03e7>



ดังนั้นเวกเตอร์ของ Nikhil จึงมีค่าเท่ากับ (9, 0, -6) ตามลำดับ (ประเภทหนัง, ประเภทแอนิเมชัน, ประเภทหนังสำหรับเด็ก) เวกเตอร์สำหรับภาพยนตร์เรื่อง Toy Story คือ (0, 1, 1) และภาพยนตร์เรื่อง Star Wars คือ (1, 0, 0) ตามลำดับ ตามภาพประกอบ 2.6



ภาพประกอบ 2.6 เวกเตอร์รายการสำหรับภาพยนตร์

ที่มา : <https://medium.com/@bindhubalu/content-based-recommender-system-4db1b3de03e7>

จากภาพประกอบ 2.7 การคูณเวกเตอร์ 2 มิติสองตัว คือเวกเตอร์ของรายการและเวกเตอร์ของผู้ใช้งาน ดังนั้นการคูณเวกเตอร์ของ Toy Story คือ -6 และ Star Wars คือ 9 จึงได้แนะนำหนังเรื่อง Star Wars ให้กับ Nikhil ซึ่งตรงกับความชอบของ Nikhil ที่ชอบดูหนังประเภทหนังบู๊และไม่ชอบภาพยนตร์สำหรับเด็ก ในลักษณะที่คล้ายกันนั้นเราสามารถคำนวณการคูณเวกเตอร์ของเวกเตอร์รายการทั้งหมดของภาพยนตร์ทั้งหมดในร้านค้าและแนะนำภาพยนตร์ 10 อันดับแรกให้กับ Nikhil

Dot product of 2-d vectors

$$v_1 = (x_1, y_1)$$

$$v_2 = (x_2, y_2)$$

$$v_1 \cdot v_2 = x_1x_2 + y_1y_2$$

ภาพประกอบ 2.7 การคูณเวกเตอร์ 2 มิติ

ที่มา : <https://medium.com/@bindhubalu/content-based-recommender-system-4db1b3de03e7>

### 2.1.3 การกรองข้อมูลแบบพึ่งพาผู้ใช้ร่วม (Collaborative Filtering)


การกรองข้อมูลแบบพึ่งพาผู้ใช้ร่วม คือการแนะนำสินค้าหรือบริการโดยพิจารณาจากความคล้ายคลึงกันกับผู้ใช้งานรายอื่นมาประกอบคำแนะนำด้วย โดยนำข้อมูลจากผู้ใช้งานรายอื่นมาทำการคาดเดาว่าผู้ใช้งานรายนี้จะมีความชื่นชอบสินค้าประเภทใด ซึ่งจะใช้หลักการของ The Wisdom of the Clouds คือฐานข้อมูลจะต้องมีค่า rating ของสินค้าหรือบริการของผู้ใช้งานแต่ละคนที่ผ่านมา

ข้อมูล rating สามารถนำมาใช้ในการแนะนำสินค้าได้ 2 วิธี ได้แก่ 1. User-Based คือผู้ใช้งานที่ถูกจัดอยู่ในกลุ่มประเภทเดียวกัน ซึ่งจะมีความชื่นชอบสินค้าชนิดเดียวกันจากภาพประกอบ 2.8 ถ้าผู้ใช้ 1 และผู้ใช้ 3 ชอบสินค้ารายการ 3 และ 4 เหมือนกัน ในกรณีที่ผู้ใช้ 1 ตั้งสินค้ารายการ 1 เพิ่มเติม ระบบแนะนำก็จะทำการแนะนำรายการสินค้า 1 ให้กับ ผู้ใช้ 3 ด้วยเช่นกัน 2. Item-Based คือสินค้าที่มีลักษณะใกล้เคียงกัน เช่น ถ้าสินค้ารายการ 1 และ 3 มีความคล้ายคลึงกัน ในกรณีที่ผู้ใช้ 1 ตัดสินใจเลือกซื้อสินค้ารายการ 1 โอกาสที่ผู้ใช้ 3 จะตัดสินใจเลือกซื้อสินค้ารายการ 1 ก็มีเช่นกัน โดยดูตัวอย่างได้จากภาพประกอบ 2.8 (Gross, 2023)



ภาพประกอบ 2.8 ตัวอย่างการแนะนำแบบ User-based

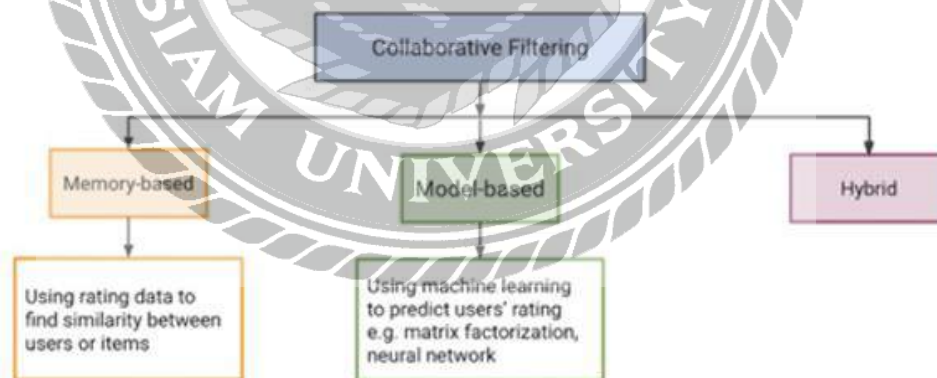
ที่มา : <https://levelup.gitconnected.com/the-mathematics-of-recommendation-systems-e8922a50bd>



ภาพประกอบ 2.9 ตัวอย่างการแนะนำแบบ Item-based

ที่มา : <https://levelup.gitconnected.com/the-mathematics-of-recommendation-systems-e8922a50bdea>

เทคนิคการกรองข้อมูลแบบพึ่งพาผู้ใช้งาน มีการนำข้อมูลจากผู้ใช้งานรายอื่นมาช่วยในการแนะนำ ว่าผู้ใช้งานรายนี้จะชื่นชอบสินค้าประเภทใด โดยรูปแบบของเทคนิคการกรองข้อมูลแบบพึ่งพาผู้ใช้งาน จะมีทั้งหมด 3 ประเภท ตามภาพประกอบ 2.10 ซึ่งงานวิจัยนี้จะมีการสร้างเทคนิคการกรองข้อมูลแบบพึ่งพาผู้ใช้งานจากประเภทของ Model-base



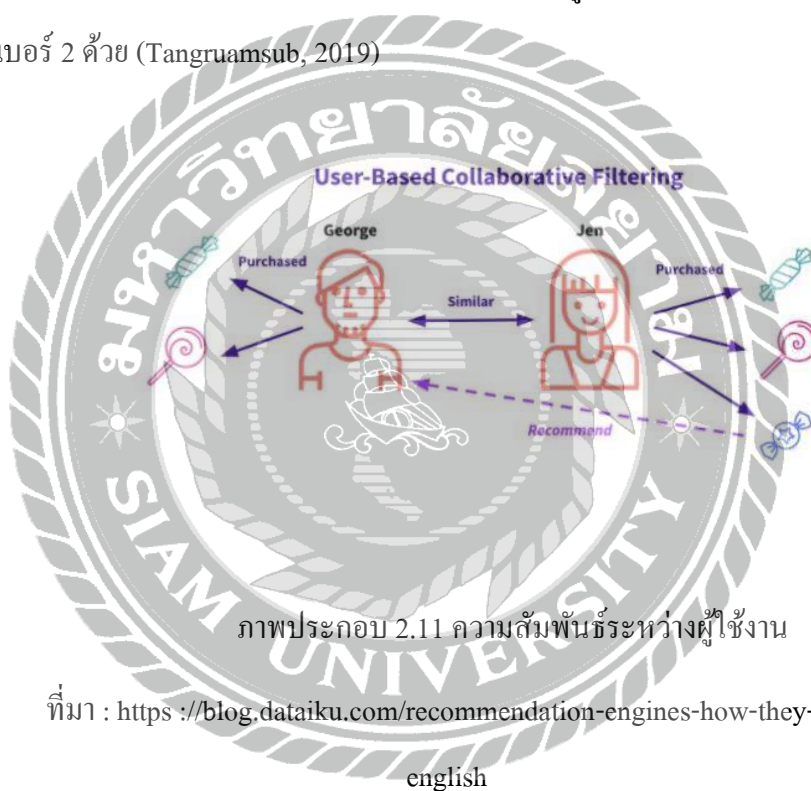
ภาพประกอบ 2.10 เทคนิคการกรองข้อมูลแบบพึ่งพาผู้ใช้งานแต่ละประเภท

ที่มา : <https://www.medium.com/@sinart.t/recommendation-system-แบบสรุปเอา>

เอง-ce6246f49754

### 2.1.4 การพิจารณาแบบจดจำ (Memory-based)

ดูจากข้อมูลและหาความสัมพันธ์ระหว่างผู้ใช้งานกับสินค้าการใช้ Nearest Neighbor ในการคาดเดา rating จากผู้ใช้งาน (user-based) หรือสินค้า (item-based) ที่มีความใกล้เคียงกัน จากภาพประกอบ 2.11 ข้อมูลจากผู้ใช้งาน (user-based) ถ้าคุณ George และคุณ Jen มีการใช้งานที่คล้ายคลึงกัน ในกรณีที่คุณ Jen ทำการสั่งซื้อสินค้าประเภทอื่นเพิ่มเติม ระบบแนะนำก็จะทำการแนะนำสินค้าชิ้นนี้ให้กับคุณ George ด้วยเช่นกัน และจากภาพประกอบ 2.12 ข้อมูลจากสินค้า เช่น ถ้าสินค้าเบอร์ 1 มีความคล้ายคลึงกับสินค้าเบอร์ 2 ในกรณีที่ผู้ใช้งานเลือกซื้อสินค้าเบอร์ 1 ก็อาจจะซื้อสินค้าเบอร์ 2 ด้วย (Tangruamsub, 2019)



ภาพประกอบ 2.11 ความสัมพันธ์ระหว่างผู้ใช้งาน

ที่มา : <https://blog.dataiku.com/recommendation-engines-how-they-work-in-plain-english>



ภาพประกอบ 2.12 ความสัมพันธ์ระหว่างสินค้า

ที่มา : <https://blog.dataiku.com/recommendation-engines-how-they-work-in-plain-english>

### 2.1.5 การพิจารณาแบบจำลอง (Model-based)






มีการใช้ Machine Learning เพื่อหา user embedding และ item embedding มาทำนาย rating ที่ผู้ใช้งานจะให้คะแนนกับสินค้า Model-based ส่วนใหญ่จะอยู่ในรูปแบบการใช้แบบจำลองหา user weight และ item weight เพื่อให้สามารถประเมินความชื่นชอบของผู้ใช้งานได้จากภาพประกอบ 2.13 ตัวอย่างเว็บไซต์การจองโรงแรม ในการเลือกโรงแรมนั้นผู้ใช้งานมักจะมีเกณฑ์ในการตัดสินใจเลือกโรงแรมที่ต่างกัน เช่น บางคนให้ความสำคัญกับตำแหน่งที่ตั้งโรงแรมหรือบางคนอาจจะให้ความสำคัญของรีวิวที่พักมากกว่า เป็น (Prasad, 2020)

	Star rating	location
A	0.3	0.7
B	0.1	0.9
C	0.8	0.2
D	0.15	0.85
E	0.5	0.5

ภาพประกอบ 2.13 เวกเตอร์แต่ละผู้ใช้งานที่ให้ความสำคัญกับคุณลักษณะของโรงแรม

ที่มา : <https://www.medium.com/@sinart.t/recommendation-system-แบบสรุปเอา>

hotel features คือคุณลักษณะของ โรงแรมแต่ละ โรงแรมว่ามีคะแนนในแต่ละด้านเป็นอย่างไร จากภาพประกอบ 2.14 ตัวเลขในแต่ละช่อง คือคะแนนของแต่ละหมวดหมู่ เช่น โรงแรมหมายเลข 5 มีคะแนนของ star rating 10 คะแนน หรือโรงแรมหมายเลข 10 นั้นมีคะแนนในส่วน ของ star rating อยู่ที่ 2 คะแนน ซึ่งไม่ดีมากนัก แต่ว่ามีคะแนนในส่วน ของ location ที่ดี

	1	2	3	4	5
					
Star rating	2.0	7.0	3.0	8.0	10.0
location	9.0	6.0	8.5	7.5	7.0

ภาพประกอบ 2.14 คุณลักษณะของ โรงแรม

ที่มา : <https://www.medium.com/@sinart.t/recommendation-system-แบบสรุปเอา>

เอง-ce6246f49754

จากข้อมูลเบื้องต้นนั้นสามารถทำการคาดเดาได้ว่าผู้ใช้งานแต่ละคนนั้นจะมีความชื่นชอบโรงแรมใดบ้าง เช่น ผู้ใช้งาน B มีความชื่นชอบโรงแรมหมายเลข 1 เนื่องจากผู้ใช้งาน B ให้ความสำคัญกับ location และ โรงแรมหมายเลข 1 ก็เป็น โรงแรมที่มี location ดีมาก ส่วนผู้ใช้งาน C อาจจะมี ความชื่นชอบโรงแรมหมายเลข 5 เนื่องจากผู้ใช้งาน C ชอบ โรงแรมที่มีคะแนน star rating ที่สูง ซึ่งการคาดเดาลักษณะแบบนี้สามารถนำ weight ของ users มาคูณกับคะแนนด้านต่าง ๆ ของโรงแรมได้เช่น เมื่อนำข้อมูลผู้ใช้งาน B มาทำการคาดเดาว่าในบรรดาทั้ง 5 โรงแรมนั้น ผู้ใช้งาน B จะมีความชื่นชอบโรงแรมใดมากที่สุด และนำ weight vector ของผู้ใช้งาน B มาคูณกับ

hotel features ตามภาพประกอบ 2.15 (Tangruamsub, 2019)





ภาพประกอบ 2.15 ตัวอย่างการคัดเอาผู้ใช้งาน B จะมีความชื่นชอบโรงแรมใด

ที่มา : <https://www.medium.com/@sinart.t/recommendation-system-แบบสรุปเอา>

[://www.medium.com/@sinart.t/recommendation-system-แบบสรุปเอา](https://www.medium.com/@sinart.t/recommendation-system-แบบสรุปเอา)

เอง-ce6246f49754

### 2.1.6 การแยกตัวประกอบเมทริกซ์ (Matrix Factorization)

Matrix Factorization คือการแยกตัวประกอบของเมทริกซ์ให้ได้เมทริกซ์ย่อยลงไป โดยที่ผลคูณของเมทริกซ์ย่อยนั้นจะได้เท่ากับเป็นเมทริกซ์ดั้งเดิม โดยทั่วไปจะใช้เป็นเมทริกซ์ของrating หรือการให้คะแนน rating ของแต่ละผู้ใช้งาน แต่ละสินค้านั้นจะทำการแยกเมทริกซ์ rating นี้ ออกเป็น 2 ส่วน ได้แก่ ส่วนที่เป็นเมทริกซ์ของผู้ใช้งาน X และเมทริกซ์ของสินค้า Y โดยเมื่อนำเมทริกซ์ทั้ง X และ Y มาคูณกันก็จะได้กลับมาเป็นเมทริกซ์ rating ดั้งเดิม (Bailey, 2016)

	Item 1	Item 2	Item 3	Item 4	Item 5
User 1	0	3	0	3	0
User 2	4	0	0	2	0
User 3	0	0	3	0	0
User 4	3	0	4	0	3
User 5	4	3	0	4	0

ภาพประกอบ 2.16 เมทริกซ์ของผู้ใช้งานและการให้คะแนน

ที่มา : <http://katbailey.github.io/post/matrix-factorization-with-tensorflow/>

จากภาพประกอบ 2.16 คือเมทริกซ์ของการให้คะแนนที่มีผู้ใช้งานเป็นแถวและรายการเป็นคอลัมน์ ซึ่งการแยกตัวประกอบเมทริกซ์ของเทคนิคการกรองข้อมูลแบบพึ่งพาผู้ใช้งานนั้นจะมีเมทริกซ์ 2 เมทริกซ์คือ users และ items โดยที่เมทริกซ์ของ user กับ item จะมีลักษณะที่บ่งบอกถึงความชอบหรือความใกล้เคียง และเมื่อนำเมทริกซ์มาคูณกันแล้วจะได้รับความชอบของ user ที่มีต่อ item นั้น ตามภาพประกอบ 2.17

	Feature 1	Feature 2
User 1	?	?
User 2	?	?
User 3	?	?
User 4	?	?
User 5	?	?

X

	Item 1	Item 2	Item 3	Item 4	Item 5
Feature 1	?	?	?	?	?
Feature 2	?	?	?	?	?

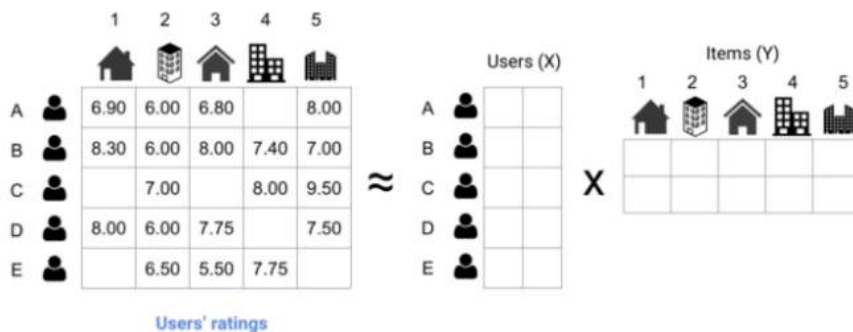
	Item 1	Item 2	Item 3	Item 4	Item 5
User 1	0	5	0	3	0
User 2	4	0	0	2	0
User 3	0	0	3	0	0
User 4	3	0	4	0	3
User 5	4	3	0	4	0

ภาพประกอบ 2.17 ตัวอย่างการแยกตัวประกอบของเมทริกซ์

ที่มา : <http://katbailey.github.io/post/matrix-factorization-with-tensorflow/>

จากภาพประกอบ 2.18 ในการเรียนรู้จะพยายามหาเมทริกซ์ของผู้ใช้งาน  $X$  และเมทริกซ์ของสินค้า  $Y$  เพื่อให้ได้ผลคูณของ  $X$  และ  $Y$  นั้นให้มีความใกล้เคียงกับเมทริกซ์ rating ของจริงให้ได้มากที่สุด โดยวิธีการนั้นก็สามารการใช้ SVD, PCA, NMF หรือ Gradient Descent ในส่วนของข้อดีนั้นการใช้ user และ item embedding ทำให้แบบจำลองสามารถเรียนรู้หาการแทนข้อมูลที่เหมาะสมได้และยังช่วยลดเรื่องมิติของข้อมูลได้อีกด้วย ในส่วนข้อเสียยังคงมีปัญหาสำหรับผู้ใช้งานใหม่หรือสินค้าใหม่ เช่น ในกรณีที่จะทำระบบแนะนำโรงแรมให้ผู้ใช้งาน จะไม่สามารถใช้ข้อมูลอื่น ๆ ที่ผู้ใช้งานจะใช้ในการค้นหาที่พัก ไม่ว่าจะเป็นจำนวนคนเข้าพัก เมืองที่ผู้เข้าพักหรือจำนวนวันเข้าพักมาร่วมใช้ในการทำนาย (Tangruamsub, 2019)



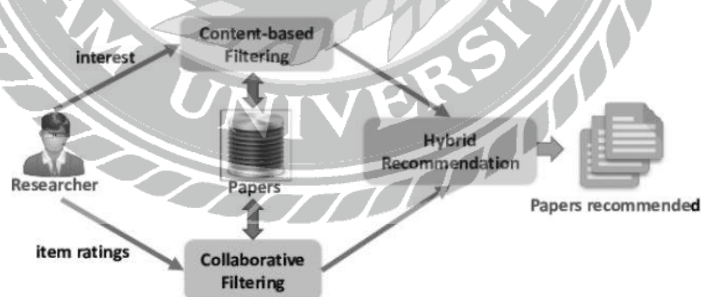


ภาพประกอบ 2.18 การหาเมทริกซ์ของผู้ใช้งาน X และเมทริกซ์ของสินค้า Y  
ที่มา : [https://www.medium.com/@sinart.t/recommendation-system-แบบสรุปเอา](https://www.medium.com/@sinart.t/recommendation-system-แบบสรุปเอาเอง-ce6246f49754)

เอง-ce6246f49754

### 2.1.7 ระบบแนะนำแบบผสมผสาน (Hybrid Recommendation System)

ระบบแนะนำแบบผสมผสานคือการใช้เทคนิคของระบบแนะนำสินค้ามากกว่า 2 เทคนิคขึ้นไป จากภาพประกอบ 2.19 ได้นำเทคนิคการกรองแบบอิงเนื้อหา และเทคนิคการกรองข้อมูลแบบพึ่งพาผู้ใช้ร่วม มาทำงานร่วมกันเพื่อทำให้ระบบแนะนำมีประสิทธิภาพการทำงานที่ดีขึ้น โดยจะนำจุดเด่นของเทคนิคหนึ่งไปปรับปรุงจุดด้อยของอีกเทคนิคหนึ่ง เช่น เมื่อมีสินค้าใหม่เข้ามา และยังไม่เคยมีประวัติการให้คะแนนทำให้ไม่สามารถแนะนำด้วยเทคนิคการกรองข้อมูลแบบพึ่งพาผู้ใช้ร่วม ได้ดังนั้นจึงนำวิธีการเทคนิคการกรองแบบอิงเนื้อหา มาช่วยสร้างโอกาสในการแนะนำสินค้าที่เข้ามาใหม่ (Kong, 2019)



ภาพประกอบ 2.19 ตัวอย่างของระบบแนะนำแบบผสมผสาน

ที่มา : [https://www.researchgate.net/figure/A-hybrid-paper-recommendation-](https://www.researchgate.net/figure/A-hybrid-paper-recommendation-system_fig5_330077673)

system\_fig5\_330077673

## 2.1.8 วิธีการวัดความคล้ายคลึง

### 2.1.8.1 ความคล้ายคลึงแบบโคไซน์ (Cosine Similarity)

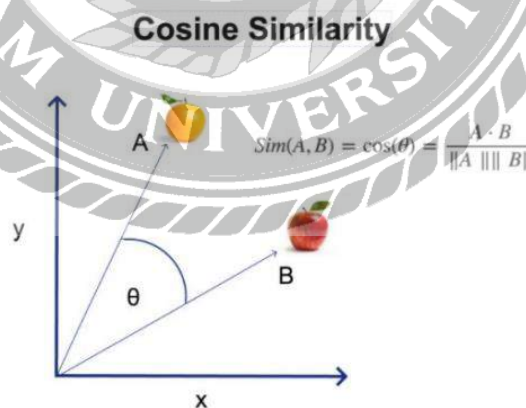
ความคล้ายคลึงแบบโคไซน์ คือการหาความเหมือนของข้อมูล โดยใช้ค่าโคไซน์จากการวัดค่าข้อมูลเป็นลายลักษณ์อักษรในเทคนิคการกรองแบบอิงเนื้อหา (Content-Based Filtering) จะถูกใช้เพื่อวัดความเหมือนระหว่างเวกเตอร์ของน้ำหนักราคาโคไซน์จะมีค่าอยู่ระหว่าง 0 ถึง 1 ยกตัวอย่างเช่น ค่า 1 หมายถึง ข้อมูล A และข้อมูล B มีลักษณะข้อมูลที่เหมือนกัน และส่วนของค่า 0 นั้นหมายถึงข้อมูล A และข้อมูล B มีลักษณะข้อมูลที่ไม่เหมือนกันดังสมการ (1) โดยมีที่มาจากกฎสามเหลี่ยมคือ  $\cos(\theta) = \text{ซิด/ฉาก}$  โดยที่ A และ B คือรายการที่ต่างกัน ตามภาพประกอบ 21 (Lin, 2018)

$$\text{similarity} = \cos(\theta) = \frac{\mathbf{A} \cdot \mathbf{B}}{\|\mathbf{A}\| \|\mathbf{B}\|} = \frac{\sum_{i=1}^n A_i B_i}{\sqrt{\sum_{i=1}^n A_i^2} \sqrt{\sum_{i=1}^n B_i^2}}, \quad (1)$$

เมื่อ  $A$  = รายการ A

$B$  = รายการ B


$n$  = จำนวนคู่ของรายการ A และรายการ B ทั้งหมด



ภาพประกอบ 2.20 การหาความคล้ายคลึงแบบโคไซน์

ที่มา : <https://www.linkedin.com/pulse/cosine-similarity-classification-michael-lin>

จากภาพประกอบ 2.21 การประยุกต์ใช้การหาความคล้ายคลึงแบบโคไซน์ การทำระบบแนะนำเพื่อดูว่าผู้ใช้งานส่วนใหญ่เมื่อซื้อสินค้า A แล้วจะมีโอกาสซื้อสินค้า B หรือ C เท่าไร



ภาพประกอบ 2.21 การประยุกต์ใช้การหาความคล้ายคลึงแบบโคไซน์  
ที่มา : <https://www.softnix.co.th/2019/05/29/similarity-ความเหมือนที่แตกต่าง>

## 2.1.9 อัลกอริทึมในการสร้างแบบจำลองเทคนิคการกรองข้อมูลแบบพึ่งพาผู้ใช้ร่วม

### 2.1.9.1 Non-negative Matrix Factorization (NMF)

Non-negative Matrix Factorization (NMF) ทำหน้าที่ลดมิติของข้อมูลโดยที่ข้อมูลจะไม่มีค่าเป็นลบ ผลลัพธ์จะได้เมทริกซ์ที่เป็นค่าบวกเท่านั้น ดังภาพประกอบ 2.22 (Kanoktipsatharporn, 2019)



ภาพประกอบ 2.22 ตัวอย่างการลดมิติของวิธี Non-negative Matrix Factorization  
ที่มา : <https://www.bualabs.com/archives/2971/lsa-latent-semantic-analysis-text-classification-singular-value-decomposition-svd-non-negative-matrix-factorization-nmf-nlp-ep-4>

## 2.2 งานวิจัยที่เกี่ยวข้อง

งานวิจัยนี้ได้ทำการศึกษาค้นคว้างานวิจัยที่เกี่ยวข้องกับเทคนิคการกรองแบบอิงเนื้อหา (Content-Based Filtering) และเทคนิคการกรองข้อมูลแบบพึ่งพาผู้ใช้ร่วม (Collaborative Filtering) โดยงานวิจัยที่เกี่ยวข้องมีรายละเอียดดังนี้

(1) บทความวิจัยเรื่อง Generating Items Recommendations by Fusing Content and User-Item based Collaborative Filtering (Tewari, 2020)

ปัจจุบันอีคอมเมิร์ซได้แพร่กระจายไปทั่วโลก ร้านค้าอิเล็กทรอนิกส์สามารถมีสินค้าได้หลายร้อย หรือหลายพันรายการ โดยไม่มีขอบเขต ซึ่งข้อมูลผลิตภัณฑ์เหล่านี้ทั้งหมดมีอยู่บนอินเทอร์เน็ต อีกทั้งยังมีข้อมูลของลูกค้าเป็นจำนวนมากระบบแนะนำจะค้นหาความสนใจของผู้ใช้งาน และแนะนำรายการที่ตรงกับความต้องการของผู้ใช้งานมากที่สุด เทคนิคที่ใช้ในการแนะนำสินค้าคือเทคนิคการกรองแบบอิงเนื้อหาและเทคนิคการกรองข้อมูลแบบพึ่งพาผู้ใช้ร่วมแนะนำรายการที่มีลักษณะคล้ายคลึงกับสินค้าที่ผู้ใช้งานเคยใช้ในอดีต ในส่วนของเทคนิค เทคนิคการกรองข้อมูลแบบพึ่งพาผู้ใช้ร่วม สร้างกลุ่มผู้ใช้ที่คล้ายกันและแนะนำรายการให้กับผู้ใช้งาน จุดประสงค์หลักของงานวิจัยนี้คือเพื่อลดจำนวนของสินค้าที่จะนำมาแนะนำลง เพื่อช่วยในการจัดวางสินค้าที่มีความสัมพันธ์กันให้ดียิ่งขึ้น ซึ่งผลการทดลองแสดงให้เห็นว่างานที่ทำขึ้นนั้น ดีกว่าวิธีการแนะนำแบบทั่วไป

(2) บทความวิจัยเรื่อง Combining Content-based and Collaborative Filtering for Personalized Sports News Recommendations (Lenhart Philip, Daniel Herzog, 2016)

ในการนำเสนอข่าวกีฬา ผู้อ่านมักจะมาพร้อมกับอารมณ์ที่แนบแน่นกับทีมกีฬาหรือผู้เล่น นอกจากนี้ความสนใจในหัวข้อของข่าวนั้นสามารถเปลี่ยนแปลงได้อย่างรวดเร็ว เช่น มีการแข่งขันกีฬาที่สำคัญเกิดขึ้นในงานนี้ ได้นำเสนอระบบผู้แนะนำข่าวกีฬาแบบไฮบริดที่รวมคำแนะนำตามเนื้อหาเข้ากับการกรองแบบร่วมมือมีพัฒนาแดชบอร์ดผู้แนะนำและรวมเข้ากับเว็บไซต์ Sport1.de จากภาพประกอบ 2.23 การพัฒนาวิดเจ็ตแดชบอร์ดซึ่งสามารถรวมเข้าด้วยกันได้ในเว็บไซต์ที่มีอยู่เพื่อให้คำแนะนำข่าวกีฬาส่วนบุคคล โดยแสดงภาพหน้าจอบริเวณของแดชบอร์ดผู้แนะนำของเรา มีการนำเสนอคำแนะนำรายการในครั้งเดียว เมื่อเลื่อนเมาส์ไปเหนือบทความหนึ่ง ผู้ใช้งานสามารถอ่าน ("Ansehen") หรือปฏิเสธคำแนะนำ ("Entfernen")



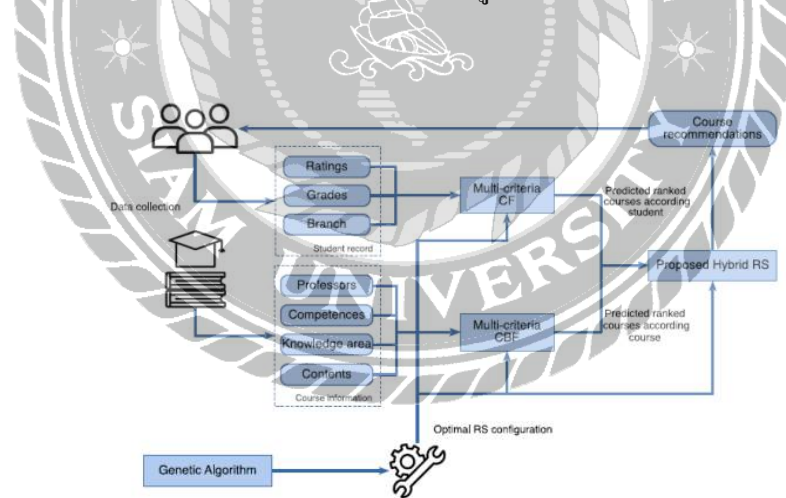
ภาพประกอบ 2.23 แดชบอร์ดของระบบแนะนำ

ที่มา : (Lenhart Philip, Daniel Herzog, 2016)

(3) บทความวิจัยเรื่อง Helping university students to choose elective courses by using a hybrid multi-criteria recommendation system with genetic optimization.

(Esteban,Zafra,Romero, 2020)

การศึกษาในระดับมหาวิทยาลัยมักจะมีหลักสูตรรายวิชาเลือกวิชาต่าง ๆ ซึ่งจะถูกละเลือกจากนักเรียนจำนวนมากในมหาวิทยาลัย นักเรียนจะใช้เวลาจำนวนมากในการค้นหาข้อมูลเกี่ยวกับหลักสูตรที่แตกต่างกันเพื่อการตัดสินใจเลือกรายวิชาให้เหมาะสมกับตัวเองมากที่สุด ในการตัดสินใจของนักเรียนอาจจะไม่ดีพอเนื่องจากนักเรียนมีข้อมูลไม่เพียงพอ ดังนั้นโดยทั่วไปนักเรียนอาจได้รับอิทธิพลจากความคิดเห็นของนักศึกษารายอื่น หรืออาจจะมีความชอบและความสนใจของนักเรียนมาเป็นเกณฑ์ในการพิจารณาร่วมด้วย วิธีในการแก้ไขปัญหานี้คือการใช้ระบบการแนะนำ (Recommendation System) ที่ช่วยให้นักเรียนตัดสินใจได้ดี โดยปรับตามความต้องการเฉพาะของตนเอง เทคนิคในการทำระบบแนะนำที่นิยมใช้คือเทคนิคการกรองข้อมูลแบบพึ่งพาผู้ใช้ร่วมและเทคนิคการกรองแบบอิงเนื้อหาจากภาพประกอบ 2.24 คือขั้นตอนของระบบการแนะนำหลักสูตรแบบผสมผสาน โดยเทคนิคการกรองข้อมูลแบบพึ่งพาผู้ใช้ร่วม แนะนำรายการที่อิงตามการให้คะแนนของผู้ใช้ที่คล้ายกัน ในขณะที่เทคนิคการกรองแบบอิงเนื้อหา แนะนำรายการที่อ้างอิงเนื้อหาของรายการที่คล้ายกันใน โปรไฟล์ผู้ใช้ โดยจะนำทั้งสองอัลกอริทึมนี้มาทำการแนะนำแบบผสมผสานเพื่อเพิ่มประสิทธิภาพในการแนะนำหลักสูตรรายวิชาเรียนให้กับนักเรียนได้ดีขึ้น



ภาพประกอบ 2.24 ขั้นตอนระบบการแนะนำหลักสูตรแบบผสมผสาน

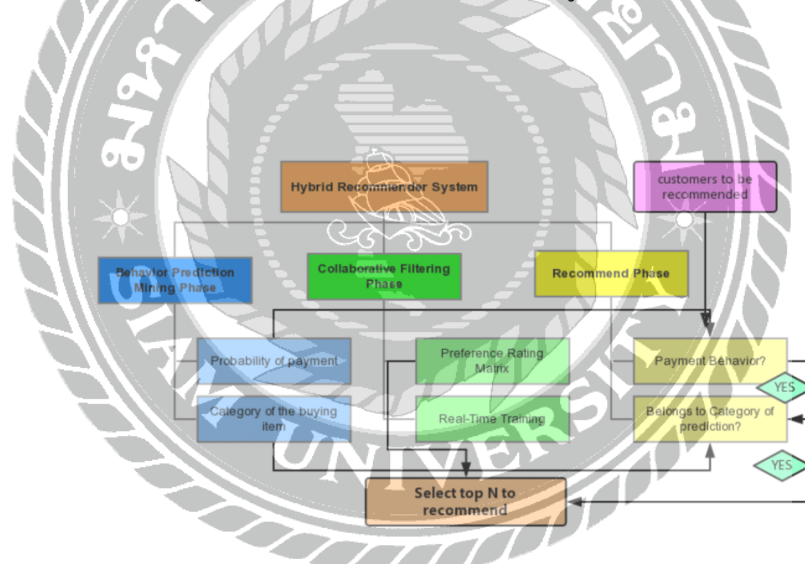
ที่มา : (Esteban,Zafra,Romero, 2020)



## (4) บทความวิจัยเรื่อง Hybrid Recommender System Based on Personal Behavior

Mining (Fang, 2016)

ระบบแนะนำเป็นที่รู้จักอย่างแพร่หลายจากเว็บไซต์อีคอมเมิร์ซ และส่วนใหญ่จะเป็นในรูปแบบของแบบจำลอง อัลกอริทึมที่ใช้แนะนำความชอบส่วนบุคคล ที่รวมถึงการแนะนำแบบพึ่งพาผู้ใช้ร่วม จาก item-based ที่ใช้ใน Amazon การแนะนำแบบพึ่งพาผู้ใช้ร่วมจาก matrix factorization based ที่ใช้กับ Netflix และวิธีอื่นอีกมากมาย ในบทความนี้ผู้วิจัยจะทำการรวมแบบจำลองแบบเดิม ๆ กับวิธีแบบ pattern extraction ซึ่งใช้ข้อมูล desensitized mobile transaction record ที่ได้มาจาก T-mal ของ Alibaba จากภาพประกอบ 2.25 จะทำการบันทึกการทำธุรกรรมซึ่งจัดทำโดย T-mall, Alibaba ซึ่งมีข้อมูลการซื้อในอดีตของผู้ใช้งาน โดยจะแบ่งพฤติกรรมที่แตกต่างกันของผู้บริโภคออกเป็น 4 ประเภทได้แก่ คลิก เลือก หยิบใส่รถเข็นและชำระเงิน เพื่อสร้างระบบแนะนำแบบผสมผสานที่แนะนำได้อย่างหลากหลาย sequential pattern mining มีจุดประสงค์เพื่อหาความถี่ของ รูปแบบตามลำดับใน ลำดับของฐานข้อมูล และจะนำไปใช้ในแบบจำลองแบบผสมผสานเพื่อใช้ทำนายพฤติกรรมทางการเงินของลูกค้า และมีส่วนในการเพิ่มความถูกต้องของแบบจำลอง

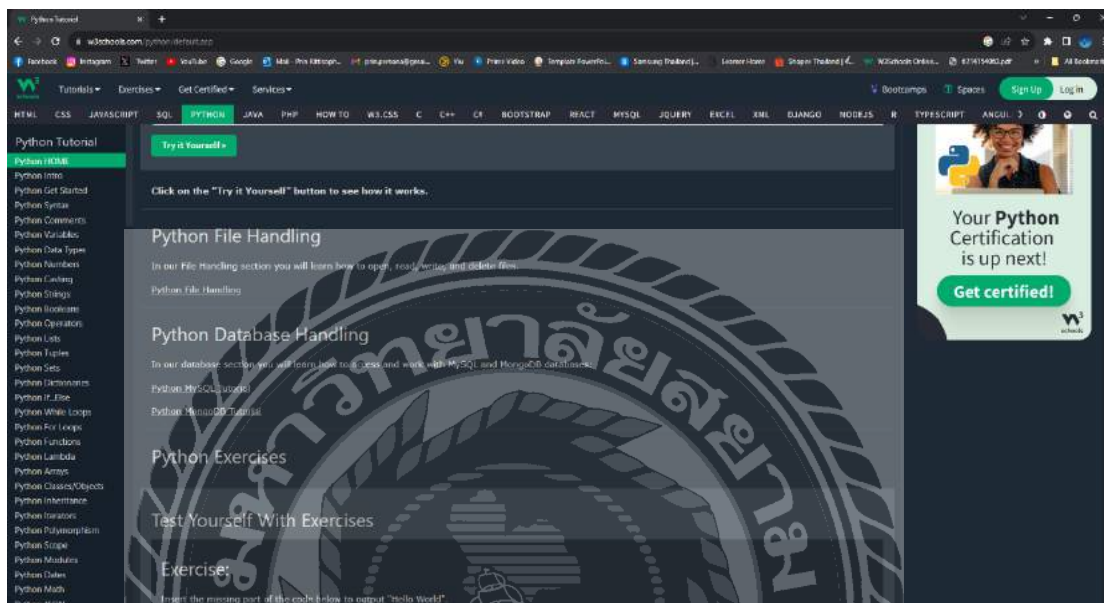


ภาพประกอบ 2.25 โครงสร้างของระบบแนะนำแบบผสมผสาน

ที่มา : (Fang, 2016)

### 2.3 เว็บไซต์ที่เกี่ยวข้อง

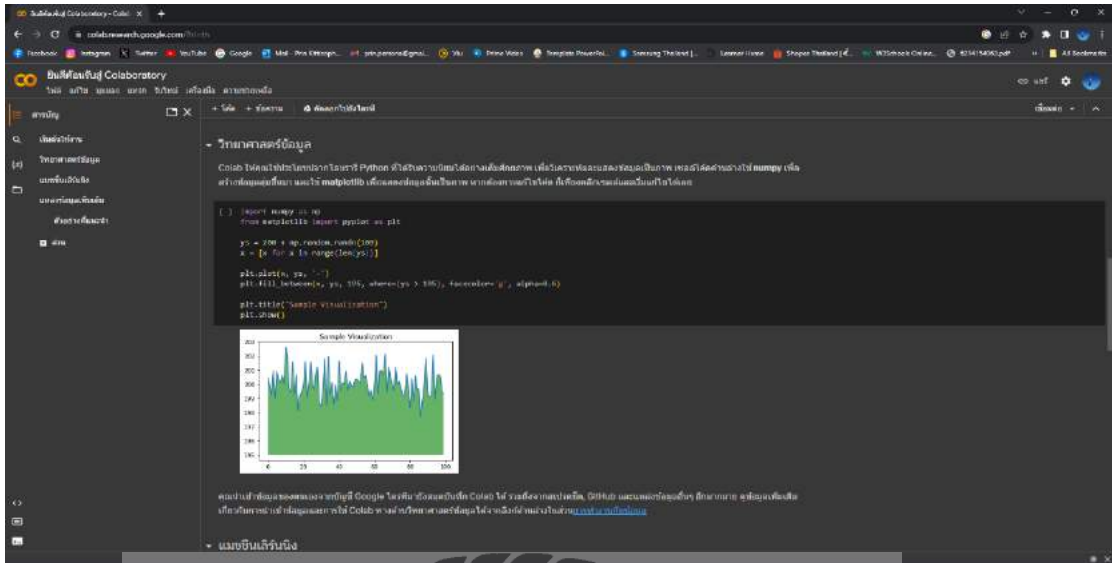
ผู้จัดทำได้ทำการค้นหาเว็บไซต์ที่เกี่ยวข้องกับการพัฒนาระบบ เนื่องจากมีประโยชน์ต่อการดำเนินโครงการในด้านการออกแบบเว็บไซต์ด้านการออกแบบฐานข้อมูลและการเขียนโปรแกรม โดยค้นหาจากเว็บไซต์ดังต่อไปนี้



รูปที่ 2.26 <https://www.w3schools.com/python/default.asp>

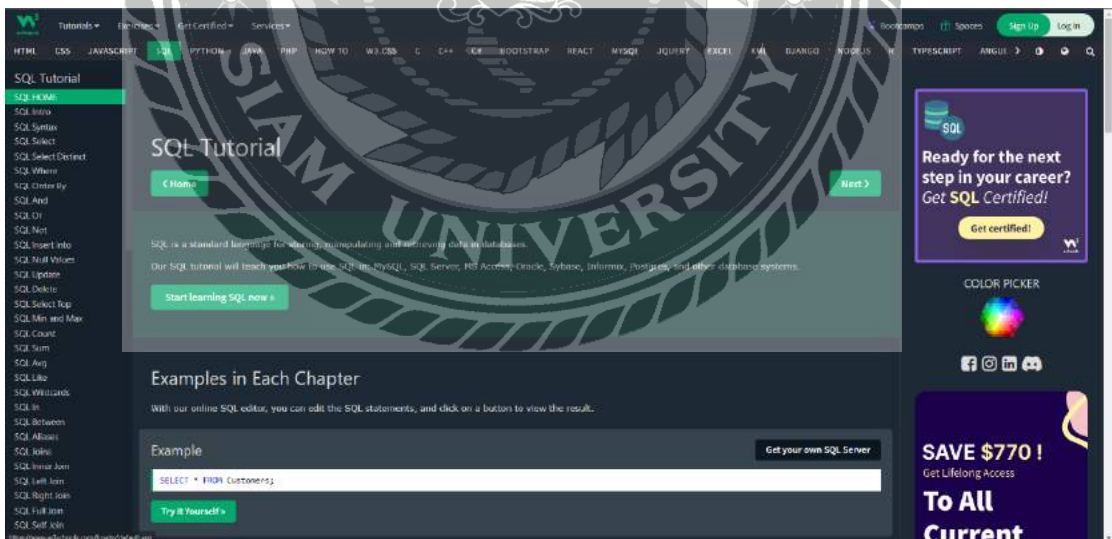
เป็นเว็บไซต์ที่สอนเกี่ยวกับการเขียนภาษา Python ไซต์ด้วยการเขียนคำสั่ง จะแสดงทั้งคำสั่งและผลลัพธ์ซึ่งสามารถเลือกดูได้ว่าต้องการแบบใด และเว็บไซต์นี้ยังสามารถเรียนรู้ได้หลายภาษา หลายระดับความยาก ตั้งแต่ขั้นพื้นฐานจนถึงขั้นสูง จึงเป็นที่นิยมมากในการศึกษาการเขียนโปรแกรมในภาษาต่างๆ





รูปที่ 2.27 <https://colab.research.google.com/?hl=th>

เป็นเว็บไซต์ที่ให้คุณใช้ประโยชน์จากไลบรารี Python ที่ได้รับความนิยมได้อย่างเต็มศักยภาพ เพื่อวิเคราะห์และแสดงข้อมูลเป็นภาพ เซลล์โค้ดด้านล่างใช้ Numpy เพื่อสร้างข้อมูลสุ่มขึ้นมา และใช้ matplotlib เพื่อแสดงข้อมูลนั้นเป็นภาพ หากต้องการแก้ไขโค้ด ก็เพียงคลิกเซลล์และเริ่มแก้ไขได้เลย



รูปที่ 2.28 <https://www.w3schools.com/sql/default.asp>

เป็นเว็บไซต์ที่สอนเกี่ยวกับการเขียนภาษา SQL ด้วยการเขียนคำสั่ง จะแสดงทั้งคำสั่งและผลลัพธ์ซึ่งสามารถเลือกดูได้ว่าต้องการแบบใด และเว็บไซต์นี้ยังสามารถเรียนรู้ได้หลายภาษาหลายระดับความยาก ตั้งแต่ขั้นพื้นฐานจนถึงขั้นสูง จึงเป็นที่นิยมมากในการศึกษาการเขียนโปรแกรมในภาษาต่างๆ

### บทที่ 3

#### รายละเอียดการปฏิบัติงาน


##### 3.1 ชื่อและที่ตั้งของสถานประกอบการ



บริษัท ยูโนเต็ดฟู้ดส์ จำกัด (มหาชน)

95 ถ. ท่าข้าม แขวงสามดํา เขตบางขุนเทียน กรุงเทพมหานคร 10150

โทรศัพท์ 0-2849-6600 โทรสาร 0-2849-6666



รูปที่ 3.1 แผนที่บริษัท ยูโนเต็ดฟู้ดส์ จำกัด (มหาชน)

### 3.2 ลักษณะการประกอบและการให้บริการหลัก

บริษัท ยูไนเต็ดฟู้ดส์ จำกัด (มหาชน) เป็นธุรกิจขนาดใหญ่นี้เป็นผู้ผลิตและจัดจำหน่าย แก่กลุ่มลูกค้าที่มีความสนใจ เช่น ห้างสรรพสินค้า ร้านขายของชำ เป็นต้น โดยมีศูนย์กระจายสินค้าอยู่ในจังหวัดต่างๆในประเทศ และบริษัทได้มีการติดต่อกับลูกค้าในต่างประเทศหลายๆ ประเทศ

### 3.3 รูปแบบการจัดองค์กรและการบริหารงานขององค์กร



รูปที่ 3.2 โครงสร้างการจัดองค์กรและการบริหารงานขององค์กร

#### งานแผนก IT

หน่วยงานแผนก IT เป็นหน่วยงานที่ให้บริการด้านสารสนเทศแก่งานของบริษัท ยูไนเต็ดฟู้ดส์ ทั้งงานด้านข้อมูลลูกค้า ข้อมูลการขาย การบำรุงรักษาซอฟต์แวร์คอมพิวเตอร์ และงานด้านระบบเครือข่ายหลักทั้งหมด รวมถึงการดูแล และพัฒนาเว็บไซต์การใช้งานด้านต่างๆ จึงเป็นหน่วยงานหลักที่มีประสิทธิภาพ และพร้อมให้บริการ

### 3.4 ตำแหน่งและลักษณะงานที่ได้รับมอบหมาย

นายปรินทร์ กิตติโสภณธรรม ตำแหน่ง หน่วยงาน IT  
งานที่ได้รับมอบหมาย คือ จัดการข้อมูลของหน่วยงานและนำเสนอข้อมูลให้กับผู้จัดการฝ่าย IT การทำโมเดลวิเคราะห์ข้อมูล การไปตรวจคลังสินค้า การเข้าประชุมบริษัท เป็นต้น

### 3.5 ชื่อและตำแหน่งงานของพนักงานที่ปรึกษา

คุณปรีชา ตั้งเกียรติกำจาย ผู้จัดการฝ่าย IT  
นายธิดิวฒ สีม่วง ตำแหน่ง พนักงาน IT

### 3.6 ระยะเวลาที่ปฏิบัติงาน

22 พฤษภาคม 2566 – กันยายน 2566

### 3.7 ขั้นตอนและวิธีการดำเนินงาน

ตารางที่ 3.1 แสดงระยะเวลาและขั้นตอนในการดำเนินงาน

ขั้นตอนการดำเนินงาน	พ.ค. 66	มิ.ย. 66	ก.ค. 66	ส.ค. 66
1.รวบรวมความต้องการและศึกษาความต้องการของโครงการ	←→			
2.จัดทำระบบ ปรับปรุงแก้ไขข้อบกพร่อง		←→		
3.นำระบบไปทดลองใช้งานจริง			←→	
4.สรุปผลความพึงพอใจ			←→	
5.ปรับแก้ไขตามความต้องการ			←→	
6.จัดทำเอกสาร	←→			

### 3.8 อุปกรณ์และเครื่องมือที่ใช้

#### 3.8.1 คุณสมบัติของฮาร์ดแวร์ผู้พัฒนาระบบ

- 1.ฮาร์ดแวร์สำหรับผู้พัฒนาระบบ
- 2.CPU CORE i5-1135G7 2.40 GHz
- 3.Hard Disk 1 TB.
- 4.DDR4 16.0 GB.
- 5.Mouse
- 6.Keyboard

#### 3.8.2 ฮาร์ดแวร์สำหรับผู้ใช้ระบบ

- 1.CPU CORE i5-1135G7 2.40 GHz
- 2.Hard Disk 512 GB.
- 3.DDR4 16.0 GB.
- 4.Mouse
- 5.Keyboard

### 3.9 คุณสมบัติของซอฟต์แวร์

#### 3.9.1 ซอฟต์แวร์สำหรับผู้พัฒนาระบบ

- 1.Microsoft Windows 11
- 2.Microsoft Excel 2019
- 3.Microsoft SQL Server 2019
- 4.Google Chrome Version 116.0.5845.111 (64-bit)

#### 3.9.2 ซอฟต์แวร์สำหรับผู้ใช้ระบบ

- 1.Microsoft Windows 11
- 2.Microsoft Excel 2019
- 3.Google Chrome Version 116.0.5845.111 (64-bit)

## บทที่ 4

### ผลการปฏิบัติงานตามโครงการ

#### 4.1 รายละเอียดของโครงการ

ภาพรวมเป็นการวิเคราะห์ข้อมูลธุรกิจเป็นการนำข้อมูลของลูกค้ามาวิเคราะห์เพื่อนำไปสู่การแนะนำสินค้าและสนับสนุนการตัดสินใจต่อยอดในแผนกลยุทธ์ทางธุรกิจต่อไปตามความต้องการของลูกค้าโดยการพัฒนาโครงการนี้เป็นการนำเสนอให้กับทีมงานในบริษัทเพื่อที่จะนำไปต่อยอดในเชิงธุรกิจต่อไปได้โปรแกรมหลักที่ใช้ในการทำงานคือ Google Colab ในการทำ Data Science แล้วนำการแนะนำสินค้านำเสนอ โดยนำข้อมูลมาจาก Database ของบริษัท มาทำการวิเคราะห์ ใช้เทคนิคการกรองแบบอิงเนื้อหา (Content-Based Filtering) เพื่อทำการแนะนำสินค้าให้ลูกค้าใหม่และใช้เทคนิคการกรองข้อมูลแบบพึ่งพาผู้เข้าร่วม (Collaborative Filtering) เพื่อทำการแนะนำสินค้าให้ลูกค้าประจำในบางอย่างที่เขาไม่เคยซื้อ

#### 4.2 ขั้นตอนการวิเคราะห์ข้อมูล

เนื่องจากงานที่ได้รับมอบหมายนั้นมีการใช้ข้อมูลลูกค้าจริงไม่สามารถนำข้อมูลออกมาเผยแพร่ได้จึงสามารถแสดงตัวอย่างงานได้บางส่วนเท่านั้น โดยงานที่ได้รับมอบหมายมีลักษณะขั้นตอนทำงานดังนี้

##### 4.2.1 ศึกษาเครื่องมือการทำงาน

ผู้จัดทำได้ศึกษาภาษา Python และวิธีใช้ การทำงานต่าง ๆ ของ Google Colab

##### 4.2.2 กำหนดเป้าหมายในการวิเคราะห์ข้อมูล (Research Understanding)

เพื่อเพิ่มยอดขายและแนะนำสินค้าให้กับลูกค้าใหม่และลูกค้าประจำโดยดูจากความสัมพันธ์ของข้อมูล

##### 4.2.3 รวบรวมข้อมูล (Data Understanding)

ผู้จัดทำได้ศึกษาชุดข้อมูลที่ได้รับมอบหมายจากบริษัทข้อมูลชุดนี้เป็นข้อมูลการซื้อขายสินค้าโดยข้อมูลชุดนี้นำเข้าจาก Database และเปลี่ยนแปลงเป็นไฟล์ CSV เพื่อนำข้อมูลเข้าโมเดลใน Google Colab ในขั้นตอนถัดไป



```
[ ] datarecom = pd.read_csv('/data_recom.csv') #นำเข้าไฟล์ csv
datarecom.head() #แสดงข้อมูล
```

	CustomerID	ID	TotalOrderQty
0	103110301682	1	1
1	206101102034	1	2
2	1031101120477	1	1
3	206104602037	1	4
4	206104201277	1	3

```
▶ itemrecom = pd.read_csv('/data_item.csv') #นำเข้าไฟล์ csv
itemrecom.head()
```

	ProductID	ID	ProductRefCode	ProductName
0	30000048	1	30000048	ลูกอมรสบ๊วย 100 เม็ด 1x24x100
1	30000815	2	30000815	ลูกอม 123 ชีส รวมรส 1x24x100
2	30001003	3	30002926	โยโย่ โคลา 20g. 1x12x12
3	30001021	4	30001021	แท่ง ช็อกโกแลต 40g 1x6x12
4	30001080	5	30001080	แท่ง สตรอเบอร์รี่ 40g 1x6x12

รูปที่ 4.1 ข้อมูลลูกค้าและรายการสินค้าการกรองข้อมูลแบบพึ่งพาผู้ใช้ร่วม

```
[ ] df.head()
```

	CustomerID	ID	TotalOrderQty
0	01111111111	1	1
1	01111111111	2	1
2	01111111111	3	2
3	01111111111	6	3
4	01111111111	7	4

รูปที่ 4.2 ข้อมูลลูกค้าการกรองแบบอิงเนื้อหา



#### 4.2.4 เทคนิคการกรองข้อมูลแบบพึ่งพาผู้ใช้ร่วม (Collaborative Filtering)

สำหรับเทคนิคการกรองข้อมูลแบบพึ่งพาผู้ใช้ร่วม ใช้ไลบรารี Pandas และ Numpy มาช่วยในการสร้างแบบจำลองการแนะนำสินค้า ซึ่งใช้อัลกอริทึม NMF โดยพิจารณาจากค่าความคล้ายคลึงแบบโคไซน์

```

Create User X Rating matrix

[ ] from google.colab import drive #นำเข้าไฟล์จาก drive
    drive.mount('/content/drive')

Drive already mounted at /content/drive; to attempt to forcibly remount, call drive.mount("/content/drive", force_remount=True).

[ ] cmat = pd.crosstab(datarecom['CustomerID'],datarecom['ID'],datarecom['TotalOrderQty'],aggfunc=sum) #แปลงข้อมูล

cmat

```

CustomerID	ID	1	2	3	6	7	8	9	14	15	16	...	288	290	291	292	293	295	296	297	299	304
103100905001		2.0	NaN	4.0	NaN	NaN	NaN	NaN	NaN	NaN	NaN	...	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN
103100905004		NaN	NaN	1.0	NaN	NaN	NaN	NaN	2.0	1.0	1.0	...	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN
103100905008		NaN	NaN	5.0	3.0	NaN	NaN	NaN	NaN	2.0	1.0	...	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN
103100905009		NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	...	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN
103100905013		NaN	NaN	1.0	NaN	NaN	NaN	NaN	1.0	NaN	NaN	...	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN
...		...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...
2061412050007		NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	...	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN
2061412050008		NaN	NaN	2.0	NaN	NaN	NaN	NaN	NaN	NaN	NaN	...	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN
2061412050009		NaN	NaN	NaN	NaN	NaN	NaN	NaN	1.0	NaN	NaN	...	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN
2061412130001		NaN	NaN	3.0	4.0	NaN	NaN	NaN	6.0	6.0	8.0	...	NaN	NaN	3.0	NaN	3.0	NaN	NaN	3.0	3.0	NaN
2061414010001		NaN	NaN	1.0	NaN	NaN	NaN	NaN	NaN	NaN	NaN	...	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN

15539 rows x 224 columns

รูปที่ 4.3 การสร้างเมทริกซ์และจัดรูปแบบข้อมูล

จากรูปที่ 4.3 ทำการจัดรูปแบบข้อมูลให้อยู่ในการเข้าอัลกอริทึม NMF

```
[ ] cmat = cmat.fillna(0) #เปลี่ยน NaN เป็น 0
cmat
```

ID	1	2	3	6	7	8	9	14	15	16	...	288	290	291	292	293	295	296	297	299	304	
CustomerID																						
103100905001	2.0	0.0	4.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	
103100905004	0.0	0.0	1.0	0.0	0.0	0.0	0.0	2.0	1.0	1.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	
103100905008	0.0	0.0	5.0	3.0	0.0	0.0	0.0	0.0	2.0	1.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	
103100905009	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	
103100905018	0.0	0.0	1.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	
...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	
2061412050007	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	
2061412050008	0.0	0.0	2.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	
2061412050009	0.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	
2061412130001	0.0	0.0	3.0	4.0	0.0	0.0	0.0	6.0	6.0	8.0	...	0.0	0.0	3.0	0.0	3.0	0.0	0.0	3.0	3.0	0.0	
2061414010001	0.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	

15539 rows x 224 columns

รูปที่ 4.4 แปลงข้อมูลที่ NaN ให้เป็นค่า 0.0

จากรูปที่ 4.4 ทำการแปลงข้อมูล NaN ให้เป็นค่า 0.0 เพื่อที่จะนำไปคูณกับข้อมูลในเมทริกซ์

```
[ ] from sklearn.decomposition import NMF #นำเข้า libraries NMF
nmf = NMF(50) #แบ่ง 50 กลุ่มที่คล้ายคลึงกัน
nmf.fit(cmat) #คำนวณจาก cmat ตัวแปรที่ประกาศ
```

NMF  
NMF(n\_components=50)

```
[ ] cmat
```

ID	1	2	3	6	7	8	9	14	15	16	...	288	290	291	292	293	295	296	297	299	304	
CustomerID																						
103100905001	2.0	0.0	4.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	
103100905004	0.0	0.0	1.0	0.0	0.0	0.0	0.0	2.0	1.0	1.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	
103100905008	0.0	0.0	5.0	3.0	0.0	0.0	0.0	0.0	2.0	1.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	
103100905009	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	
103100905018	0.0	0.0	1.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	
...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...
2061412050007	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	
2061412050008	0.0	0.0	2.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	
2061412050009	0.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	
2061412130001	0.0	0.0	3.0	4.0	0.0	0.0	0.0	6.0	6.0	8.0	...	0.0	0.0	3.0	0.0	3.0	0.0	0.0	3.0	3.0	0.0	
2061414010001	0.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	

15539 rows x 224 columns

รูปที่ 4.5 นำข้อมูลเข้าอัลกอริทึม NMF

จากรูปที่ 4.5 แบ่งกลุ่มลูกค้าออกมา 50 กลุ่มที่มีรูปแบบการซื้อสินค้าคล้ายคลึงกัน

```
reconstructed = pd.DataFrame(np.round(np.dot(W,H),2), columns=cmat.columns) #คำนวณหาค่าเมทริกซ์ W และ H นำมาคูณกัน
reconstructed.index = cmat.index #เติมค่าลงใน cmat
reconstructed
```

ID	1	2	3	6	7	8	9	14	15	16	...	288	290	291	292	293	295	296	297	299	304
CustomerID																					
103100905001	0.61	0.40	3.11	0.56	0.43	0.00	0.00	0.09	0.08	0.22	...	0.02	0.00	0.01	0.00	0.04	0.01	0.00	0.01	0.09	0.02
103100905004	0.01	0.09	0.24	0.00	0.03	0.00	0.00	3.08	1.25	0.56	...	0.00	0.00	0.01	0.00	0.01	0.00	0.00	0.02	0.01	0.01
103100905008	1.21	0.65	2.90	0.70	0.63	0.00	0.00	0.02	2.00	1.12	...	0.08	0.00	1.83	0.00	1.34	0.03	0.00	0.81	1.00	0.16
103100905009	0.00	0.04	0.11	0.03	0.00	0.00	0.00	0.00	0.00	0.00	...	0.00	0.00	0.04	0.00	0.01	0.00	0.00	0.01	0.06	0.01
103100905018	0.30	0.20	0.12	0.01	0.21	0.00	0.00	0.00	0.04	0.00	...	0.00	0.00	0.03	0.00	0.01	0.00	0.00	0.00	0.03	0.02
...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...
2061412050007	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	...	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
2061412050008	0.00	0.00	0.19	0.00	0.00	0.00	0.00	0.00	0.00	0.00	...	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
2061412050009	0.00	0.00	0.09	0.00	0.00	0.00	0.00	0.00	0.00	0.00	...	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
2061412130001	0.64	0.48	3.34	1.78	0.27	0.54	0.34	6.67	7.84	3.86	...	0.39	0.01	10.77	0.01	8.03	0.12	0.24	4.42	4.81	0.79
2061414010001	0.00	0.00	0.10	0.00	0.00	0.00	0.00	0.00	0.00	0.00	...	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00

15539 rows x 224 columns

รูปที่ 4.8 ผลการคำนวณเมทริกซ์ตัวที่ 1 กับ เมทริกซ์ตัวที่ 2

```
import re

def recommendation(uid,topk=5): #หา Top 5 index
    res = list(reconstructed.T[uid].sort_values(ascending=False)[0:topk].index)
    res = itemrecom[itemrecom['ID'].isin(res)]
    mList = datarecom[datarecom['CustomerID']!=uid][['ID', 'TotalOrderQty']] #หาข้อมูลการซื้อสินค้าของลูกค้าตามสินค้าที่หาได้
    #return mList, res
    res = res.merge(mList,on='ID',how='left') #จะมีสินค้าที่เขาเคยซื้อกับไม่เคยซื้อ
    #return res
    res = res[['ID', 'ProductID', 'ProductName', 'TotalOrderQty']]
    return res

res = recommendation(2061414010001,topk=10)
res
```

	ID	ProductID	ProductName	TotalOrderQty
0	24	30001781	โยโย่ อ่อน 20g 1x12x12 Pro	1.0
1	25	30001782	โยโย่ ร่มรส 20g 1x12x12 Pro	NaN
2	26	30001825	เขี้ยวไฮ เคลือบช็อกโกแลต 6g 1x36x15	1.0
3	27	30001827	เขี้ยวไฮ เคลือบชาชิลลา 6g 1x36x15	1.0
4	28	30001829	เขี้ยวไฮ เคลือบสตรอเบอร์รี่ 6g 1x36x15	1.0
5	30	30001831	เขี้ยวไฮ เคลือบนม 6g 1x36x15	1.0
6	45	30001975	โหมม ช็อกโกแลต 30g 1x12x12	1.0
7	47	30001978	โหมม นม 30 g. 1x12x12	NaN
8	48	30001979	โหมม สตรอเบอร์รี่ 30g 1x12x12	NaN
9	50	30002455	เขี้ยวไฮ ซูเปอร์จัมโบ้ รสช็อกโกแลต 34 g. 1x12x12	1.0

รูปที่ 4.9 ผลลัพธ์ที่ได้จากเทคนิคการกรองข้อมูลแบบฟังก์ชันผู้ใช้งาน

จากรูปที่ 4.9 จะทำการเลือกรหัสลูกค้า 2061414010001 มาทดสอบโดยเลือกสินค้าที่จะทำการแนะนำ 10 รายการโดยจะแนะนำสินค้าที่ลูกค้าเคยซื้อและไม่เคยซื้อ

#### 4.2.5 เทคนิคการกรองแบบอิงเนื้อหา (Content-Based Filtering)

สำหรับเทคนิคการกรองข้อมูลแบบอิงเนื้อหา ใช้ไลบรารี Pandas และ Numpy มาช่วยในการสร้างแบบจำลองการแนะนำสินค้าให้กับลูกค้าใหม่ซึ่งใช้อัลกอริทึม Cosine Math และทำการจำลองข้อมูลลูกค้าขึ้นมาใหม่และนำไปเทียบกับประวัติการซื้อของลูกค้าคนอื่นๆ โดยพิจารณาจากค่าความคล้ายคลึงแบบโคไซน์

```
data = {'CustomerID': ['0111111111'], 'ID': 1, 'TotalOrderQty': 1} # ข้อมูลลูกค้าเดิม
df = pd.DataFrame(data) # สร้าง DataFrame
print(df)
# เพิ่มลงใน DataFrame
new_row = {'CustomerID': '0111111111', 'ID': 2, 'TotalOrderQty': 1}
df = df.append(new_row, ignore_index=True)
new_row = {'CustomerID': '0111111111', 'ID': 3, 'TotalOrderQty': 2}
df = df.append(new_row, ignore_index=True)
new_row = {'CustomerID': '0111111111', 'ID': 6, 'TotalOrderQty': 2}
df = df.append(new_row, ignore_index=True)
new_row = {'CustomerID': '0111111111', 'ID': 7, 'TotalOrderQty': 4}
df = df.append(new_row, ignore_index=True)
print(df)
```

CustomerID	ID	TotalOrderQty
0	0111111111	1
0	0111111111	ID
1	0111111111	2
2	0111111111	3
3	0111111111	6
4	0111111111	4

```
df.head()
```

CustomerID	ID	TotalOrderQty
0	0111111111	1
1	0111111111	2
2	0111111111	3
3	0111111111	6
4	0111111111	7

รูปที่ 4.10 เพิ่มข้อมูลลูกค้าที่จะนำมาทดสอบ

จากรูปที่ 4.10 ทำการเพิ่มข้อมูลลูกค้าใหม่โดยสมมุติข้อมูลการซื้อสินค้า 5 ชนิด

```
[ ] cmat1 = pd.crosstab(df['CustomerID'],df['ID'],df['TotalOrderQty'],aggfunc=sum)
[ ] cmat1
```

ID	1	2	3	6	7
CustomerID					
0111111111	1	1	2	3	4

รูปที่ 4.11 จัดการสร้างเมทริกซ์และจัดรูปแบบข้อมูล

จากรูปที่ 4.11 ทำการจัดรูปแบบข้อมูลให้อยู่ในการเข้าอัลกอริทึม Cosine Math

```
cmat_copy = cmat.copy()
cmat_copy
```

ID	1	2	3	6	7	8	9	14	15	16	...	288	290	291	292	293	295	296	297	299	304	
CustomerID																						
103100905001	2.0	0.0	4.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
103100905004	0.0	0.0	1.0	0.0	0.0	0.0	0.0	2.0	1.0	1.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
103100905008	0.0	0.0	5.0	3.0	0.0	0.0	0.0	0.0	2.0	1.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
103100905009	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
103100905018	0.0	0.0	1.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...
2061412050007	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
2061412050008	0.0	0.0	2.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
2061412050009	0.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
2061412130001	0.0	0.0	3.0	4.0	0.0	0.0	0.0	6.0	6.0	8.0	...	0.0	0.0	3.0	0.0	3.0	0.0	0.0	0.0	3.0	3.0	0.0
2061414010001	0.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0

15539 rows x 224 columns

รูปที่ 4.12 ทำการคัดลอกตารางเดิมมาใช้งาน

จากรูปที่ 4.12 ทำการคัดลอกข้อมูลจากตารางเดิมเพื่อนำคอลัมน์ให้มีจำนวนเท่ากันเพื่อนำมาคูณเมทริกซ์ได้

```

▶ cmat_copy = cmat_copy.drop(index=cmat_copy.index,axis=0) #ลบข้อมูลทั้งหมด
  cmat_copy.head()

```

ID	1	2	3	6	7	8	9	14	15	16	...	288	290	291	292	293	295	296	297	299	304	
CustomerID																						

0 rows x 224 columns

รูปที่ 4.13 ทำการลบข้อมูลข้อมูลในแถว

```

▶ # ดึงข้อมูลจากแถวที่ 1
  row_to_add = cmat1.iloc[0:1]
  row_to_add

```

ID	1	2	3	6	7	
CustomerID	011111111111	1	1	2	3	4

```

[ ] test = pd.concat([row_to_add,cmat_copy.iloc[:]],reset_index(drop=True)) #เพิ่ม row to add ไป cmat_copy โดยตรงและ รีเซ็ต index
  test

```

ID	1	2	3	6	7	8	9	14	15	16	...	288	290	291	292	293	295	296	297	299	304
0	1.0	1.0	2.0	3.0	4.0	NaN	NaN	NaN	NaN	NaN		NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN

1 rows x 224 columns

```

[ ] test = test.fillna(0) #เปลี่ยน NaN เป็น 0
  test

```

ID	1	2	3	6	7	8	9	14	15	16	...	288	290	291	292	293	295	296	297	299	304
0	1.0	1.0	2.0	3.0	4.0	0.0	0.0	0.0	0.0	0.0		0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0

1 rows x 224 columns

รูปที่ 4.14 ทำการดึงข้อมูลลูกค้าที่สมมุติมาใส่ในตาราง

จากรูปที่ 4.14 ทำการดึงข้อมูลลูกค้าที่สมมุติมาใส่ในตาราง ทำการจัดรูปแบบและแปลงค่า NaN เป็น 0.0

```

Create Application

[ ] from scipy.spatial.distance import cosine #ดึง libraries cosinemath

similarity = []
for idx in range(len(reconstructed)): #วนลูปตัวค่าที่สร้างขึ้นมาสำหรับลูกค้าใหม่ ออกมาเทียบกับข้อมูลลูกค้าที่ละคน
    similarity.append(cosine(test.values.reshape(224),reconstructed.iloc[idx].values))
similarity = pd.Series(similarity).fillna(0).tolist()
close_to = np.argsort(similarity)[-1]
close_to #เทียบแล้วเลือกคนที่ 6417 ใน index

/usr/local/lib/python3.10/dist-packages/scipy/spatial/distance.py:622: RuntimeWarning: invalid value encountered in double_scalars
  dist = 1.0 - uv / np.sqrt(uu * vv)
6417

test.values.reshape(224)

(224,)

reconstructed.iloc[idx].values.shape

(224,)

recommendation(reconstructed.index[close_to],5) # เที่ยบตำแหน่งใน index ที่อีก 5

  ID  ProductID  ProductName  TotalOrderQty
0  46  30001976  โทนม ส้ม 30 g 1x12x12  2.0
1  47  30001978  โทนม นม 30 g 1x12x12  NaN
2  48  30001979  โทนม สตรอเบอรี่ 30g 1x12x12  NaN
3  50  30002455  เค้กช็อคชานเปอริงมิโงรสค็อกโกแลต 84 g 1x12x12  2.0
4  63  30002518  โทนมแพรว 30 g 1x12x12  NaN

reconstructed.index[close_to] #ตำแหน่ง 6417 คือรหัสลูกค้า 206130506002
206130506002

```

#### รูปที่ 4.15 ผลลัพธ์ที่ได้จากเทคนิคการกรองข้อมูลแบบอิงเนื้อหา

จากรูปที่ 4.15 จะทำการเลือกรหัสลูกค้า 0111111111 มาทดสอบโดยเลือกสินค้าที่จะทำการแนะนำ 5 รายการโดยจะแนะนำสินค้าที่ลูกค้าเคยซื้อและไม่เคยซื้อซึ่งจะทำการเทียบโคไซน์ว่ามี การซื้อคล้ายคลึงกับลูกค้าคนไหนตามรูปคือ ตำแหน่งที่ 6417 คือรหัสลูกค้า 206130506002 จึงทำการแนะนำสินค้าที่รหัสลูกค้า 206130506002 เลขซื้อให้กับรหัสลูกค้า 0111111111



## บทที่ 5

### สรุปผลและข้อเสนอแนะ

#### 5.1 สรุปผลโครงการ

##### 5.1.1 สรุปผลโครงการ

คณะนักศึกษาสหกิจศึกษาได้พัฒนาระบบแนะนำสินค้าของ บริษัท ยูไนเต็พดิส จำกัด (มหาชน) เพื่อนำมาใช้งานในการแนะนำสินค้าให้กับลูกค้าใหม่และลูกค้าประจำ เพื่อเพิ่มยอดขายและความรวดเร็วให้กับพนักงานขาย เช่น พนักงานขายต้องการแนะนำสินค้าให้ลูกค้าใหม่โดยดูจากรายการที่เขาต้องสั่งซื้อและแนะนำสินค้าที่เขาไม่เคยซื้อและลูกค้าประจำที่มีประวัติการซื้อสินค้านำมาเปรียบเทียบกับลูกค้าคนอื่นๆที่มีลักษณะการซื้อที่คล้ายกันนำมาแนะนำสินค้าที่เขาไม่เคยซื้อ

##### 5.1.2 ข้อจำกัดหรือปัญหาของโครงการ

5.1.2.1 นักศึกษายังไม่มีความชำนาญในการเขียนโปรแกรมภาษา Python จึงต้องใช้เวลาศึกษาเพิ่มเติม

5.1.2.2 นักศึกษายังไม่เข้าใจในระบบงานที่จะทำจึงต้องใช้เวลาในการศึกษา

##### 5.1.3 ข้อเสนอแนะ

5.1.3.1 ควรศึกษาด้านการพัฒนาโปรแกรมภาษา Python เพิ่มเติม

#### 5.2 สรุปผลการปฏิบัติงานสหกิจศึกษา

##### 5.2.1 ข้อดีของการปฏิบัติงานสหกิจศึกษา

5.2.1.1 ได้เรียนรู้ประสบการณ์ในการปฏิบัติงานจริงในการทำงานในสถานประกอบการใหญ่ๆ

5.2.1.2 พัฒนาศักยภาพด้านการพัฒนาโปรแกรมภาษา Python

5.2.1.3 ทำให้เข้าใจถึงกระบวนการทางธุรกิจ

##### 5.2.2 ปัญหาที่พบของการปฏิบัติงานสหกิจศึกษา

5.2.2.1 วันที่เริ่มปฏิบัติงานแรกๆไม่มีความรู้ในการแก้ไขปัญหา

5.2.2.2 ขาดประสบการณ์ในการปฏิบัติงานในรูปแบบขององค์กร

5.2.2.3 ขาดความรู้ความเข้าใจทางด้านกระบวนการทางธุรกิจ

##### 5.2.3 ข้อเสนอแนะ

5.2.3.1 ควรศึกษาจากการปฏิบัติงานสหกิจศึกษา เพื่อเป็นประสบการณ์ในการทำงาน

5.2.3.2 ควรศึกษากระบวนการทางธุรกิจให้เพิ่มมากขึ้น

## บรรณานุกรม

- Anand Shanker Tewari. (2020). *Generating Items Recommendations by Fusing Content and User-Item based Collaborative Filtering*. <https://www.sciencedirect.com/science/article/pii/S1877050920306803>
- Ankita Prasad. (2020). *The Mathematics of Recommendation Systems*. <https://levelup.gitconnected.com/the-mathematics-of-recommendation-systems-e8922a50bdea>
- Bindhu Balu. (2019). *Content-Based Recommendation System*. <https://medium.com/@bindhubalu/content-based-recommender-system-4db1b3de03e7>
- CHAKRIT. (2019). *Similarity*. <https://www.softnix.co.th/2019/05/29/similarity-ความเหมือนที่แตกต่าง>
- Esteban,Zafra,Romero. (2020). *Helping university students to choose elective courses by using a hybrid multi-criteria recommendation system with genetic optimization*. <https://www.sciencedirect.com/science/article/abs/pii/S0950705119306306>
- Google Colab. (2023). <https://colab.research.google.com/?hl=th>
- Katherine Bailey. (2016). *Matrix Factorization with Tensorflow*. <https://katbailey.github.io/post/matrix-factorization-with-tensorflow/>
- Katie Gross. (2023). *Recommendation Engines*. <https://blog.dataiku.com/recommendation-engines-how-they-work-in-plain-english>
- Lenhart Philip,Daniel Herzog. (2016). *Combining Content-based and Collaborative Filtering*. [http://www.di.uniba.it/~lops/CBRecSys/CBRecSys2016\\_proceedings.pdf#page=8](http://www.di.uniba.it/~lops/CBRecSys/CBRecSys2016_proceedings.pdf#page=8)
- Michael Lin. (2018). *Cosine Similarity & Classification*. <https://www.linkedin.com/pulse/cosine-similarity-classification-michael-lin>

*My SQL Database*. (2023). <https://www.w3schools.com/sql/default.asp>

*Python*. (2023). <https://www.w3schools.com/python/default.asp>

Roberto Iriondo Saniya Parveez. (2020). *Recommendation System Tutorial with Python using Collaborative Filtering*. <https://pub.towardsai.net/recommendation-system-in-depth-tutorial-with-python-for-netflix-using-collaborative-filtering-533ff8a0e444>

Sirinart Tangruamsub. (2019). *Recommendation System (แบบสรุปไม่ค่อยสั้น)*. <https://www.medium.com/@sinart.t/recommendation-system-แบบสรุปเอา>

Surapong Kanoktipsatharporn. (2019). *Latent Semantic Analysis (LSA) คืออะไร Text Classification ด้วย Singular Value Decomposition (SVD), Non-negative Matrix Factorization (NMF) – NLP*. <https://www.bualabs.com/archives/2971/lsa-latent-semantic-analysis-text-classification-singular-value-decomposition-svd-non-negative-matrix-factorization-nmf-nlp-ep-4/>

Xiangjie Kong. (2019). *A hybrid paper recommendation system*. [https://www.researchgate.net/figure/A-hybrid-paper-recommendation-system\\_fig5\\_330077673](https://www.researchgate.net/figure/A-hybrid-paper-recommendation-system_fig5_330077673)

Zhiyuan Fang. (2016). *Hybrid Recommender System Based on Personal Behavior Mining*. [https://www.researchgate.net/publication/305186147\\_Hybrid\\_Recommender\\_System\\_Based\\_on\\_Personal\\_Behavior\\_Mining](https://www.researchgate.net/publication/305186147_Hybrid_Recommender_System_Based_on_Personal_Behavior_Mining)




ภาคผนวก

ภาคผนวก ก

ภาพระหว่างปฏิบัติงาน



รูปที่ ก.1 ออกแบบ UX UI หน้าเว็บไซต์



รูปที่ ก.2 เขียนโค้ดระบบแนะนำสินค้า



รูปที่ ก.3 ลองใช้เครื่องมือต่างๆในการวิเคราะห์ข้อมูล





รูปที่ ก.4 เลือกข้อมูลจาก Database



รูปที่ ก.5 คัดเลือกข้อมูลลง Excel



## ประวัตินักศึกษาสหกิจศึกษา



รหัสนักศึกษา : 6305000007  
 ชื่อ-นามสกุล : นายปรินทร์  
 กิตติโสภณธรรม  
 ที่อยู่ : หมู่บ้านวินนิ่ง 98/8  
 ซ.ศาลธนบุรี44/2  
 ถ.กำนันแมน  
 แขวงบางหว้า  
 เขตภาษีเจริญ  
 กรุงเทพฯ 10160  
 เบอร์โทรศัพท์ : 090-992-1096  
 E-Mail : [printae\\_ss@hotmail.com](mailto:printae_ss@hotmail.com)  
 ระดับปริญญาตรี : มหาวิทยาลัยสยาม





<https://drive.google.com/drive/folders/1FnGHp9BcsuYCG-VGH6pG0ykV6AiSbV9b?usp=sharing>

รายงานการปฏิบัติงานสหกิจศึกษา

ระบบแนะนำสินค้า

PRODUCT RECOMMENDATION SYSTEM

โดย

นายปรินทร์ กิตติโสภณธรรม 6305000007

รายงานนี้เป็นส่วนหนึ่งของวิชา สหกิจศึกษา

ภาควิชาธุรกิจดิจิทัล

คณะเทคโนโลยีสารสนเทศ มหาวิทยาลัยสยาม

ภาคการศึกษาที่ 3 ปีการศึกษา 2565