

การแนะนำสินค้าด้วยรูปภาพสำหรับการขายสินค้าบนอินเทอร์เน็ต  
โดยใช้แนวทางการเรียนรู้เชิงลึก

IMAGE – BASED PRODUCT RECOMMENDATIONS FOR  
E – COMMERCE USING DEEP LEARNING APPROACH



การศึกษาค้นคว้าอิสระนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร  
ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการข้อมูลและการวิเคราะห์  
ศูนย์วิเคราะห์ข้อมูลดิจิทัลอัจฉริยะพระจอมเกล้าลาดกระบัง คณะวิทยาศาสตร์  
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง  
พ.ศ. 2567

KMITL-2024-SC-M-017-019

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

IMAGE – BASED PRODUCT RECOMMENDATIONS FOR  
E – COMMERCE USING DEEP LEARNING APPROACH



AN INDEPENDENT STUDY SUBMITTED IN PARTIAL FULFILLMENT OF  
THE REQUIREMENT FOR THE DEGREE OF  
MASTER OF SCIENCE IN DATA SCIENCE AND ANALYTICS  
KMITL DIGITAL ANALYTICS AND INTELLIGENCE CENTER SCHOOL OF SCIENCE  
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

2024

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น เมื่อนำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

KMITL-2024-SC-M-017-019



COPYRIGHT 2024

SCHOOL OF SCIENCE

**KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG**

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หัวข้อการค้นคว้าอิสระ	การแนะนำสินค้าด้วยรูปภาพสำหรับการขายสินค้าบนอินเทอร์เน็ตโดยใช้แนวทางการเรียนรู้เชิงลึก
ชื่อนักศึกษา	ปิยะวรรณ โนมะวงศ์
รหัสนักศึกษา	65056064
ปริญญา	วิทยาศาสตรมหาบัณฑิต (วิทยาการข้อมูลและการวิเคราะห์)
พ.ศ.	2567
อาจารย์ที่ปรึกษาการค้นคว้าอิสระ	ดร.จิรภัทร์ หยกรัตน์ศักดิ์

### บทคัดย่อ

การศึกษาค้นคว้าอิสระนี้ได้ทำการศึกษาและพัฒนาแบบจำลองโครงข่ายประสาทแบบคอนโวลูชัน เพื่อนำไปวัดความคล้ายคลึงกันสำหรับให้คำแนะนำจากสินค้าที่คล้ายคลึงกัน โดยมีจุดประสงค์เพื่อพัฒนาแบบจำลองโครงข่ายประสาทแบบคอนโวลูชันสำหรับค้นหาคุณลักษณะจากรูปภาพสินค้าแฟชั่น เปรียบเทียบประสิทธิภาพของแบบจำลองในการจำแนกกลุ่มรูปภาพสินค้าแฟชั่น โดยโครงข่ายประสาทแบบคอนโวลูชันที่แตกต่างกัน และพัฒนาระบบแนะนำสินค้าแบบออนไลน์ โดยใช้วิธีการเพื่อนบ้านที่ใกล้เคียงที่สุด K ตัว (K-Nearest Neighbor : K-NN) เพื่อแนะนำสินค้าที่มีความคล้ายคลึงกัน ในการศึกษาแบบจำลองโครงข่ายประสาทแบบคอนโวลูชัน ได้ทำการเปรียบเทียบประสิทธิภาพของแบบจำลองจำนวน 3 โครงสร้าง ประกอบด้วย ResNet50, VGG16 และ Inception v3 ผลจากการศึกษาพบว่า แบบจำลอง VGG16 มีประสิทธิภาพดีที่สุด มีความแม่นยำถึงร้อยละ 90 ของชุดข้อมูลทดสอบทั้งหมด รองลงมาคือ Inception v3 และ ResNet50 ที่ได้ความแม่นยำถึงร้อยละ 87 และถึงร้อยละ 86 ของชุดข้อมูลทดสอบทั้งหมด ตามลำดับ

**คำสำคัญ :** การเรียนรู้เชิงลึก ค้นหาเพื่อนบ้านใกล้เคียง k ตัว โครงข่ายประสาทแบบคอนโวลูชัน ระบบแนะนำสินค้าแบบออนไลน์

<b>Independent study Title</b>	Image-Based Product Recommendations for E-Commerce using Deep Learning Approach
<b>Student</b>	Miss Piyawan Nomawong
<b>Student ID</b>	65056064
<b>Degree</b>	Master of Science (Data Science and Analytics) KMITL Digital Analytics and Intelligence Center
<b>Year</b>	2024
<b>Independent Study Advisor</b>	Dr. Jiraphat Yokrattanasak

### Abstract

This independent research study investigated and developed convolutional neural network models to measure similarity for recommending similar products. The objective was to enhance convolutional neural network models for extracting features from fashion product images, comparing the performance of models in classifying fashion product images, utilizing different convolutional neural network architectures, and developing an online product recommendation system using the K-Nearest Neighbor (K-NN) method to suggest similar products. In the study of convolutional neural network models, the performance of three model architectures, including ResNet50, VGG16, and Inception v3, was compared. The study's results found that the VGG16 model performed the best, achieving an accuracy of 90% on the entire test dataset. Following VGG16 were Inception v3 and ResNet50, which gained 87% and 86% accuracy on the whole test dataset, respectively.

**Keywords:** Deep Learning, K-Nearest Neighbor, Convolutional Neural Network, Recommendation System

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## กิตติกรรมประกาศ

การศึกษาค้นคว้าอิสระครั้งนี้สำเร็จลุล่วงไปได้ด้วยดีด้วยความกรุณาจากหลายท่าน ผู้ศึกษาขอกราบขอบพระคุณอาจารย์ ดร.จิรภัทร์ หยกรัตนศักดิ์ อาจารย์ที่ปรึกษาเป็นอย่างสูงที่ได้ให้ทั้งความรู้ คำชี้แนะ คำปรึกษาตลอดจนตรวจสอบชี้แนะแนวทาง และแก้ไขปรับปรุงข้อบกพร่องต่าง ๆ ด้วยความเอาใจใส่ตลอดระยะเวลาที่ทำการศึกษานการศึกษาค้นคว้าครั้งนี้เสร็จสมบูรณ์

ขอกราบขอบพระคุณคณาจารย์คณะวิทยาศาสตร์ สาขาวิชาวิทยาการข้อมูลและการวิเคราะห์ศูนย์วิเคราะห์ข้อมูลดิจิทัลอัจฉริยะ พระจอมเกล้าลาดกระบัง ที่ได้ถ่ายทอดวิชาความรู้ อันเป็นประโยชน์ยิ่งให้แก่ผู้ศึกษา รวมถึงเจ้าหน้าที่สาขาวิชาทุกท่านที่ให้ความช่วยเหลือในการติดต่อประสานงานในเรื่องต่าง ๆ

สุดท้ายนี้ ขอกราบขอบพระคุณสถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง สถานที่ที่ถ่ายทอดความรู้แก่นักศึกษา

ปิยะวรรณ โนมะวงศ์

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

# สารบัญ

	หน้า
บทคัดย่อ.....	ก
Abstract.....	ข
กิตติกรรมประกาศ.....	ค
สารบัญ.....	ง
สารบัญตาราง.....	ฉ
สารบัญภาพ.....	ช
<b>บทที่ 1 บทนำ.....</b>	<b>1</b>
1.1 ที่มาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์.....	2
1.3 ขอบเขตของการศึกษา.....	3
1.4 ประโยชน์ที่คาดว่าจะได้รับ.....	3
<b>บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง.....</b>	<b>4</b>
2.1 โครงข่ายประสาทแบบคอนโวลูชัน.....	4
2.2 การเรียนรู้แบบถ่ายโอน (Transfer Learning).....	10
2.3 ระบบให้การแนะนำ (Recommender System).....	15
2.4 การทดสอบความเป็นอิสระด้วยไคกำลังสอง.....	17
2.5 งานวิจัยที่เกี่ยวข้อง.....	18
<b>บทที่ 3 วิธีดำเนินการศึกษา.....</b>	<b>21</b>
3.1 เครื่องมือที่ใช้ในการศึกษา.....	21
3.2 ข้อมูลที่ใช้ในการศึกษา.....	21
3.3 ขั้นตอนในกระบวนการสร้างแบบจำลอง.....	24
3.4 ขั้นตอนในกระบวนการให้การแนะนำ.....	26

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## สารบัญ (ต่อ)

หน้า

บทที่ 4 ผลการศึกษา.....	30
4.1 ผลการทดลองจากกระบวนการสร้างแบบจำลอง .....	30
4.2 ผลการทดลองจากกระบวนการให้การแนะนำ.....	43
บทที่ 5 สรุป และอภิปรายผลการศึกษา .....	48
5.1 สรุป และอภิปรายผลการศึกษา .....	48
5.2 ข้อจำกัดและการทำงานในอนาคต .....	49
เอกสารอ้างอิง .....	50



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## สารบัญตาราง

ตารางที่	หน้า
4.1 การกำหนดค่าต่าง ๆ และผลจากการตั้งค่าให้กับแบบจำลอง .....	31
4.2 ผลลัพธ์ประสิทธิภาพของการฝึกสอนแบบจำลอง VGG16 ใน 22 รอบ .....	31
4.3 ผลลัพธ์ของการทำนายหรือความแม่นยำในการจำแนกของแบบจำลองโดย VGG16 .....	34
4.4 ผลลัพธ์ประสิทธิภาพของการฝึกสอนแบบจำลอง ResNet50 ใน 50 รอบ .....	35
4.5 ผลลัพธ์ของการทำนายหรือความแม่นยำในการจำแนกของแบบจำลองโดย ResNet50 .....	38
4.6 ผลลัพธ์ประสิทธิภาพของการฝึกสอนแบบจำลอง Inception v3 ใน 12 รอบ .....	39
4.7 ผลลัพธ์ของการทำนายหรือความแม่นยำในการจำแนกของแบบจำลองโดย Inception v3 .....	41
4.8 เปรียบเทียบประสิทธิภาพของแบบจำลองทั้ง 3 โครงสร้าง .....	42



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## สารบัญภาพ

ภาพที่	หน้า
2.1 โครงสร้างโครงข่ายแบบคอนโวลูชัน .....	5
2.2 วิธีการคอนโวลูชัน ระหว่างพื้นที่ส่วนย่อย และเคอร์เนล .....	5
2.3 ขั้นตอนการคำนวณด้วยฟังก์ชันค่าเฉลี่ย โดยตัวกรองขนาด 2x2 จำนวน Stride คือ 2 .....	6
2.4 ขั้นตอนการคำนวณด้วยฟังก์ชันค่าต่ำสุด โดยตัวกรองขนาด 2x2 จำนวน Stride คือ 2 .....	7
2.5 ขั้นตอนการคำนวณด้วยฟังก์ชันค่าสูงสุด โดยตัวกรองขนาด 2x2 จำนวน Stride คือ 2.....	7
2.6 การเชื่อมต่อกันของแต่ละชั้นอย่างสมบูรณ์ Fully connected layer .....	8
2.7 กราฟ ReLU function.....	8
2.8 ตัวอย่างการคำนวณของ Softmax function.....	9
2.9 ความแตกต่างของ (a) โครงข่ายประสาทปกติ กับ (b) โครงข่ายประสาทหลังจากใช้เทคนิค dropout.....	9
2.10 โครงสร้างแบบ ResNet-50.....	10
2.11 โครงสร้างแบบ VGG16.....	11
2.12 ขั้นตอนการทำงานของเทคนิค Smaller convolutions.....	11
2.13 โครงสร้าง Inception Module A โดยใช้วิธีการแยกตัวประกอบ .....	12
2.14 ขั้นตอนของ Asymmetric convolutions.....	12
2.15 โครงสร้าง Inception Module B และ C โดยใช้วิธี Asymmetric convolutions .....	13
2.16 Auxiliary classifier ทำหน้าที่เป็น Regularization .....	13
2.17 การลดขนาดแบบเดิม (ซ้ายบน) การลดขนาดกริดอย่างมีประสิทธิภาพ (ซ้ายล่าง) โครงสร้าง . 14	14
2.18 โครงสร้างแบบ Inception v3.....	14
3.1 ตัวอย่างของชุดข้อมูลอธิบายลักษณะของผลิตภัณฑ์แฟชั่นที่ใช้ในการศึกษา .....	22
3.2 ตัวอย่างรูปภาพผลิตภัณฑ์แฟชั่นที่ใช้ในการศึกษา .....	22
3.3 ตัวอย่างรูปภาพจากชุดข้อมูล Fashion-MNIST ที่ใช้ในการศึกษา.....	23
3.4 ลำดับขั้นตอนโดยภาพรวมในกระบวนการสร้างแบบจำลอง .....	24
3.5 โครงสร้างการดัดแปลง และเพิ่มส่วนท้ายของแบบจำลอง .....	26
3.6 ลำดับขั้นตอนโดยภาพรวมในกระบวนการให้การแนะนำ .....	27
3.7 ผลลัพธ์ของการรวมข้อมูลที่มีโครงสร้างของชุดข้อมูล Fashion Product กับคุณลักษณะจากแบบจำลอง.....	28

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## สารบัญภาพ (ต่อ)

ภาพที่	หน้า
4.1 กราฟแสดงผลลัพธ์ประสิทธิภาพของการฝึกสอนแบบจำลอง VGG16 ใน 22 รอบ.....	32
4.2 กราฟแสดง Confusion Matrices การจำแนกรูปภาพสินค้าแฟชั่นด้วย VGG16 โดยแกน y คือค่าจริง (Actual value) และแกน x คือค่าที่ทำนาย (Predicted Value).....	33
4.3 กราฟแสดงผลลัพธ์ประสิทธิภาพของการฝึกสอนแบบจำลอง ResNet50 ใน 50 รอบ.....	37
4.4 กราฟแสดง Confusion Matrices การจำแนกรูปภาพสินค้าแฟชั่นด้วย ResNet50 โดยแกน y คือค่าจริง (Actual value) และแกน x คือค่าที่ทำนาย (Predicted Value).....	38
4.5 กราฟแสดงผลลัพธ์ประสิทธิภาพของการฝึกสอนแบบจำลอง Inception v3 ใน 12 รอบ .....	40
4.6 กราฟแสดง Confusion Matrices การจำแนกรูปภาพสินค้าแฟชั่นด้วย Inception v3 โดยแกน y คือค่าจริง (Actual value) และแกน x คือค่าที่ทำนาย (Predicted Value).....	41
4.7 แสดงผลการให้การแนะนำ.....	45



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

# บทที่ 1

## บทนำ

ในบทนี้ มีเป้าหมายในการแนะนำแนวคิดหลักของการศึกษาค้นคว้าอิสระที่จะศึกษา และพัฒนาแบบจำลองโครงข่ายประสาทแบบคอนโวลูชันสำหรับค้นหาคุณลักษณะที่แยกออกมาจากรูปภาพสินค้าแฟชั่นโดยจะกล่าวถึงที่มา และความสำคัญของปัญหา วัตถุประสงค์ ขอบเขตของการศึกษา และประโยชน์ที่คาดว่าจะได้รับ โดยมีรายละเอียด ดังนี้

### 1.1 ที่มาและความสำคัญของปัญหา

ในยุคที่เทคโนโลยี และอินเทอร์เน็ตเข้าสู่ชีวิตประจำวันอย่างมาก การซื้อขายสินค้าออนไลน์ หรือ อีคอมเมิร์ซ (E-Commerce) กลายเป็นส่วนสำคัญของกิจกรรมธุรกิจ และสังคมมากขึ้นเรื่อย ๆ ในการเปลี่ยนแปลงวิธีที่ผู้คนซื้อสินค้า และบริการ ผู้บริโภคมักมองหาสินค้า และบริการผ่านพื้นที่อินเทอร์เน็ตมากขึ้นเรื่อย ๆ ดังนั้นเมื่อพูดถึงอีคอมเมิร์ซ การแนะนำสินค้าจึงเป็นปัจจัยที่สำคัญในการเพิ่มยอดขาย ความพึงพอใจของลูกค้า และช่วยให้ธุรกิจออนไลน์ประสบความสำเร็จได้

ด้วยความนิยมในการเลือกซื้อสินค้าออนไลน์ ผู้ให้บริการธุรกิจอีคอมเมิร์ซต้องหาวิธีที่จะทำให้ลูกค้าเลือกซื้อสินค้าได้อย่างรวดเร็ว และแม่นยำมากที่สุด ภาพถ่ายสินค้าจึงมีบทบาทสำคัญในการแสดงสินค้าในแพลตฟอร์มอีคอมเมิร์ซและทำให้ผู้บริโภคเข้าใจสินค้า เห็นภาพลักษณะของสินค้ามากขึ้น

แนวทางการเรียนรู้เชิงลึก (Deep Learning) เป็นที่นิยมในการแก้ปัญหาที่เกี่ยวข้องกับการจัดการกับรูปภาพ และข้อมูลที่ซับซ้อน การใช้แนวทางการเรียนรู้เชิงลึกเพื่อปรับปรุงแนวทางการแนะนำสินค้าจึงกลายเป็นแนวทางที่มีความศักยภาพสูงในการปรับปรุงประสิทธิภาพของระบบอีคอมเมิร์ซในการแนะนำสินค้าผ่านรูปภาพ

การแนะนำสินค้ามีมาตั้งแต่ยุคแรกของการขายสินค้า ในรูปแบบเดิมการแนะนำสินค้ามักจะเป็นผ่านพนักงานขาย หรือจากการแนะนำของเพื่อน และครอบครัว แต่ด้วยการเปลี่ยนแปลงในสภาพแวดล้อมการซื้อขาย และการใช้เทคโนโลยีที่มีอยู่ในปัจจุบัน การแนะนำสินค้าก็ได้รับการปรับปรุง และพัฒนาขึ้น ระบบการแนะนำสินค้า (Recommendation System) ในอีคอมเมิร์ซมีความสำคัญในการสร้างประสบการณ์ที่ดีให้กับลูกค้าและเพิ่มยอดขายของธุรกิจ อีกทั้งการใช้ระบบการแนะนำสินค้าที่มีประสิทธิภาพสามารถช่วยธุรกิจให้เจริญเติบโต และเพิ่มความสามารถใน

การแข่งขันในตลาดอีคอมเมิร์ซที่มีการแข่งขันสูง ในการซื้อสินค้าออนไลน์นั้นต้องใช้เวลามากในเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

การมองหาสินค้าต่าง ๆ ระบบแนะนำสามารถลดระยะเวลาในการหาสินค้าที่หลากหลายแล้วลูกค้าสนใจ

จากงานวิจัยของ Anupama A. และคณะ (2021) ได้ศึกษาเพื่อประยุกต์ใช้โครงข่ายประสาทแบบคอนโวลูชัน หรือ CNN และแบบจำลอง Transfer Learning สำหรับการแนะนำผลิตภัณฑ์ที่คล้ายคลึงกัน พบว่า ระบบการแนะนำสินค้าด้วยรูปภาพที่เสนอโดยใช้โครงข่ายประสาทแบบคอนโวลูชันมีประสิทธิภาพเหนือกว่าระบบการแนะนำอื่น ๆ โดยแบบจำลองที่มีประสิทธิภาพมากที่สุด คือแบบจำลองที่มีโครงสร้าง Visual Geometry Group-16 (VGG16) นอกจากนี้ Pegah M. A. และคณะ (2022) เสนอเทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลอง Convolutional Neural Network หารูปแบบคือ VGG16, VGG19, ResNet50, Inception v3 และ Xception เพื่อดึงข้อมูลลักษณะจากรูปภาพของสินค้า และใช้อัลกอริทึม KNN สำหรับการแนะนำและในการวัดความคล้ายคลึงของภาพ พบว่า วิธีการแนะนำผลิตภัณฑ์โดยใช้รูปภาพโดยใช้ โครงข่ายประสาทแบบคอนโวลูชัน มีประสิทธิภาพเหนือกว่าระบบการแนะนำแบบดั้งเดิม การตั้งค่าที่แตกต่างกันสำหรับแบบจำลอง CNN แต่ละแบบจำลองที่เลือกส่งผลกระทบต่อเมตริกซ์ความคล้ายคลึงของคุณลักษณะที่แยกออกมาจากรูปภาพ Shereen E. และคณะ (2022) เสนอว่าแบบจำลอง ResNet50 ประสิทธิภาพดีกว่าทุกวิธีการแนะนำที่ใช้ภาพในการตีความรายการสินค้าแฟชั่น และยังกล่าวอีกว่าการเพิ่มคุณสมบัติภาพ ลดการขาดหายของข้อมูล ทำให้ประสิทธิภาพของแบบจำลองดีขึ้นอย่างชัดเจน และ Akshit และคณะ (2021) ศึกษาการใช้การเรียนรู้เชิงลึกในการพัฒนาระบบแนะนำสินค้า โดยใช้การเรียนรู้แบบถ่ายโอนโดยโครงสร้าง VGG16 และใช้ Cosine similarity เพื่อคำนวณหารายการที่คล้ายกันมากที่สุด จากการรวบรวมชุดข้อมูลรูปภาพ Style Color Images ประกอบด้วยเครื่องแต่งกายแฟชั่น เช่น รองเท้า รองเท้าส้นสูง แหวน เสื้อผ้า สำหรับชายและหญิง ชุดข้อมูลมาพร้อมกับไฟล์ข้อความที่ประกอบด้วยตัวแปรต่างๆ เช่น ชื่อแบรนด์ ชื่อผลิตภัณฑ์ ประเภทผลิตภัณฑ์ พบว่า หลังจากสุ่มตัวอย่างภาพมาทดสอบแล้วได้ระบบแนะนำเสื้อผ้า ที่มีประสิทธิภาพดี

ดังนั้นในการศึกษาค้นคว้าอิสระนี้จึงมีแนวคิดที่จะศึกษา และพัฒนาแบบจำลองโครงข่ายประสาทแบบคอนโวลูชัน 3 โครงสร้าง ได้แก่ VGG16, ResNet50 และ Inception v3 สำหรับค้นหาคุณลักษณะที่แยกออกมาจากรูปภาพสินค้าแฟชั่น เพื่อนำไปวัดความคล้ายคลึงกันสำหรับให้คำแนะนำจากสินค้าที่คล้ายคลึงกัน โดยใช้วิธีการเพื่อนบ้านที่ใกล้ที่สุด K ตัว

## 1.2 วัตถุประสงค์

วัตถุประสงค์ของการศึกษาค้นคว้าอิสระครั้งนี้ มีวัตถุประสงค์ ดังนี้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

1.2.1. เพื่อพัฒนาแบบจำลองโครงข่ายประสาทแบบคอนโวลูชันสำหรับค้นหาคุณลักษณะจากรูปภาพสินค้าแฟชั่น

1.2.2. เพื่อเปรียบเทียบประสิทธิภาพของแบบจำลองในการจำแนกกลุ่มรูปภาพสินค้าแฟชั่น โดยแบบจำลองโครงข่ายประสาทแบบคอนโวลูชันที่แตกต่างกัน 3 โครงสร้าง

1.2.3. เพื่อพัฒนาระบบแนะนำสินค้าแบบออนไลน์ โดยใช้วิธีการเพื่อนบ้านที่ใกล้ที่สุด K ตัว (K-Nearest Neighbor: K-NN) เพื่อแนะนำสินค้าที่มีความคล้ายคลึงกัน

### 1.3 ขอบเขตของการศึกษา

การศึกษาค้นคว้าอิสระครั้งนี้ มีขอบเขตของการศึกษา ดังนี้

1.3.1. ขอบเขตด้านเนื้อหาในการศึกษาครั้งนี้ จะศึกษาและพัฒนาแบบจำลองโครงข่ายประสาทแบบคอนโวลูชัน สำหรับค้นหาคุณลักษณะที่แยกออกมาจากรูปภาพสินค้าแฟชั่น เพื่อนำไปวัดความคล้ายคลึงกันสำหรับให้คำแนะนำจากสินค้าที่คล้ายคลึงกัน

1.3.2. ขอบเขตด้านข้อมูลในการศึกษา สำหรับชุดข้อมูลที่ใช้ในการสร้างแบบจำลอง คือชุดข้อมูลสินค้าแฟชั่น ที่ฉลากติดกำกับไว้แล้ว จากเว็บไซต์ Kaggle และชุดข้อมูลสำหรับระบบให้คำแนะนำ คือชุดข้อมูลสินค้าแฟชั่น ที่มีทั้งรูปภาพของสินค้า และรายละเอียดของสินค้า จากเว็บไซต์ Kaggle

1.3.3. ขอบเขตด้านวิธีการสร้างแบบจำลอง คือ สร้างแบบจำลองโครงข่ายประสาทแบบคอนโวลูชัน โดยใช้ไลบรารีในภาษาไพทอน (Python) คือ Tensorflow และ Keras และใช้ตัวประมวลผล GPU (Graphics Processing Unit)

### 1.4 ประโยชน์ที่คาดว่าจะได้รับ

การศึกษาค้นคว้าอิสระครั้งนี้ มีประโยชน์ที่คาดว่าจะได้รับ ดังนี้

1.4.1. ได้แบบจำลองโครงข่ายประสาทแบบคอนโวลูชันสำหรับค้นหาคุณลักษณะจากรูปภาพสินค้าแฟชั่น

1.4.2. ได้แบบจำลองในการจำแนกกลุ่มรูปภาพสินค้าแฟชั่น โดยโครงข่ายประสาทแบบคอนโวลูชันที่มีประสิทธิภาพ

1.4.3. ได้ระบบแนะนำสินค้าแบบออนไลน์ เพื่อเพิ่มประสิทธิภาพการขายสินค้าทางสื่อออนไลน์ให้ตรงกับ ความต้องการของลูกค้าให้ได้รับความพึงพอใจสูงสุด

## บทที่ 2

# ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

การศึกษาค้นคว้าอิสระนี้ มีวัตถุประสงค์เพื่อพัฒนาแบบจำลองโครงข่ายประสาทแบบคอนโวลูชันสำหรับค้นหาคุณลักษณะจากรูปภาพสินค้าแฟชั่น จึงรวบรวมทฤษฎี หลักเกณฑ์ และงานวิจัยต่าง ๆ ที่มีส่วนเกี่ยวข้องกับงานวิจัย โดยแบ่งออกเป็นหัวข้อต่าง ๆ ดังนี้


- 2.1 โครงข่ายประสาทแบบคอนโวลูชัน (Convolutional Neural Networks)
- 2.2 การเรียนรู้แบบถ่ายโอน (Transfer Learning)
- 2.3 ระบบให้การแนะนำ (Recommender System)
- 2.4 การทดสอบความเป็นอิสระด้วยไคกำลังสอง
- 2.5 งานวิจัยที่เกี่ยวข้อง

ซึ่งแต่ละหัวข้อมีรายละเอียด ดังต่อไปนี้

### 2.1 โครงข่ายประสาทแบบคอนโวลูชัน

โครงข่ายประสาทแบบคอนโวลูชัน (Convolutional Neural Networks : CNN) คือโครงข่ายประสาทเทียมรูปแบบหนึ่งที่ใช้ในการวิเคราะห์รูปภาพ เช่น การจำแนกรูปภาพ (Image Classification) การรู้จำใบหน้า (Face Recognition) เป็นต้น ซึ่งรูปภาพจะถูกแบ่งออกเป็นพื้นที่ย่อย ๆ เป็นจุดภาพ (Pixel) ในรูปแบบของ เมทริกซ์ (Matrix) และทำการดึงลักษณะเด่น (Feature Extraction) ของพื้นที่ย่อยนั้น ๆ เพื่อจำแนกประเภท หรือจัดกลุ่มของรูปภาพ

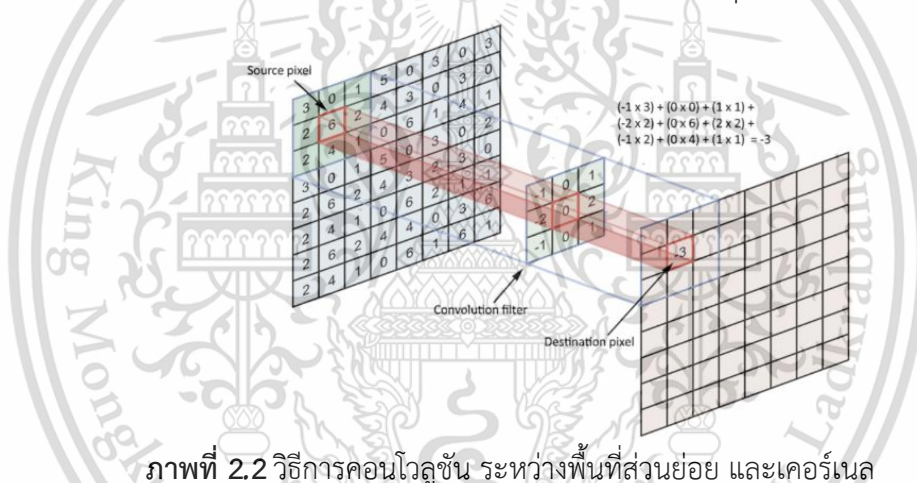
โดยรูปแบบของโครงข่ายประสาทเทียมที่ประกอบด้วย ชั้นนำเข้า (Input Layer) ชั้นแอบแฝง (Hidden Layer) และชั้นส่งออกข้อมูล (Output Layer) ภายหลังมีการวิจัย ด้วยการคำนวณแบบคอนโวลูชัน (Convolutional) เข้าไปในโครงข่าย โดย LeCun et al. (1989) เรียกว่า โครงข่ายประสาทเทียมแบบคอนโวลูชัน โดยภาพที่ 2.1 แสดงโครงสร้างโครงข่ายแบบคอนโวลูชันที่ประกอบด้วยชั้นต่าง ๆ สำหรับกระบวนการทำการจำแนก หรือหาคุณลักษณะของข้อมูล



ภาพที่ 2.1 โครงสร้างโครงข่ายแบบคอนโวลูชัน

### 2.1.1 ชั้นคอนโวลูชัน (Convolutional Layer)

คอนโวลูชัน เป็นการหาคูณลักษณะเด่นของภาพ เพื่อแยกองค์ประกอบของรูปภาพ เช่น ขอบเส้นเพื่อให้ได้ฟังก์ชันลักษณะ (Feature Maps) โดยรูปภาพนำเข้า (Input image) กำหนดให้มีขนาด  $W \times W \times M$  เมื่อ  $W$  คือ ความสูง และความกว้างของภาพ และ  $M$  คือ มิติของภาพ จากนั้นนำพื้นที่ส่วนย่อย (Local Region) มาทำการคูณเมทริกซ์ (Dot matrix) กับเคอร์เนล (Kernel) แล้วเก็บไว้ในฟีเจอร์แมพ (Feature Map) ดังภาพที่ 2.2



ภาพที่ 2.2 วิธีการคอนโวลูชัน ระหว่างพื้นที่ส่วนย่อย และเคอร์เนล

Stride เป็นตัวกำหนดจำนวนจุดภาพที่เคอร์เนลจะถูกเลื่อนไปบนภาพ เมื่อทำการหาผลลัพธ์ของคอนโวลูชันในแต่ละช่อง โดยมีสมการคำนวณขนาดของผลลัพธ์ ดังนี้

$$\left( \frac{n+2p-f}{s} + 1, \frac{n+2p-f}{s} + 1 \right) \tag{2.1}$$

- โดยกำหนดให้
- $n$  คือ มิติของข้อมูลนำเข้า
  - $f$  คือ มิติของตัวกรอง
  - $p$  คือ ขนาดจุดภาพของ Padding
  - $s$  คือ จำนวนก้าวข้าม

Padding คือการปรับขนาดรูปภาพนำเข้าเป็นพื้นที่สี่เหลี่ยมรอบ ๆ โดยเติม 0 หรือค่าอื่น ๆ เข้าไป เพื่อให้ฟีเจอร์แมพที่ได้ยังคงมีขนาดเท่ากับรูปภาพนำเข้า ซึ่งสามารถคำนวณขนาดของ padding ได้ดังสมการ (2.2)

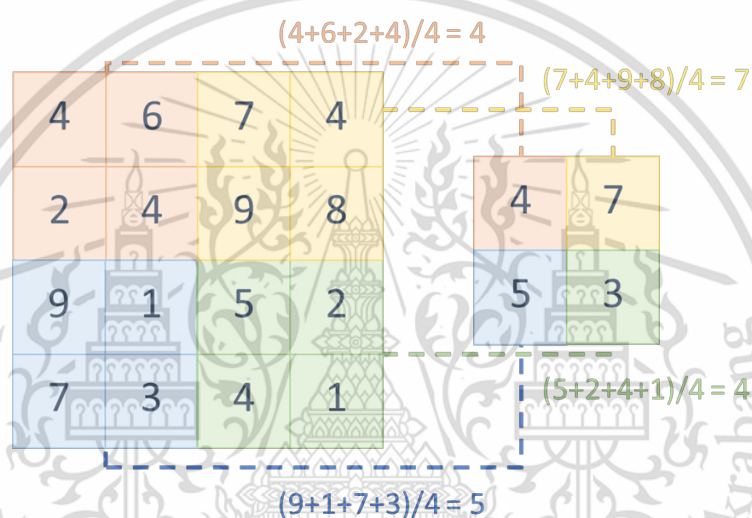
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$p = \frac{f-1}{2} \quad (2.2)$$

### 2.1.2 ชั้นพูลลิ่ง (Pooling Layer)


ชั้นพูลลิ่ง เป็นการลดขนาดข้อมูลจากฟังก์ชันลักษณะที่มาจากชั้นคอนโวลูชัน ทำให้จำนวนของพารามิเตอร์และระยะเวลาในการฝึกสอนแบบจำลองลดลง ชั้นพูลลิ่ง มีฟังก์ชันดังนี้

ฟังก์ชันค่าเฉลี่ย (Average pooling) การหาค่าเฉลี่ยของค่าที่ได้จากการดอทเมทริกซ์กับตัวกรองเพื่อสร้างพีเจอร์แมพใหม่ ภาพที่ 2.3 แสดงตัวอย่างขั้นตอนด้วยฟังก์ชันค่าเฉลี่ย โดยตัวกรองขนาด  $2 \times 2$  จำนวน Stride คือ 2 ซึ่งจะได้พีเจอร์แมพใหม่ (ขวา)



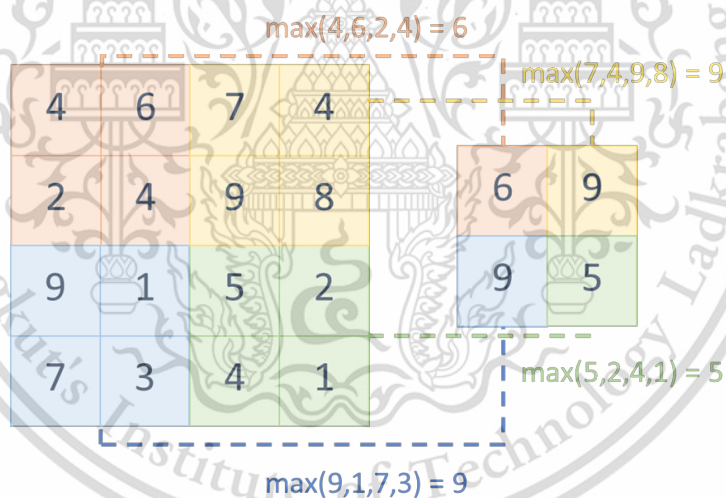
ภาพที่ 2.3 ขั้นตอนการคำนวณด้วยฟังก์ชันค่าเฉลี่ย โดยตัวกรองขนาด  $2 \times 2$  จำนวน Stride คือ 2

ฟังก์ชันค่าต่ำสุด (Min pooling) การหาค่าต่ำสุดของค่าที่ได้จากการดอทเมทริกซ์กับตัวกรองเพื่อสร้างพีเจอร์แมพใหม่ ภาพที่ 2.4 แสดงตัวอย่างขั้นตอนด้วยฟังก์ชันค่าต่ำสุดค่าเฉลี่ย โดยตัวกรองขนาด  $2 \times 2$  จำนวน Stride คือ 2 ซึ่งจะได้พีเจอร์แมพใหม่ (ขวา)



ภาพที่ 2.4 ขั้นตอนการคำนวณด้วยฟังก์ชันค่าต่ำสุด โดยตัวกรองขนาด 2x2 จำนวน Stride คือ 2

ฟังก์ชันค่าสูงสุด (Max pooling) การหาค่าสูงสุดของค่าที่ได้จากการดอทเมทริกซ์กับตัวกรองเพื่อสร้างพีเจอร์แมพใหม่ ภาพที่ 2.5 แสดงตัวอย่างขั้นตอนด้วยฟังก์ชันค่าสูงสุดค่าเฉลี่ย โดยตัวกรองขนาด 2x2 จำนวน Stride คือ 2 ซึ่งจะได้พีเจอร์แมพใหม่ (ขวา)




ภาพที่ 2.5 ขั้นตอนการคำนวณด้วยฟังก์ชันค่าสูงสุด โดยตัวกรองขนาด 2x2 จำนวน Stride คือ 2

### 2.1.3 ชั้นเชื่อมโยงแบบสมบูรณ์ (Fully-Connected Layer)

ชั้นเชื่อมโยงแบบสมบูรณ์ เป็นขั้นสุดท้ายของการทำ CNN ที่นำพีเจอร์แมพก่อนหน้าไปเชื่อมโยงกับผลลัพธ์แบบสมบูรณ์ ซึ่งทุก ๆ โหนดที่อยู่ในชั้นเชื่อมโยงแบบสมบูรณ์จะถูกเชื่อมต่อกับทุกโหนดในชั้นก่อนหน้า ชั้นเชื่อมโยงแบบสมบูรณ์ มีหน้าที่นำคุณลักษณะสำคัญไปสร้างเป็นโครงข่ายประสาทสำหรับการเรียนรู้ จัดจำรูปแบบ และการทำนายประเภท โดย

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ใช้ฟังก์ชันกระตุ้น (Activation function) โดยภาพที่ 2.6 แสดงการเชื่อมต่อกันของแต่ละชั้นอย่างสมบูรณ์




ภาพที่ 2.6 การเชื่อมต่อกันของแต่ละชั้นอย่างสมบูรณ์ Fully connected layer

### 2.1.4 ฟังก์ชันกระตุ้น (Activation function)

ฟังก์ชันกระตุ้น คือฟังก์ชันที่รับผลรวมการประมวลผลทั้งหมดจากทุกข้อมูลนำเข้า แล้วพิจารณาว่าจะส่งค่าผลลัพธ์ที่ออกมาจากเซลล์ประสาทในรูปแบบใด

ฟังก์ชันกระตุ้นแบบ Rectified-Linear Unit (ReLU) คือการนำพีเจอร์แมพมาปรับแต่งให้ไม่เป็นลักษณะเชิงเส้น โดยแทนที่จุดภาพที่มีค่าเป็นเชิงลบในพีเจอร์แมพด้วย 0 ส่วนค่าเชิงบวกจะมีค่าเท่าเดิมตามค่าที่ส่งเข้ามา ภาพที่ 2.7 แสดงกราฟ ReLU function ค่าของ ReLU function จะมีค่าตั้งแต่ 0 ขึ้นไป



ภาพที่ 2.7 กราฟ ReLU function


ฟังก์ชันกระตุ้นแบบ Softmax คือฟังก์ชันที่รับข้อมูลเป็นเวกเตอร์ (Vector) แล้วแปลงให้เป็นมาตรฐาน (Normalize) ออกมาเป็นความน่าจะเป็นที่ผลรวมเท่ากับ 1 โดยทั่วไปจะอยู่ในชั้นสุดท้ายของโครงข่ายประสาทเทียม นิยมใช้ในงานจำแนกประเภท โดยมีสมการ ดังนี้

$$\sigma(\vec{z})_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \text{ เมื่อ } i = 1, \dots, K \text{ และ } \vec{z} = (z_1, \dots, z_K) \in R^K \quad (2.3)$$

โดยกำหนดให้  $z_i$  คือ ค่าของเวกเตอร์นำเข้า

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$K$  คือ จำนวนคลาส




ภาพที่ 2.8 ตัวอย่างการคำนวณของ Softmax function

ภาพที่ 2.8 แสดงตัวอย่างการคำนวณของ Softmax function ที่แสดงผลลัพธ์ความน่าจะเป็น จากชั้นผลลัพธ์ โดยคำนวณจากสมการที่ (2.3)

### 2.1.5 วิธีการเรกูลาร์ไรเซชัน (Regularization)

เรกูลาร์ไรเซชัน เป็นเทคนิคในการลดความแปรปรวน ความซับซ้อนของแบบจำลอง ช่วยลดปัญหาของแบบจำลองที่สามารถได้รับความแม่นยำสูงในชุดข้อมูลสำหรับฝึกสอน แต่ได้ผลลัพธ์ไม่ดีในชุดข้อมูลสำหรับทดสอบหรือข้อมูลที่แบบจำลองไม่เคยเห็น (Overfitting) การแก้ปัญหาเหล่านี้สามารถทำได้หลายวิธี ในการศึกษาครั้งนี้จะกล่าวถึงเทคนิคการ Dropout

เทคนิคการ Dropout เป็นเทคนิคที่ใช้ในการปรับปรุงการอิงกับข้อมูลฝึกสอนมากเกินไปบนโครงข่ายประสาท โดยการสุ่มปิดนิวรอน (neurons) บางส่วนจากชั้นที่เชื่อมต่อกันอย่างสมบูรณ์ไม่ได้รับข้อมูลใด ๆ ระหว่างการฝึกสอน ซึ่งจะช่วยลดความซับซ้อนของแบบจำลอง ภาพที่ 2.9 แสดงความแตกต่างของโครงข่ายประสาทปกติ และโครงข่ายประสาทหลังจากใช้เทคนิค dropout โดยโครงข่ายประสาทปกติทุกนิวรอนจะเชื่อมต่อกัน แต่โครงข่ายประสาทหลังจากใช้เทคนิค dropout จะปิดบาง นิวรอน



ภาพที่ 2.9 ความแตกต่างของ (a) โครงข่ายประสาทปกติ กับ (b) โครงข่ายประสาทหลังจากใช้เทคนิค dropout

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

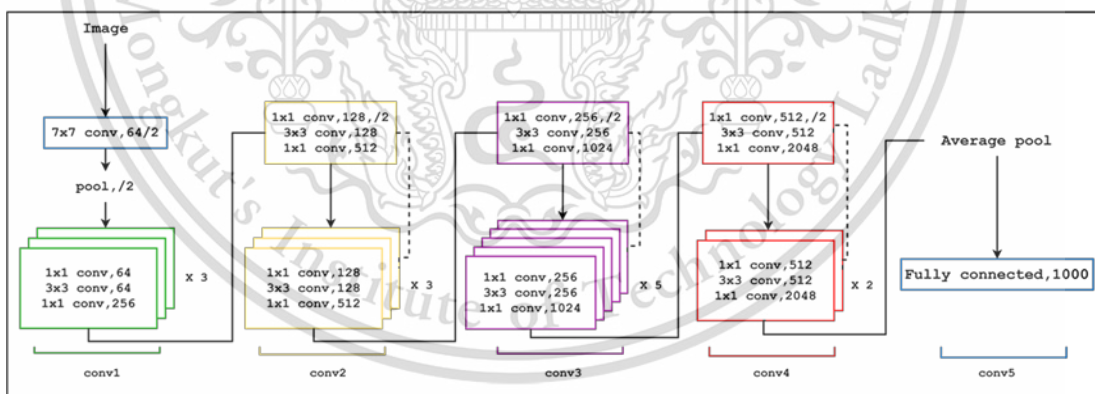
## 2.2 การเรียนรู้แบบถ่ายโอน (Transfer Learning)

การเรียนรู้แบบถ่ายโอน (Transfer Learning) เป็นวิธีการที่ช่วยลดระยะเวลาของการฝึกฝนแบบจำลอง ด้วยการถ่ายทอดความรู้เกี่ยวกับแบบจำลองที่ผ่านการฝึกฝนมาแล้ว และนำการเรียนรู้นั้นไปใช้ในการแก้ปัญหาอื่นที่ใกล้เคียงกัน โดยแทนที่จะเริ่มต้นสร้างแบบจำลองทั้งหมดตั้งแต่ต้น เปลี่ยนมาเริ่มต้นจากรูปแบบที่ได้เรียนรู้จากการแก้ปัญหาที่ลักษณะคล้ายกัน โครงสร้างภายในจะเป็นโครงสร้างของ CNN แบบต่าง ๆ เช่น Xception, VGG16, AlexNet และ ResNet เป็นต้น ส่วนใหญ่จะใช้งานด้านคอมพิวเตอร์วิทัศน์ และการประมวลผลภาษาธรรมชาติ

การสร้างการเรียนรู้แบบถ่ายโอนมี 2 แนวทางคือ การพัฒนาการเรียนรู้ (Develop Model Approach) และการใช้วิธีการฝึกอบรมรุ่นก่อน (Pre-trained Model Approach)

### 2.2.1 โครงสร้างแบบ ResNet-50

Residual Network (ResNet) ได้รับการนำเสนอครั้งแรกในปี ค.ศ. 2015 โดย K. He และคณะ จากการแข่งขันใน ILSVRC 2015 ซึ่งเกิดขึ้นจากการใช้โครงข่ายที่มีความลึกมากแล้วพบว่า ค่าความผิดพลาดในการฝึกสอนแบบจำลอง และการทดสอบแย่ง เนื่องจากปัญหาการหาค่าที่เหมาะสมที่สุด (Optimization) จึงแก้ไขโดยการปรับรูปแบบชั้นด้วยการเพิ่มทางลัด (shortcut) ลงในโครงข่ายเพื่อทำการส่งผลลัพธ์ข้ามชั้น และนำไปเชื่อมต่อกับชั้นถัดไป ดังภาพที่ 2.10 แสดงโครงสร้างแบบ ResNet-50




ภาพที่ 2.10 โครงสร้างแบบ ResNet-50

### 2.2.2 โครงสร้างแบบ VGG16

Visual Geometry Group (VGG) เป็นโครงสร้างแบบของโครงข่ายประสาทแบบคอนโวลูชันเชิงลึก ที่นำเสนอโดย K. Simonyan และ A. Zisserman จาก University of Oxford ในปี ค.ศ. 2015 แบบจำลองนี้มาจากการแข่ง ImageNet ซึ่งเป็นชุดข้อมูลที่มีข้อมูลมากกว่า 14 ล้านรูป และมีภาพถึง 1000 คลาส ซึ่งสามารถติด 1 ใน 5 อันดับสูงสุด ได้รับ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ความแม่นยำในการทดสอบถึงร้อยละ 92.7 เนื่องจากมีความลึกของชั้นแอ่งจำนวน 16 ชั้น จึงเรียกว่า VGG16 ดังภาพที่ 2.11 แสดงโครงสร้างแบบ VGG16




ภาพที่ 2.11 โครงสร้างแบบ VGG16

### 2.2.3 โครงสร้างแบบ Inception v3

Inception v3 เป็นแบบจำลองสำหรับระบบจดจำภาพ ที่ได้รับการพัฒนาโดย Google ซึ่งต่อยอดมาจาก Inception v2 และ Inception v1 หรือ GoogLeNet นำเสนอครั้งแรกในปี ค.ศ. 2015 โดย C. Szegedy และคณะ โดยมุ่งเน้นไปที่การใช้พลังงานในการคำนวณน้อยลงด้วยการปรับเปลี่ยนโครงสร้าง Inception ก่อนหน้านั้น โครงสร้างของ Inception v3 ถูกสร้างขึ้นโดยมีขั้นตอน ดังนี้

- Factorized Convolutions คือการลดจำนวนพารามิเตอร์โดยไม่ทำให้ประสิทธิภาพของเครือข่ายลดลง
- Smaller convolutions คือการเปลี่ยนคอนโวลูชันที่ใหญ่กว่าด้วยคอนโวลูชันที่เล็กกว่า เพื่อลดระยะเวลาในการฝึกสอนแบบจำลอง

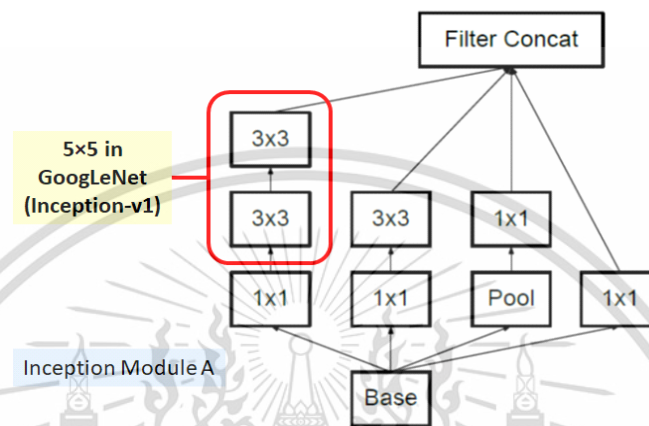


ภาพที่ 2.12 ขั้นตอนการทำงานของเทคนิค Smaller convolutions

จากภาพที่ 2.12 แสดงขั้นตอนการทำงานของเทคนิค Smaller convolutions โดยการแทนที่ตัวกรองขนาด 5x5 จำนวน 1 ชั้น ที่มีจำนวนพารามิเตอร์คือ  $5 \times 5 = 25$  และด้วยตัวกรองขนาด 3x3 จำนวน 2 ชั้น จำนวนพารามิเตอร์คือ  $3 \times 3 + 3 \times 3 = 18$  ดังนั้นจำนวนของ


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

พารามิเตอร์จะลดลงจาก 25 ไปเป็น 18 ซึ่งคิดเป็นร้อยละ 28 เทคนิคนี้จะเป็นโมดูลใหม่ใน Inception ที่เรียกว่า Inception Module A วัตถุประสงค์ของการออกแบบเป็น 1x1 คอนโวลูชัน คือต้องการให้ขนาดของผลลัพธ์หรือ Filter Concat เป็น tensor ดังภาพที่ 2.13 แสดง Inception Module A ที่ถูกพัฒนาเริ่มต้นมาจาก Naïve Module ในกรอบสีแดง แสดงให้เห็นถึง การแทนที่ตัวกรองขนาด 5x5 ด้วยตัวกรองขนาด 3x3 จำนวน 2 ชั้น



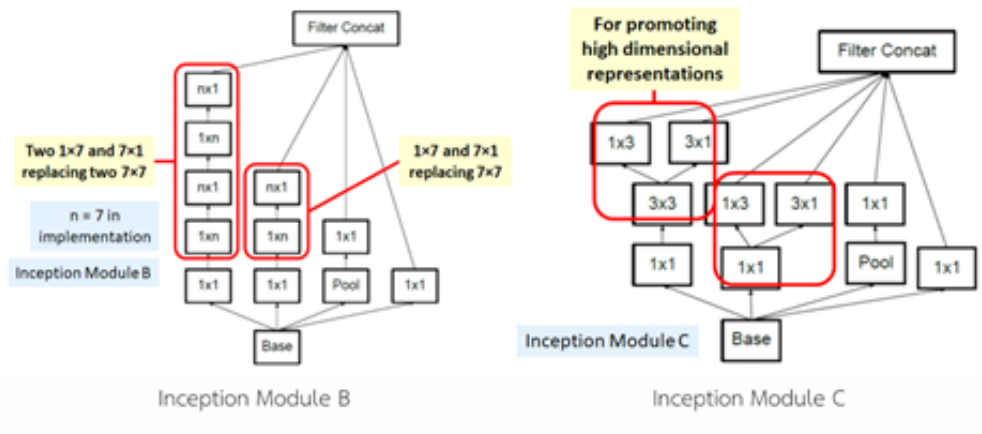
ภาพที่ 2.13 โครงสร้าง Inception Module A โดยใช้วิธีการแยกตัวประกอบ

- Asymmetric convolutions : การนำคอนโวลูชัน 3x3 (nxn) แทนที่ด้วยคอนโวลูชัน 1x3 (1xn) ตามด้วยคอนโวลูชัน 3x1 (nx1)



ภาพที่ 2.14 ชั้นตอนของ Asymmetric convolutions


จากภาพที่ 2.14 แสดงขั้นตอนของ Asymmetric convolutions โดยมีตัวกรองขนาด 3x3 จำนวนพารามิเตอร์คือ 9 และตัวกรองขนาด 3x1 และ 1x3 จำนวนพารามิเตอร์คือ  $3 \times 1 + 1 \times 3 = 6$  ดังนั้นจำนวนของพารามิเตอร์จะลดลงจาก 9 ไปเป็น 6 สามารถลดไปได้ร้อยละ 33 ซึ่งเทคนิคนี้เป็นโมดูลใหม่ใน Inception ที่เรียกว่า Inception Module B และ Inception Module C ถูกนำเสนอใช้ในมิติที่สูงกว่า



ภาพที่ 2.15 โครงสร้าง Inception Module B และ C โดยใช้วิธี Asymmetric convolutions

จากภาพที่ 2.15 แสดงโครงสร้าง Inception Module B โดยใช้วิธี Asymmetric convolutions ในกรอบสีแดงที่มีการแทนที่คอนโวลูชัน  $3 \times 3$  ใน Inception Module A ทั้ง 2 ชั้นด้วย  $1 \times 3$  ตามด้วย  $3 \times 1$  และสำหรับในมิติที่สูงจะใช้ Inception Module C ที่มีการแทนที่คอนโวลูชัน  $3 \times 3$  ด้วย  $1 \times 3$  ตามด้วย  $3 \times 1$  ในลักษณะที่ขนานกัน


- Auxiliary classifier คือ CNN ขนาดเล็กที่แทรกระหว่างชั้นฝึกฝน ทำหน้าที่จัดการกับความซับซ้อนของแบบจำลอง โดยภาพที่ 2.16 แสดง Auxiliary classifier ในกรอบสีแดงที่แทรกระหว่างชั้นในระหว่างการฝึกฝน



ภาพที่ 2.16 Auxiliary classifier ทำหน้าที่เป็น Regularization

- Grid size reduction คือเทคนิคการลดขนาดฟังก์ชันลักษณะที่มีประสิทธิภาพมากขึ้นแทนการทำพูลลิ่งด้วยใช้ฟังก์ชันค่าสูงสุด ซึ่งอาจทำให้เกิดปัญหาคอขวด (bottlenecks) ดังภาพที่ 2.17 แสดงการลดขนาดของกริด


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



ภาพที่ 2.17 การลดขนาดแบบเดิม (ซ้ายบน) การลดขนาดกริดอย่างมีประสิทธิภาพ (ซ้ายล่าง) โครงสร้างโดยละเอียดของการลดขนาดกริดที่มีประสิทธิภาพ (ขวา)

จากภาพที่ 2.17 แสดงให้เห็นก่อนที่จะมีการลดขนาดของภาพ (ซ้ายบน) และการลดขนาดกริด (ซ้ายล่าง) โดยจากชั้นก่อนหน้า มีขนาด  $35 \times 35 \times 320$  ( $2n \times 2n \times c$ ) จะถูกแบ่งในชั้นคอนโวลูชัน และพูลลิ่ง  $17 \times 17 \times 320$  ( $n \times n \times c$ ) แล้วจะได้ผลลัพธ์ เป็น  $17 \times 17 \times 640$  ( $n \times n \times 2c$ ) ส่วน (ขวา) Grid size reduction module ที่มีการใช้ จำนวนก้าวข้ามของชั้นคอนโวลูชัน มีค่าเป็น 2 ซึ่งจะทำให้ขนาดของ channel เพิ่มขึ้น เนื่องจากข้อมูลจะถูกเพิ่มเข้าไปใน channel เพิ่มเติมหลังจากการรวมกัน ทำให้มีข้อมูลมากขึ้น โดยที่ไม่เปลี่ยนแปลงขนาดพื้นที่

ภาพที่ 2.18 แสดงโครงสร้างแบบ Inception v3 ที่ประกอบด้วยขั้นตอนต่าง ๆ ที่กล่าวมาข้างต้น



ภาพที่ 2.18 โครงสร้างแบบ Inception v3

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 2.2.4 การประเมินประสิทธิภาพแบบจำลอง

การวิเคราะห์ความถูกต้อง ในงานวิจัยนี้จะประเมินประสิทธิภาพแบบจำลองโดยพิจารณาจากค่าความแม่นยำ (Accuracy) ความเที่ยงตรง (Precision) และ F1-score โดยคำนวณจากสมการดังต่อไปนี้

- ความแม่นยำ (Accuracy)

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (2.4)$$

- ความเที่ยงตรง (Precision)

$$Precision(class = i) = \frac{TP(class=i)}{TP(class=i)+FP(class=i)} \quad (2.5)$$

- ความไว (Recall)

$$Recall(class = i) = \frac{TP(class=i)}{TP(class=i)+FN(class=i)} \quad (2.6)$$

- F1-score

$$F1 - score(class = i) = \frac{2 \times Precision(class=i) \times Recall(class=i)}{Precision(class=i) + Recall(class=i)} \quad (2.7)$$

เมื่อ

$TP$  (True Positive)

กำลังพิจารณา

$FP$  (False Positive)

พิจารณา

$FN$  (False Negative)

$TN$  (True Negative)

ไม่ได้พิจารณา

คือ คลาส  $i$

คือ จำนวนที่ทำนายตรงกับข้อมูลจริงในคลาสที่

คือ จำนวนที่ทำนายผิดเป็นคลาสที่กำลัง

คือ จำนวนที่ทำนายผิดเป็นคลาสที่ไม่ได้พิจารณา

คือ จำนวนที่ทำนายตรงกับข้อมูลจริงในคลาสที่

## 2.3 ระบบให้การแนะนำ (Recommender System)

ระบบให้การแนะนำ (Recommender System) เป็นระบบที่ออกแบบเพื่อช่วยผู้ใช้หรือลูกค้าค้นหา และเลือกสินค้าหรือบริการที่ตรงกับความสนใจ และความต้องการของอย่างเหมาะสม ระบบนี้ใช้เทคโนโลยีและอัลกอริทึมเพื่อทำการแนะนำและส่งเสริมการเลือกซื้อหรือการใช้งานสินค้าหรือบริการ โดยหวังว่าผู้ใช้จะพบสิ่งที่ต้องการ และสนใจมากที่สุด โดยระบบให้การแนะนำสามารถจำแนกประเภทจากวิธีการแนะนำเป็น 5 ประเภท ได้แก่

- 1) การกรองแบบใช้เนื้อหา (Content-based Filtering) เป็นระบบแนะนำที่ปรับการแนะนำให้เข้ากับผู้ใช้ โดยการวิเคราะห์ลักษณะและคุณสมบัติของรายการ ใน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ระบบนี้ให้ความสำคัญกับพฤติกรรมและความชื่นชอบของผู้ใช้ในอดีต ระบบจะแนะนำรายการเมื่อรายการนั้นมีคุณสมบัติที่คล้ายกับสิ่งที่ผู้ใช้เคยชอบในอดีต

การกรองแบบใช้เนื้อหา ใช้พื้นฐานจากข้อมูลจากรายละเอียดเนื้อหาของข้อมูลนั้น ๆ ในการบ่งชี้ว่าผู้ใช้ที่มีความชอบในลักษณะของเนื้อหาข้อมูลแบบใด สำหรับอัลกอริทึม ที่ใช้ในการวิเคราะห์หาความคล้าย โดยทั่วไปมีหลายวิธีการศึกษาค้นคว้าอิสระครั้งนี้ จะกล่าวถึง k-Nearest Neighbor

- 2) การกรองร่วมกัน (Collaborative Filtering) เป็นระบบแนะนำที่พิจารณาความคล้ายคลึงกันของผู้ใช้ที่มีความชื่นชอบคล้ายกัน นิยมใช้กับระบบที่มีการให้คะแนนความชื่นชอบ (Rating) ระบบนี้ให้ความสำคัญกับข้อมูลการให้คะแนนความชื่นชอบของผู้ใช้ เพื่อสร้างคำแนะนำที่เหมาะสมสำหรับผู้ใช้ใหม่ ผู้ใช้ที่มีพฤติกรรมและความชอบที่คล้ายคลึงกัน จะได้รับคำแนะนำเกี่ยวกับสิ่งของที่ผู้ใช้คนอื่นสนใจอยู่
- 3) การกรองโดยใช้ข้อมูลด้านประชากรศาสตร์ (Demographic Filtering) เป็นระบบแนะนำโดยพิจารณาข้อมูลด้านประชากรศาสตร์ เช่น เพศ อายุ อาชีพ การศึกษา ที่อยู่ เชื้อชาติ ของผู้ใช้งาน
- 4) การกรองโดยใช้ความรู้ที่ได้จากผู้ใช้โดยตรง (Knowledge-based Recommender) ระบบจะทำการแนะนำขึ้นมาจากความรู้เฉพาะตัวของผู้ใช้ โดยไม่จำเป็นต้องพิจารณาถึงประวัติ และการให้คะแนนของผู้ใช้ ระบบจะพยายามแนะนำรายการโดยใช้ความรู้ที่ระบบมีเกี่ยวกับรายการที่มีอยู่ ความชอบของผู้ใช้ และเกณฑ์การแนะนำ เช่น สินค้าใดควรถูกแนะนำในสถานการณ์ใด
- 5) การกรองแบบผสม (Hybrid) คือระบบแนะนำที่ผสมผสานหลายวิธีการแนะนำเข้าด้วยกันเพื่อเพิ่มประสิทธิภาพ และความแม่นยำในการแนะนำให้กับผู้ใช้ เช่น การผสมระบบให้การแนะนำแบบการกรองแบบใช้เนื้อหา และ การกรองร่วมกัน เพื่อให้ผู้ใช้ได้รับคำแนะนำที่เป็นรายละเอียดและที่เหมาะสมมากที่สุด

### 2.3.1 K-nearest Neighbors

K-Nearest Neighbors หรือ KNN เป็นอัลกอริทึมการเรียนรู้ของเครื่อง ที่ใช้ในการงานการจัดกลุ่มและการจำแนกข้อมูล ซึ่งเป็นอัลกอริทึมแบบการเรียนรู้แบบมีผู้สอน (Supervised Learning) ที่มีการใช้ความคล้ายคลึงกันของข้อมูลในการทำนาย หรือจัดกลุ่มข้อมูลที่ไม่รู้ผลลัพธ์ล่วงหน้า โดยจะตัดสินใจว่าข้อมูลมีความคล้ายคลึงหรือใกล้เคียงกัน โดยการตรวจสอบข้อมูลบางจำนวน (K) ซึ่ง K หมายถึงจำนวนของข้อมูลที่ใกล้เคียงที่สุดที่จะนำมาพิจารณา

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

การคำนวณระยะห่าง ในการระบุว่าจุดข้อมูลใดที่คล้ายคลึงกัน จำเป็นต้องคำนวณระยะทางระหว่างจุด ในการวัดระยะทางมีหลายวิธี การศึกษาค้นคว้าอิสระครั้งนี้ จะกล่าวถึง Euclidean distance

Euclidean distance ถูกนำมาใช้เพื่อหาระยะห่างระหว่างจุดข้อมูลต่าง ๆ เพื่อทำการจัดกลุ่มหรือค้นหา K จุดที่ใกล้ที่สุดของจุดที่ต้องการจำแนกหรือทำนาย โดยมีสมการคำนวณ ดังนี้

$$d(x, y) = \sqrt{\sum_{i=1}^n (y_i - x_i)^2} \tag{2.8}$$

โดยที่  $d(x, y)$  คือ ระยะห่างระหว่างจุด  $x$  ไปยังจุด  $y$   
 $x$  คือ จุดใด ๆ  
 $y$  คือ จุดใด ๆ  
 $n$  คือ จำนวนมิติของข้อมูล

### 2.4 การทดสอบความเป็นอิสระด้วยไคกำลังสอง

การทดสอบความเป็นอิสระด้วยไคกำลังสอง หรือไคสแควร์ (Chi-Square Test of Independence) คือ การทดสอบทางสถิติที่ใช้เพื่อพิจารณาว่าตัวแปรที่อยู่ในระดับนามบัญญัติ หรือเรียงลำดับ สองตัวมีความสัมพันธ์กันหรือไม่ หรือกล่าวอีกอย่างหนึ่งคือตัวแปรทั้งสองอิสระต่อกันหรือไม่ เป็นการทดสอบสมมติฐานที่ใช้ในกรณีที่ข้อมูลแบ่งออกเป็นกลุ่ม หรืออยู่ในรูปของความถี่ ซึ่งความถี่นั้นเป็นความถี่ของแต่ละกลุ่ม โดยการจำแนกสองทาง (Two -Way Table) หรือตารางการณ์จร (Contingency table)

ตารางที่ 2.1 ตารางการณ์จร  $r$  แถว และ  $c$  สดมภ์

ตัวแปร $X$	ตัวแปร $Y$						รวม
	$Y_1$	$Y_2$	...	$j$	...	$Y_c$	
$X_1$	$O_{11}$	$O_{12}$	...	$O_{1j}$	...	$O_{1c}$	$R_1$
$X_2$	$O_{21}$	$O_{22}$	...	$O_{2j}$	...	$O_{2c}$	$R_2$
⋮	⋮	⋮		⋮		⋮	⋮
$i$	$O_{i1}$	$O_{i2}$	...	$O_{ij}$	...	$O_{ic}$	$R_i$
⋮	⋮	⋮		⋮		⋮	⋮
$X_t$	$O_{r1}$	$O_{r2}$	...	$O_{rj}$	...	$O_{rc}$	$R_t$
รวม	$C_1$	$C_2$	...	$C_j$	...	$C_c$	$n$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

การตั้งสมมติฐานในการทดสอบ

$H_0$ : ตัวแปร X และ Y ไม่มีความสัมพันธ์กัน

$H_1$ : ตัวแปร X และ Y มีความสัมพันธ์กัน

สูตรการคำนวณการทดสอบความเป็นอิสระ คือ

$$\chi^2 = \sum_{i=1}^r \sum_{j=1}^c \frac{(O_{ij} - E_{ij})^2}{E_{ij}} ; \quad df = (r - 1)(c - 1) \quad (2.9)$$

โดยที่  $E_{ij} = \frac{R_i \times C_j}{n}$  ;  $R_i = \sum_{j=1}^c O_{ij}$  ,  $C_j = \sum_{i=1}^r O_{ij}$

เมื่อ  $\chi^2$  แทนค่าสถิติไคสแควร์ที่คำนวณได้

$R_i$  แทนผลรวมของแถวแนวนอน

$C_j$  แทนผลรวมของแถวแนวตั้ง

$O_{ij}$  แทนความถี่ที่ได้จากการสังเกตในแถวที่  $i$  สดมภ์ที่  $j$

$E_{ij}$  แทนความถี่ที่คาดหวังในแถวที่  $i$  สดมภ์ที่  $j$

การตัดสินใจจะปฏิเสธสมมติฐานหลัก ( $H_0$ ) เมื่อค่าระดับนัยสำคัญของค่าสถิติทดสอบมีค่าน้อยกว่าระดับนัยสำคัญทางสถิติที่กำหนด หรือค่า p-value น้อยกว่าระดับนัยสำคัญ

ข้อตกลงเบื้องต้นของการทดสอบความเป็นอิสระ มีดังนี้

- 1) ตัวแปรอยู่ในมาตรานามบัญญัติหรือเรียงอันดับ
- 2) ตัวแปรทั้งสองต้องเป็นอิสระต่อกัน
- 3) ข้อมูลต้องอยู่ในรูปของความถี่
- 4) ความถี่ที่คาดหวังในแต่ละกลุ่มต้องไม่น้อยกว่า 5 หรือมีความถี่คาดหวังที่น้อยกว่า 5 ควรมีจำนวนน้อยกว่าร้อยละ 20 ของจำนวนกลุ่มทั้งหมด กรณีที่กลุ่มใดมีความถี่คาดหวังน้อยกว่า 5 เกินร้อยละ 20 ของจำนวนกลุ่มทั้งหมด การศึกษาครั้งนี้เลือกใช้สถิติทดสอบ Likelihood Ratio Chi-square มีสมการดังนี้

$$\chi_{LR}^2 = 2 \sum_{i=1}^r \sum_{j=1}^c O_{ij} \ln \frac{E_{ij}}{O_{ij}} ; \quad df = (r - 1)(c - 1) \quad (2.10)$$

## 2.5 งานวิจัยที่เกี่ยวข้อง

Pegah และคณะ (2022) ทำการศึกษาเพื่อหาแบบจำลอง CNN ที่เหมาะสมสำหรับระบบแนะนำรูปภาพเพื่อเพิ่มความแม่นยำของระบบแนะนำ โดยเสนอเทคนิคการเรียนรู้เชิงลึก โดยใช้แบบจำลอง Convolutional Neural Network (CNN) ห้า รูปแบบ คือ VGG16, VGG19, ResNet50, Inception v3, และ Xception เพื่อดึงข้อมูลลักษณะจากรูปภาพของสินค้า และใช้อัลกอริทึม KNN สำหรับการแนะนำและในการวัดความคล้ายคลึงของภาพจะคำนวณจาก Cosine distance จากการรวบรวมชุดข้อมูล MovieLens ประกอบด้วยโปสเตอร์ภาพยนตร์จาก The Movie เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Database (TMDB) 4 เวอร์ชัน คือ 100k, 1M, 10M, และ 20M ผลการทดลองแสดงให้เห็นถึงการเพิ่มขึ้นอย่างมีนัยสำคัญในความแม่นยำเมื่อเทียบกับวิธีการแบบดั้งเดิม และการตั้งค่าที่แตกต่างกันสำหรับโมเดล CNN แต่ละโมเดลที่เลือกอาจส่งผลต่อเมตริกซ์ความคล้ายคลึงของคุณลักษณะที่แยกออกมา

Indira และคณะ (2022) ทำการศึกษาเพื่อสร้างระบบการแนะนำรูปภาพผลิตภัณฑ์โดยใช้ Optimization algorithm และ Deep residual network เพื่อแยกคุณสมบัติต่าง ๆ จากรูปภาพผลิตภัณฑ์และลำดับการซื้อ จากการรวบรวมชุดข้อมูล Amazon product reviews (Amazon Product Reviews dataset, 2020) จำนวน 9.35 ล้านรายการตั้งแต่เดือนพฤษภาคม 1996 ถึง กรกฎาคม 2014 ซึ่งเกี่ยวข้องกับความสัมพันธ์ระหว่างรายการต่อรายการ ราคา อันดับการขาย การประทับเวลา หมวดหมู่ คะแนนโหวต ผลิตภัณฑ์ รูปภาพ บทวิจารณ์ และการให้คะแนน พบว่าการเปรียบเทียบประสิทธิภาพของระบบกับวิธีการอื่น ๆ หลายวิธี รวมถึง Collaborative filtering, Content-based filtering และวิธีการแบบผสม ผลลัพธ์แสดงให้เห็นว่าระบบที่นำเสนอมีประสิทธิภาพเหนือกว่าวิธีการที่มีอยู่ในแง่ของ Accuracy, Precision, Recall และ F1-score

Shereen และคณะ (2022) ทำการศึกษาเสนอแบบจำลองการรับรู้คุณลักษณะที่เรียบง่ายแต่มีประสิทธิภาพ ซึ่งรวมคุณลักษณะรูปภาพเพื่อการเรียนรู้การนำเสนอรายการที่ดีขึ้นในงานแนะนำสินค้า โดยเสนอวิธีการปรับ ResNet50 จากการรวบรวมชุดข้อมูล Amazon fashion รวบรวมจาก 6 หมวดหมู่ที่แตกต่างกัน เสื้อ กางเกง และรองเท้าสำหรับผู้ชายและผู้หญิง และชุดข้อมูล Amazon men ที่มีหมวดหมู่ย่อยทั้งหมด เช่น ถุงมือ ผ้าพันคอ แวนกันแดด พบว่าแบบจำลองที่นำเสนอมีประสิทธิภาพเหนือกว่าแบบจำลองที่ใช้รูปภาพที่คล้ายกันทั้งหมดในชุดข้อมูลระบบแนะนำรูปภาพทั้งสองชุดข้อมูล

Anupama และคณะ (2021) ทำการศึกษาเพื่อประยุกต์ใช้โครงข่ายประสาทเทียม CNN และแบบจำลอง Transfer Learning สำหรับการแนะนำผลิตภัณฑ์ที่คล้ายคลึงกัน โดยใช้การเรียนรู้เชิงถ่ายโอนของแบบจำลอง Convolutional Neural Network คือ VGG16 สำหรับจำแนกรูปภาพและหาภาพที่คล้ายกัน และวัดความคล้ายของภาพด้วย Euclidean และ Cosine distance จากการรวบรวมชุดข้อมูลรูปภาพสินค้าแฟชั่นความละเอียดสูง 2,000 ภาพจาก Kaggle พบว่าระบบการแนะนำเนื้อหาด้วยรูปภาพที่เสนอโดยใช้ CNN มีประสิทธิภาพเหนือกว่าระบบการแนะนำอื่น ๆ เช่น collaborative filtering และ matrix factorization โดยแบบจำลองที่มีประสิทธิภาพมากที่สุดคือ โมเดลที่มีวิธีการ CNN + Pre-Trained โดยได้ precision/recall มากถึง 71%

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Akshit และคณะ (2021) ทำการศึกษาการใช้การเรียนรู้เชิงลึกในการพัฒนาระบบการแนะนำสินค้า โดยเทคนิคการเรียนรู้เชิงลึก ถูกนำมาใช้โดยใช้ Transfer Learning โครงสร้าง VGG16 และใช้ Cosine similarity เพื่อคำนวณหารายการที่คล้ายกันมากที่สุด จากการรวบรวมชุดข้อมูลรูปภาพ Style Color Images ประกอบด้วยเครื่องแต่งกายแฟชั่น เช่น รองเท้า รองเท้าส้นสูง แหวน เสื้อผ้าสำหรับชายและหญิง ชุดข้อมูลมาพร้อมกับไฟล์ข้อความที่ประกอบด้วยตัวแปรต่างๆ เช่น ชื่อแบรนด์ ชื่อผลิตภัณฑ์ ประเภทผลิตภัณฑ์ ฉลาก ไฟล์รูปภาพ และชุดข้อมูลเครื่องแต่งกายจากฐานข้อมูล DeepFashion ประกอบด้วยรูปภาพแฟชั่นที่หลากหลาย ตั้งแต่รูปภาพร้านค้าที่จัดวางอย่างดีซึ่งมีเสื้อผ้าผู้หญิง 14 แบบ และเสื้อผ้าผู้ชาย 9 แบบ มีการรวบรวมและรวมภาพมากกว่า 5,000 ภาพ โดยแยกรายการของผู้หญิงและผู้ชาย พบว่า หลังจากสุ่มตัวอย่างภาพมาทดสอบแล้วได้ระบบแนะนำเสื้อผ้า ที่มีประสิทธิภาพดี (ให้คะแนนความคล้ายคลึงกันมากกว่า 80%) และแสดงให้เห็นศักยภาพที่ดีในการแก้ไขคำแนะนำเฉพาะบุคคล



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## บทที่ 3

### วิธีดำเนินการศึกษา

การศึกษาค้นคว้าอิสระครั้งนี้ มีวัตถุประสงค์เพื่อพัฒนาแบบจำลองโครงข่ายประสาทแบบคอนโวลูชันสำหรับค้นหาคุณลักษณะจากรูปภาพสินค้าแฟชั่น เปรียบเทียบประสิทธิภาพของแบบจำลองในการจำแนกรูปภาพสินค้าแฟชั่น โดยโครงข่ายประสาทแบบคอนโวลูชันที่แตกต่างกัน 3 โครงสร้าง ประกอบด้วย ResNet, VGGNet และ Inception v3 พัฒนาระบบแนะนำสินค้าแบบออนไลน์ โดยใช้วิธีการ K-NN (K-Nearest Neighbor) เพื่อแนะนำสินค้าที่มีความคล้ายคลึงกัน โดยมีขั้นตอนในการศึกษาและดำเนินการศึกษา ดังนี้

- 3.1. เครื่องมือที่ใช้ในการศึกษา
- 3.2. ข้อมูลที่ใช้ในการศึกษา
- 3.3. ขั้นตอนในกระบวนการสร้างแบบจำลอง
- 3.4. ขั้นตอนการให้การแนะนำ

#### 3.1 เครื่องมือที่ใช้ในการศึกษา

- 3.1.1 การเขียนโปรแกรมทั้งหมดโดยใช้ภาษา Python เวอร์ชัน 3.11.1
- 3.1.2 Anaconda Navigator เวอร์ชัน 2.5.0 และ Jupyter Notebook 7.0.6
- 3.1.3 ไลบรารีฟังก์ชันการเขียนโปรแกรม (Library of Programming Functions)

#### 3.2 ข้อมูลที่ใช้ในการศึกษา

การศึกษาค้นคว้าอิสระครั้งนี้ ได้นำข้อมูลที่ใช้ในการศึกษา 2 ชุด ได้แก่

- 3.2.1 ข้อมูลที่ใช้ในการศึกษาเป็นข้อมูลผลิตภัณฑ์แฟชั่น (Fashion Product) ที่ทำการติดฉลากกำกับ (Label) เรียบร้อยแล้ว จำนวน 143 ประเภทสินค้า เช่น เสื้อเชิ้ต นาฬิกา รองเท้าส้นสูง ชุดชั้นใน รวมทั้งหมดจำนวน 44,424 ข้อมูลจากเว็บไซต์ Kaggle โดยข้อมูลแบ่งเป็น 2 ประเภท คือ
  - ข้อมูลที่มีโครงสร้าง คือข้อมูลอธิบายลักษณะของผลิตภัณฑ์ ดังภาพที่ 3.1

id	gender	masterCategory	subCategory	articleType	baseColour	season	year	usage	productDisplayName
15970	Men	Apparel	Topwear	Shirts	Navy Blue	Fall	2011	Casual	Turtle Check Men Navy Blue Shirt
59263	Women	Accessories	Watches	Watches	Silver	Winter	2016	Casual	Titan Women Silver Watch
53759	Men	Apparel	Topwear	Tshirts	Grey	Summer	2012	Casual	Puma Men Grey T-shirt
1855	Men	Apparel	Topwear	Tshirts	Grey	Summer	2011	Casual	Inkfruit Mens Chain Reaction T-shirt
30805	Men	Apparel	Topwear	Shirts	Green	Summer	2012	Ethnic	Fabindia Men Striped Green Shirt
26960	Women	Apparel	Topwear	Shirts	Purple	Summer	2012	Casual	Jealous 21 Women Purple Shirt
30039	Men	Accessories	Watches	Watches	Black	Winter	2016	Casual	Skagen Men Black Watch
9204	Men	Footwear	Shoes	Casual Shoes	Black	Summer	2011	Casual	Puma Men Future Cat Remix SF Black Casual Shoes
47957	Women	Accessories	Bags	Handbags	Blue	Summer	2012	Casual	Murcia Women Blue Handbag
12369	Men	Apparel	Topwear	Shirts	Purple	Fall	2011	Formal	Reid & Taylor Men Check Purple Shirts
29928	Men	Accessories	Watches	Watches	Black	Winter	2016	Casual	Police Men Black Dial Watch PL12689JSB
42419	Girls	Apparel	Topwear	Tops	White	Summer	2012	Casual	Gini and Jony Girls Knit White Top
47359	Women	Accessories	Bags	Handbags	Brown	Summer	2012	Casual	Baggitt Women Brown Handbag
17429	Men	Accessories	Watches	Watches	Black	Winter	2016	Casual	CASIO G-Shock Men Black Digital Watch G-7710-1DR G223
7990	Men	Apparel	Topwear	Tshirts	Navy Blue	Fall	2011	Sports	Fila Men's Round Neck Navy Blue T-shirt
21977	Women	Accessories	Bags	Handbags	Brown	Winter	2015	Casual	Murcia Women Casual Brown Handbag
37812	Men	Apparel	Topwear	Shirts	Navy Blue	Summer	2012	Formal	John Players Men Navy Blue Shirt
4729	Boys	Apparel	Topwear	Tshirts	Green	Summer	2011	Casual	Disney Kids Boy's Crew Sea Life Sialing Green Teen Kidswear
56825	Men	Apparel	Topwear	Shirts	Brown	Summer	2012	Casual	John Players Men Brown Shirt
39988	Men	Footwear	Shoes	Casual Shoes	White	Winter	2014	Casual	Gas Men Europa White Shoes
20099	Women	Apparel	Topwear	Kurtas	Green	Fall	2011	Ethnic	Diva Women Embroidered Green Kurta
58183	Women	Accessories	Bags	Handbags	White	Summer	2012	Casual	Rocky S Women White Handbag
29742	Women	Accessories	Bags	Handbags	Teal	Summer	2012	Casual	Kiara Women Teal Handbag
51658	Women	Accessories	Watches	Watches	Copper	Winter	2016	Casual	Fossil Women Copper Chronograph Watch CH2589
3954	Women	Apparel	Topwear	Tshirts	Pink	Summer	2011	Casual	Jealous 21 Women's Pink T-shirt

ภาพที่ 3.1 ตัวอย่างของชุดข้อมูลอธิบายลักษณะของผลิตภัณฑ์แฟชั่นที่ใช้ในการศึกษา

โดยมีตัวแปรที่อธิบายลักษณะของผลิตภัณฑ์แฟชั่น ดังนี้

- Id คือ รหัสสินค้า
- Gender คือ เพศที่เป็นกลุ่มเป้าหมายของสินค้า
- masterCategory คือ หมวดหมู่หลักของสินค้า
- subcategory คือ หมวดหมู่ย่อยของสินค้า
- articleType คือ ประเภทของเสื้อผ้า
- baseColour คือ สีของสินค้า
- season คือ ฤดูกาลเป้าหมายของสินค้า
- year คือ แฟชั่นนี้มาจากปี ค.ศ. ไດ
- usage คือ วิธีการใช้งานสินค้า
- productDisplayName คือ ชื่อสินค้า


- ข้อมูลที่ไม่มีโครงสร้าง คือข้อมูลรูปภาพสีของผลิตภัณฑ์ ดังภาพที่ 3.1



ภาพที่ 3.2 ตัวอย่างรูปภาพผลิตภัณฑ์แฟชั่นที่ใช้ในการศึกษา

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.2.2 ชุดข้อมูลของรูปภาพ Fashion-MNIST จาก Zalando ประกอบด้วยชุดข้อมูลสำหรับฝึกสอนจำนวน 60,000 ตัวอย่างและชุดทดสอบ 10,000 ตัวอย่าง แต่ละตัวอย่างเป็นรูปภาพขนาด 28x28 พิกเซล มีฉลากกำกับ จาก 10 กลุ่มสินค้าต่าง ๆ

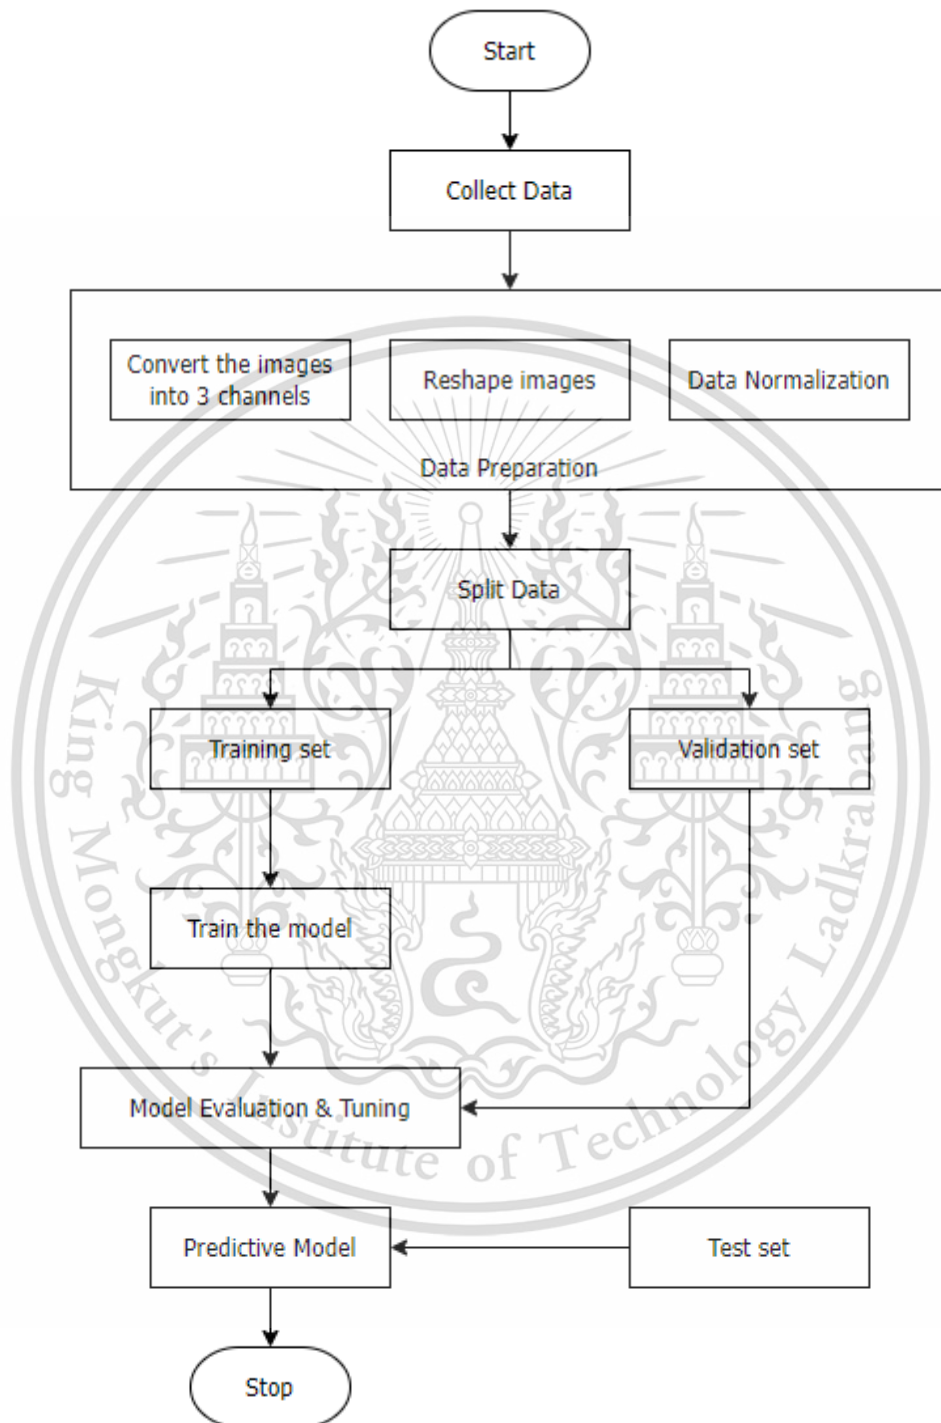


ภาพที่ 3.3 ตัวอย่างรูปภาพจากชุดข้อมูล Fashion-MNIST ที่ใช้ในการศึกษา

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 3.3 ขั้นตอนในกระบวนการสร้างแบบจำลอง

ลำดับขั้นตอนภาพรวมของกระบวนการสร้างแบบจำลอง แสดงดังภาพที่ 3.3



ภาพที่ 3.4 ลำดับขั้นตอนโดยภาพรวมในกระบวนการสร้างแบบจำลอง

จากภาพที่ 3.4 สามารถจำแนกการดำเนินงานออกเป็นขั้นตอนต่าง ๆ ได้ดังนี้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.3.1 การเก็บรวบรวมข้อมูลรูปภาพ โดยชุดข้อมูลในกระบวนการสร้างแบบจำลอง จะใช้ชุดข้อมูล Fashion-MNIST ที่มีชุดข้อมูลแยกไว้สำหรับฝึกสอน และชุดทดสอบไว้แล้ว โดยมีคลาสสำหรับจำแนกรูปภาพจำนวน 10 คลาส ได้แก่ เสื้อยืด กางเกงขายาว เสื้อกันหนาว ชุดเดรส เสื้อโค้ท รองเท้าแตะ เสื้อเชิ้ต รองเท้าผ้าใบ กระเป๋า และรองเท้าบูท

3.3.2 การเตรียมข้อมูลรูปภาพ โดยกำหนดให้รูปภาพมีขนาด  $48 \times 48$  พิกเซล และ 3 ช่องเพื่อใช้ในการสกัดคุณลักษณะเด่นของข้อมูลรูปภาพ และทำการปรับค่าคุณลักษณะให้เป็นค่ามาตรฐาน (Normalizing) อยู่ในช่วง 0 ถึง 1


3.3.3 การแบ่งข้อมูลออกจากชุดข้อมูลสำหรับฝึกสอน เป็นสองชุด โดยชุดข้อมูลแรกไว้สำหรับฝึกสอนแบบจำลองจำนวนร้อยละ 80 ของข้อมูลทั้งหมด และอีกร้อยละ 20 ของข้อมูลคือ ชุดข้อมูลสำหรับตรวจสอบ

### 3.3.4 การสร้างแบบจำลอง

การใช้แบบจำลองที่ได้รับการเรียนรู้มาก่อน (Pre-trained model) เป็นแบบจำลองตั้งต้นเพื่อเริ่มการเรียนรู้กับชุดข้อมูลอื่น ๆ จำเป็นจะต้องปรับเปลี่ยนส่วนท้ายของแบบจำลอง (Top Layer) เพื่อให้เหมาะสมกับลักษณะของข้อมูลที่ใช้ในการฝึก ซึ่งทำให้แบบจำลองมีความสามารถที่ดีในการจำแนก

ในการศึกษาค้นคว้าอิสระครั้งนี้ กำหนดขนาดของภาพตั้งต้นให้มีขนาด  $48 \times 48$  โดยมีการดัดแปลง และเพิ่มส่วนท้ายของแบบจำลอง ดังภาพที่ 3.5 และอธิบายได้ ดังนี้

- ชั้น Flatten เพื่อจะทำการเปลี่ยนรูปฝังคุณลักษณะ
- ชั้น แอบแฝง (Hidden Layer) หรือ Dense Layer เพื่อเชื่อมต่อทุกนิวรอน กำหนดให้ผลลัพธ์เป็น 512 และใช้ฟังก์ชันกระตุ้น ReLU
- ป้องกันการเกิด Overfitting โดยการทำให้ Regularization ด้วยวิธีการ Dropout โดยกำหนดให้สุ่มปิดนิวรอนร้อยละ 20 จากชั้นที่เชื่อมต่อกันอย่างสมบูรณ์
- ชั้นส่งออกข้อมูล (Output Layer) หรือ Dense Layer โดยกำหนดให้มีจำนวน 10 โหนด เท่ากับจำนวนคลาส และใช้ฟังก์ชันกระตุ้น Softmax



ภาพที่ 3.5 โครงสร้างการดัดแปลง และเพิ่มส่วนท้ายของแบบจำลอง

3.3.5 การกำหนดจำนวนรอบ (Epoch) โดยกำหนดให้มีค่าเท่ากับ 50

3.3.6 การกำหนดค่ากระบวนการเรียนรู้ และการคอมไพล์ (Compile) แบบจำลอง โดยเลือกใช้ Loss Function ชื่อ Categorical Cross entropy และวิธีการหาค่าที่เหมาะสมที่สุดของ Adaptive moment estimation (Adam)


3.3.7 การประเมินประสิทธิภาพของแบบจำลอง จะทำการสร้าง Callback เพื่อบันทึกค่าน้ำหนักของแบบจำลองที่ประสิทธิภาพดีที่สุดใน Epoch รวมถึงใช้เทคนิค Early Stopping เพื่อหยุดกระบวนการฝึกแบบจำลองไว้ก่อนที่แบบจำลองจะเริ่มเกิด Overfitting และเทคนิคในการลดอัตราการเรียนรู้ (Learning Rate) เมื่อตัวชี้วัดไม่มีการปรับปรุงใด ๆ อัตราการเรียนรู้จะถูกลดลง

3.3.8 การประเมินประสิทธิภาพของแบบจำลอง หลังจากนั้นนำแบบจำลองไปทดสอบบนชุดข้อมูลที่ใช้ทดสอบ เพื่อเปรียบเทียบประสิทธิภาพ และเลือกแบบจำลองที่มีความแม่นยำมากที่สุดไปใช้ในขั้นตอนถัดไป

### 3.4 ขั้นตอนในกระบวนการให้การแนะนำ

ลำดับขั้นตอนภาพรวมของกระบวนการให้การแนะนำ แสดงดังภาพที่ 3.6

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



ภาพที่ 3.6 ลำดับขั้นตอนโดยภาพรวมในกระบวนการให้การแนะนำ

จากภาพที่ 3.6 สามารถจำแนกการดำเนินงานออกเป็นขั้นตอนต่าง ๆ ได้ดังนี้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.4.1 การรวบรวมข้อมูลรูปภาพ โดยชุดข้อมูลที่จะใช้ในกระบวนการนี้ คือ ชุดข้อมูล Fashion Product ซึ่งจะมีข้อมูลเป็นสองส่วนจำแนกตามโครงสร้าง คือ ข้อมูลที่มีโครงสร้าง และ ข้อมูลที่ไม่มีโครงสร้าง ในขั้นตอนนี้จะใช้ข้อมูลที่ไม่มีโครงสร้าง คือรูปภาพ

3.4.2 การนำแบบจำลองที่ได้ผลลัพธ์ที่ดีที่สุดจากกระบวนการสร้างแบบจำลองมาใช้ โดยจะทำการตัดขั้นสุดท้ายหรือขั้นทำนายออกจากแบบจำลอง เนื่องจากการศึกษาค้นคว้าอิสระครั้งนี้ไม่ได้มีวัตถุประสงค์ที่จะสร้างแบบจำลองเพื่อจำแนกรูปภาพ แต่เพื่อค้นหาคุณลักษณะจากรูปภาพสินค้าแพชั่น จึงทำการตัดชุดทำนายของแบบจำลองออก เพื่อให้ได้คุณลักษณะจากรูปภาพ

3.4.3 หลังจากนำรูปภาพเข้าแบบจำลอง จะได้ผลลัพธ์ของแต่ละรูปภาพ เป็นค่า คุณลักษณะ จำนวน 512 ค่า ตามจำนวนนิวรอลในขั้นสุดท้ายของแบบจำลอง โดยมีค่าตั้งแต่ 0 ถึง 1 ในขั้นนี้ จะนำผลลัพธ์ของแต่ละรูปภาพ ไปรวมกับข้อมูลที่มีโครงสร้างของชุดข้อมูล Fashion Product ดังภาพที่ 3.7

id	gender	masterCategory	subCategory	articleType	baseColour	season	year	usage	productDisplayName	...	503	504	505	506	507	508	509	510	511	512
0	15970	Men	Apparel	Topwear	Shirts	Navy Blue	Fall	2011.0	Casual	Turtleneck Men Navy Blue Shirt	0.0	0.000000	0.000000	1.165734	0.000000	0.404663	1.103281	0.769007	0.0	0.0
1	39386	Men	Apparel	Bottomwear	Jeans	Blue	Summer	2012.0	Casual	Peter England Men Party Blue Jeans	0.0	0.132494	0.000000	0.230133	0.107618	0.000000	1.193264	0.778327	0.0	0.0
2	59263	Women	Accessories	Watches	Watches	Silver	Winter	2016.0	Casual	Titan Women Silver Watch	0.0	0.000000	0.080620	0.745753	0.292159	0.000000	0.976324	0.704970	0.0	0.0
3	21379	Men	Apparel	Bottomwear	Track Pants	Black	Fall	2011.0	Casual	Manchester United Men Solid Black Track Pants	0.0	0.095738	0.007195	0.621567	0.000000	0.000000	0.797479	0.683981	0.0	0.0
4	53759	Men	Apparel	Topwear	Tshirts	Grey	Summer	2012.0	Casual	Puma Men Grey T-shirt	0.0	0.000000	0.000000	0.543122	0.000000	0.000000	1.241319	0.790498	0.0	0.0
...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...
44414	17036	Men	Footwear	Shoes	Casual Shoes	White	Summer	2013.0	Casual	Gas Men Caddy Casual Shoe	0.0	0.000000	0.069857	0.738534	0.363205	0.060322	1.099349	0.772828	0.0	0.0
44415	6461	Men	Footwear	Flip Flops	Flip Flops	Red	Summer	2011.0	Casual	Lotto Men's Soccer Track Flip Flop	0.0	0.124537	0.000000	0.563794	0.170377	0.000000	0.954033	0.835019	0.0	0.0
44416	18842	Men	Apparel	Topwear	Tshirts	Blue	Fall	2011.0	Casual	Puma Men Graphic Stellar Blue T-shirt	0.0	0.000000	0.000000	0.737000	0.000000	0.000000	1.016648	0.861387	0.0	0.0
44417	46694	Women	Personal Care	Fragrance	Perfume and Body Mist	Blue	Spring	2017.0	Casual	Rasasi Women Blue Lady Perfume	0.0	0.000000	0.000000	0.351615	0.321840	0.000000	0.981434	0.968814	0.0	0.0
44418	51623	Women	Accessories	Watches	Watches	Pink	Winter	2016.0	Casual	Fossil Women Pink Dial Chronograph Watch ES3050	0.0	0.000000	0.129922	0.631920	0.000000	0.081134	1.030324	0.996096	0.0	0.0

ภาพที่ 3.7 ผลลัพธ์ของการรวมข้อมูลที่มีโครงสร้างของชุดข้อมูล Fashion Product กับคุณลักษณะจากแบบจำลอง

3.4.4 เตรียมข้อมูลก่อนนำเข้าแบบจำลอง KNN โดย

- นำบางคุณลักษณะของข้อมูลออก ได้แก่ คุณลักษณะที่เป็นเอกลักษณ์ คือ ชื่อสินค้าที่แสดง ไฟล์รูปภาพ คุณลักษณะที่หลังทดสอบความเป็นอิสระ โดยทดสอบด้วยไคกำลังสอง แล้วพบว่าตัวแปรนั้นไม่มีความสัมพันธ์กับตัวแปรหมวดหมู่หลักของสินค้า
- แทนที่ค่าสูญหายในคุณลักษณะของ สีของสินค้า ฤดูกาลของสินค้า และการใช้งาน ด้วย NA และแทนที่ ปีที่ออกสินค้าด้วยค่าเฉลี่ย

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- การทำ One-hot Encoder กับข้อมูลประเภทหมวดหมู่

3.4.5 การนำข้อมูลหลังจากเตรียมแล้วเข้าแบบจำลอง KNN โดยกำหนดค่าพารามิเตอร์ K คือ 5 เนื่องจากผู้ทำการศึกษามีความต้องการให้ระบบแนะนำสินค้าแนะนำสินค้าที่มีลักษณะที่คล้ายคลึงกันจำนวน 5 สินค้า



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## บทที่ 4

### ผลการศึกษา

การศึกษาค้นคว้าอิสระครั้งนี้ ได้ศึกษาพัฒนาแบบจำลองโครงข่ายประสาทแบบคอนโวลูชัน สำหรับค้นหาคุณลักษณะจากรูปภาพสินค้าแฟชั่น เพื่อเปรียบเทียบประสิทธิภาพของแบบจำลองในการจำแนกรูปภาพสินค้าแฟชั่น โดยโครงข่ายประสาทแบบคอนโวลูชันที่แตกต่างกัน 3 โครงสร้าง และพัฒนาระบบแนะนำสินค้าแบบออนไลน์ เพื่อแนะนำสินค้าที่มีความคล้ายคลึงกัน ซึ่งมีรายละเอียดของผลศึกษา ดังนี้

#### 4.1 ผลการทดลองจากกระบวนการสร้างแบบจำลอง

ในขั้นตอนนี้เป็นการเปรียบเทียบประสิทธิภาพแบบจำลองโครงข่ายประสาทแบบคอนโวลูชัน เพื่อค้นหาคุณลักษณะจากรูปภาพสินค้าแฟชั่น ด้วยโครงสร้างแบบจำลองที่แตกต่างกัน 3 โครงสร้าง ได้แก่ ResNet50, VGG16 และ Inception v3

ในการวัดประสิทธิภาพของแบบจำลองทั้ง 3 โครงสร้าง จะทำการวัดโดยการจำแนกประเภทรูปภาพสินค้าแฟชั่น ผู้ศึกษาได้แบ่งข้อมูล ออกเป็น 3 ชุด ได้แก่ ชุดข้อมูลสำหรับฝึกสอนแบบจำลอง ชุดข้อมูลสำหรับตรวจสอบแบบจำลอง และชุดข้อมูลสำหรับทดสอบแบบจำลอง โดยชุดข้อมูลสำหรับฝึกสอนมีจำนวน 60,000 รูปภาพ ถูกแบ่งออกมาเป็นชุดข้อมูลสำหรับตรวจสอบแบบจำลองร้อยละ 20 ของรูปภาพ จะได้รูปภาพสำหรับฝึกสอนจำนวน 48,000 รูปภาพ รูปภาพสำหรับตรวจสอบจำนวน 12,000 รูปภาพ และรูปภาพสำหรับทดสอบ 10,000 รูปภาพ โดยทำการฝึกสอนแบบจำลองสูงสุด 50 รอบ ในแต่ละรอบแบบจำลองจะทำการตรวจสอบแบบจำลองด้วยชุดข้อมูลสำหรับตรวจสอบ เพื่อทดสอบแบบจำลองโดยใช้ค่าความแม่นยำ แล้วทำการปรับปรุงแบบจำลองด้วย โดย Loss Function ชื่อว่า Categorical Cross entropy คำนวณค่าความแตกต่างระหว่างค่าจริงและค่าที่แบบจำลองทำนาย ส่วนวิธีการหาค่าน้ำหนักที่เหมาะสมที่สุด คือ Adam และค่าอัตราการเรียนรู้จะถูกปรับลง เมื่อค่าของ ความสูญเสียที่คำนวณจากการทดสอบแบบจำลองบนชุดข้อมูลสำหรับตรวจสอบ (Validation loss) ไม่ได้ลดลง โดยจะลดอัตราการเรียนรู้ เป็น 0.05 เท่าของค่าอัตราการเรียนรู้เดิม และหยุดการลดอัตราการเรียนรู้เมื่อไม่มีการลดค่าความสูญเสียเกิดขึ้นเป็นเวลา 3 ครั้ง และจะหยุดฝึกสอนแบบจำลองก่อน 50 รอบ เมื่อค่าความสูญเสียไม่ได้ลดลงตามที่ต้องการเป็นเวลาติดต่อกัน 5 รอบ ดังนั้น ในแต่ละโครงสร้างแบบจำลองจะได้ผลการตั้งค่าให้กับแบบจำลองที่ต่างกัน แสดงดังตารางที่ 4.1

ตารางที่ 4.2 การกำหนดค่าต่าง ๆ และผลจากการตั้งค่าให้กับแบบจำลอง

	VGG16	ResNet50	Inception v3
Input image shape	48x48x3	48x48x3	75x75x3
Epoch	17	50	7
Learning rate	0.00005	0.00005	0.00005

#### 4.1.1 ผลการทดลองจากกระบวนการสร้างแบบจำลองโดย VGG16

ในการวัดประสิทธิภาพของแบบจำลองโดย VGG16 ในการจำแนกประเภทรูปภาพสินค้าแฟชั่น เพื่อเปรียบเทียบกับแบบจำลองอื่น ๆ ในขั้นตอนของการประเมินประสิทธิภาพของแบบจำลองบนชุดข้อมูลตรวจสอบเพื่อปรับปรุงแบบจำลอง ผู้ศึกษาจะเลือกใช้ค่าน้ำหนักที่ให้ผลลัพธ์ค่าความสูญเสีย (Validation loss) ที่ต่ำที่สุด โดยแต่ละรอบของการประเมินแบบจำลอง VGG16 ได้ผลลัพธ์ดังตารางที่ 4.3

ตารางที่ 4.3 ผลลัพธ์ประสิทธิภาพของการฝึกสอนแบบจำลอง VGG16 ใน 22 รอบ

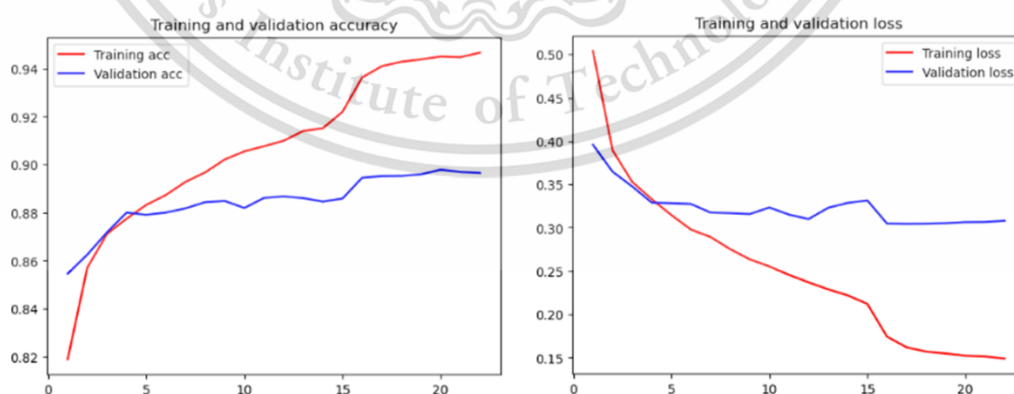
Epoch	Train accuracy	Train loss	Val accuracy	Val loss	Learning Rate
0	0.8190	0.5040	0.8546	0.3958	0.001
1	0.8571	0.3894	0.8625	0.3647	0.001
2	0.8711	0.3529	0.8718	0.3477	0.001
3	0.8775	0.3329	0.8800	0.3289	0.001
4	0.8832	0.3146	0.8791	0.3282	0.001
5	0.8873	0.2978	0.8800	0.3274	0.001
6	0.8928	0.2892	0.8818	0.3175	0.001
7	0.8967	0.2752	0.8843	0.3168	0.001
8	0.9021	0.2635	0.8848	0.3157	0.001
9	0.9055	0.2553	0.8819	0.3233	0.001
10	0.9076	0.2455	0.8861	0.3151	0.001

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.3 (ต่อ)

Epoch	Train accuracy	Train loss	Val accuracy	Val loss	Learning Rate
11	0.9099	0.2369	0.8868	0.3100	0.001
12	0.9140	0.2288	0.8860	0.3230	0.001
13	0.9151	0.2218	0.8846	0.3286	0.001
14	0.9219	0.2120	0.8858	0.3315	0.001
15	0.9362	0.1742	0.8945	0.3047	0.00005
<b>**16</b>	<b>0.9409</b>	<b>0.1619</b>	<b>0.8952</b>	<b>0.3044</b>	<b>0.00005</b>
17	0.9428	0.1569	0.8953	0.3046	0.00005
18	0.9437	0.1547	0.8959	0.3052	0.00005
19	0.9449	0.1522	0.8978	0.3064	0.00005
20	0.9447	0.1513	0.8969	0.3066	0.00005
21	0.9465	0.1489	0.8965	0.3080	0.00005

จากตารางที่ 4.3 พบว่า รอบที่ได้ผลลัพธ์ของการฝึกสอนแบบจำลองที่ดีที่สุดคือ รอบที่ 17 ได้ค่าความแม่นยำ และค่าความสูญเสียบนชุดข้อมูลฝึกสอน คือ ร้อยละ 94 และ ร้อยละ 16 ของชุดข้อมูลฝึกสอนทั้งหมด ตามลำดับ ได้ค่าความแม่นยำ และค่าความสูญเสียบนชุดข้อมูลตรวจสอบ คือ ร้อยละ 89 และ ร้อยละ 30 ของชุดข้อมูลตรวจสอบทั้งหมด ตามลำดับ



ภาพที่ 4.1 ผลลัพธ์ประสิทธิภาพของการฝึกสอนแบบจำลอง VGG16 ใน 22 รอบ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เมื่อเปรียบเทียบค่าความแม่นยำ และค่าความสูญเสียของชุดข้อมูลฝึกสอน และชุดข้อมูลตรวจสอบ ในแต่ละรอบ ดังภาพที่ 4.1 แสดงให้เห็นว่า ค่าความแม่นยำมีแนวโน้มเพิ่มขึ้นเรื่อย ๆ ในแต่ละรอบการฝึกสอน และจะเริ่มคงที่เมื่อรอบที่ 16 เป็นต้นไป ทั้งชุดข้อมูลฝึกสอน และชุดข้อมูลตรวจสอบ ในทำนองเดียวกันกับค่าความสูญเสียที่จะลดลงเรื่อย ๆ และจะเริ่มคงที่ตั้งแต่รอบที่ 16 เป็นต้นไป ทั้งชุดข้อมูลฝึกสอน และชุดข้อมูลตรวจสอบ และจากกราฟค่าความสูญเสียของชุดข้อมูลตรวจสอบมีจุดต่ำสุดในรอบที่ 17

เมื่อนำแบบจำลองไปทดสอบกับชุดข้อมูลสำหรับทดสอบ ได้ผลการจำแนกรูปภาพดังนี้

864	0	17	20	2	0	127	0	2	0
0	986	0	10	1	1	2	0	0	0
17	0	848	6	49	0	53	0	4	0
27	10	15	904	36	0	38	0	0	0
4	1	71	26	859	0	66	0	2	0
1	0	0	0	0	959	0	18	2	7
81	3	49	32	49	0	704	0	6	0
0	0	0	0	0	31	0	958	1	30
6	0	0	2	4	0	10	0	980	1
0	0	0	0	0	9	0	24	3	962

ภาพที่ 4.2 Confusion Matrices การจำแนกรูปภาพสินค้าแฟชั่นด้วย VGG16 โดยแกน y คือค่าจริง (Actual value) และแกน x คือค่าที่ทำนาย (Predicted Value)

จากภาพที่ 4.2 แสดงกราฟ Confusion Matrices การจำแนกรูปภาพสินค้าแฟชั่นด้วย VGG16 โดยแนวตั้ง แสดงค่าจริงของประเภทสินค้า คือ T-shirt/top, Trouser, Pullover, Dress, Coat, Sundal, Shirt, Sneaker, Bag และ Ankle boot ตามลำดับ และแนวนอนคือค่าที่ทำนายได้ พบว่า แบบจำลอง VGG16 ทำนาย Shirt ผิดมากที่สุด รองลงมาคือ Pullover และ Coat ตามลำดับ โดย Shirt ส่วนใหญ่ที่ทำนายผิดจะสลับกับ T-shirt/top และ Pullover ส่วนใหญ่ที่ทำนายผิดจะสลับกับ Coat เนื่องจากเป็นสินค้าที่มีลักษณะคล้ายคลึงกัน

ตารางที่ 4.4 ผลลัพธ์ของการทำนายหรือความแม่นยำในการจำแนกของแบบจำลองโดย VGG16

	Precision	Recall	F1 - score	Support
T-shirt/top	0.8372	0.8640	0.8504	1000
Trouser	0.9860	0.9860	0.9860	1000
Pullover	0.8680	0.8480	0.8579	1000
Dress	0.8777	0.9040	0.8906	1000
Coat	0.8348	0.8590	0.8467	1000
Sundal	0.9716	0.9590	0.9653	1000
Shirt	0.7619	0.7040	0.7318	1000
Sneaker	0.9392	0.9580	0.9485	1000
Bag	0.9771	0.9800	0.9785	1000
Ankle boot	0.9639	0.9620	0.9630	1000
Accuracy			0.9024	10000
Macro Avg	0.9017	0.9024	0.9019	10000
Weighted Avg	0.9017	0.9024	0.9019	10000

จากตารางที่ 4.4 แสดงผลลัพธ์ของการทำนายหรือความแม่นยำในการจำแนกของแบบจำลองโดย VGG16 โดยจะแสดง Precision, Recall, F1-score และ Support ของแต่ละคลาสที่ถูกทำนาย พร้อมกับค่าเฉลี่ยของทั้งหมด พบว่า ค่าความเที่ยงตรงเฉลี่ยของทุกคลาส คือ ร้อยละ 90.17 ค่าความไวเฉลี่ยของทุกคลาส คือ ร้อยละ 90.24 ค่า F1-score คือร้อยละ 90.19 แบบจำลองนี้มีความถูกต้อง ร้อยละ 90.24 ของการทำนายทั้งหมด

#### 4.1.2 ผลการทดลองจากกระบวนการสร้างแบบจำลองโดย ResNet50

ในการวัดประสิทธิภาพของแบบจำลองโดย ResNet50 ในการจำแนกประเภทรูปภาพสินค้าแฟชั่น เพื่อเปรียบเทียบกับแบบจำลองอื่น ๆ ในการประเมินประสิทธิภาพของแบบจำลองบนชุดข้อมูลตรวจสอบได้ผลลัพธ์ ดังตารางที่ 4.4

ตารางที่ 4.5 ผลลัพธ์ประสิทธิภาพของการฝึกสอนแบบจำลอง ResNet50 ใน 50 รอบ

Epoch	Train accuracy	Train loss	Val accuracy	Val loss	Learning Rate
0	0.7048	0.8133	0.7568	0.6594	0.001
1	0.7621	0.6399	0.7820	0.5697	0.001
2	0.7785	0.5966	0.8074	0.5203	0.001
3	0.7841	0.5749	0.8176	0.4973	0.001
4	0.7943	0.5522	0.8170	0.4915	0.001
5	0.7973	0.5420	0.7955	0.5350	0.001
6	0.8013	0.5318	0.8189	0.4858	0.001
7	0.8057	0.5222	0.8164	0.4915	0.001
8	0.8114	0.5056	0.8173	0.4824	0.001
9	0.8141	0.5040	0.8203	0.4583	0.001
10	0.8164	0.4935	0.8249	0.4607	0.001
11	0.8167	0.4884	0.8247	0.4680	0.001
12	0.8192	0.4820	0.8348	0.4386	0.001
13	0.8223	0.4757	0.8278	0.4605	0.001
14	0.8245	0.4736	0.8223	0.4733	0.001
15	0.8249	0.4669	0.8305	0.4401	0.001
16	0.8473	0.4112	0.8433	0.4090	0.00005
17	0.8490	0.4046	0.8433	0.4104	0.00005
18	0.8507	0.3991	0.8445	0.4064	0.00005
19	0.8520	0.3943	0.8497	0.3994	0.00005
20	0.8555	0.3898	0.8493	0.3979	0.00005
21	0.8556	0.3868	0.8481	0.3979	0.00005
22	0.8561	0.3863	0.8499	0.3954	0.00005
23	0.8549	0.3854	0.8503	0.3972	0.00005
24	0.8569	0.3837	0.8503	0.3937	0.00005
25	0.8574	0.3827	0.8509	0.3956	0.00005

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่ควรเผยแพร่ให้ผู้อื่นใช้ประโยชน์ด้านการค้า

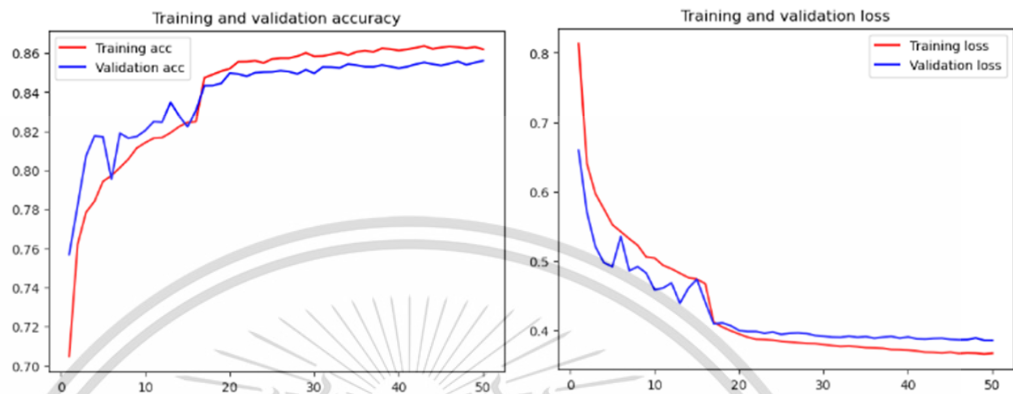
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.5 (ต่อ)

Epoch	Train accuracy	Train loss	Val accuracy	Val loss	Learning Rate
26	0.8574	0.3817	0.8505	0.3959	0.00005
27	0.8584	0.3808	0.8493	0.3950	0.00005
28	0.8600	0.3805	0.8514	0.3921	0.00005
29	0.8583	0.3791	0.8496	0.3911	0.00005
30	0.8585	0.3776	0.8528	0.3898	0.00005
31	0.8593	0.3765	0.8528	0.3895	0.00005
32	0.8602	0.3769	0.8523	0.3912	0.00005
33	0.8589	0.3760	0.8543	0.3896	0.00005
34	0.8606	0.3746	0.8538	0.3906	0.00005
35	0.8611	0.3743	0.8530	0.3883	0.00005
36	0.8605	0.3737	0.8529	0.3897	0.00005
37	0.8624	0.3719	0.8538	0.3908	0.00005
38	0.8620	0.3717	0.8531	0.3884	0.00005
39	0.8613	0.3711	0.8522	0.3900	0.00005
40	0.8619	0.3699	0.8530	0.3875	0.00005
41	0.8626	0.3682	0.8543	0.3870	0.00005
42	0.8636	0.3679	0.8552	0.3879	0.00005
43	0.8621	0.3672	0.8543	0.3882	0.00005
44	0.8628	0.3682	0.8536	0.3866	0.00005
45	0.8634	0.3664	0.8546	0.3859	0.00005
46	0.8630	0.3671	0.8557	0.3862	0.00005
47	0.8624	0.3668	0.8540	0.3886	0.00005
48	0.8631	0.3656	0.8551	0.3851	0.00005
<b>**49</b>	<b>0.8619</b>	<b>0.3667</b>	<b>0.8561</b>	<b>0.3851</b>	<b>0.00005</b>

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากตารางที่ 4.5 พบว่า รอบที่ได้ผลลัพธ์ของการฝึกสอนแบบจำลองที่ดีที่สุดคือ รอบที่ 50 ได้ค่าความแม่นยำ และค่าความสูญเสียบนชุดข้อมูลฝึกสอน คือ ร้อยละ 86 และ ร้อยละ 36 ของชุดข้อมูลฝึกสอนทั้งหมด ตามลำดับ และได้ค่าความแม่นยำ และค่าความสูญเสียบนชุดข้อมูลตรวจสอบ คือ ร้อยละ 85 และ ร้อยละ 38 ของชุดข้อมูลตรวจสอบทั้งหมด ตามลำดับ



ภาพที่ 4.3 ผลลัพธ์ประสิทธิภาพของการฝึกสอนแบบจำลอง ResNet50 ใน 50 รอบ

ภาพที่ 4.3 เปรียบเทียบค่าความแม่นยำ และค่าความสูญเสียของชุดข้อมูลฝึกสอน และชุดข้อมูลตรวจสอบ ในแต่ละรอบ แสดงให้เห็นว่า ค่าความแม่นยำมีแนวโน้มเพิ่มขึ้นเรื่อย ๆ ในแต่ละรอบการฝึกสอน และจะเริ่มคงที่เมื่อรอบที่ 20 เป็นต้นไป ทั้งชุดข้อมูลข้อมูลฝึกสอน และชุดข้อมูลตรวจสอบ ในทำนองเดียวกันกับค่าความสูญเสียที่จะลดลงเรื่อย ๆ และจะเริ่มคงที่ตั้งแต่รอบที่ 20 เป็นต้นไป ทั้งชุดข้อมูลข้อมูลฝึกสอน และชุดข้อมูลตรวจสอบ และจากกราฟค่าความสูญเสียของชุดข้อมูลตรวจสอบมีจุดต่ำสุดในรอบที่ 50

เมื่อนำแบบจำลองไปทดสอบกับชุดข้อมูลสำหรับทดสอบ ได้ผลการจำแนกรูปภาพดังนี้

828	2	17	34	1	3	196	1	3	0
1	971	1	10	1	0	2	0	0	0
18	1	765	10	76	0	84	0	8	0
37	17	11	898	33	1	29	0	4	0
3	1	93	20	790	0	66	0	1	0
0	0	0	0	0	943	0	20	10	13
102	7	103	25	95	0	612	0	10	0
1	0	1	0	0	43	0	942	0	57
10	1	9	3	4	2	11	0	961	0
0	0	0	0	0	8	0	37	3	930

ภาพที่ 4.4 Confusion Matrices การจำแนกรูปภาพสินค้าแฟชั่นด้วย ResNet50 โดยแกน y คือค่าจริง (Actual value) และแกน x คือค่าที่ทำนาย (Predicted Value)

จากภาพที่ 4.4 แสดงกราฟ Confusion Matrices การจำแนกรูปภาพสินค้าแฟชั่นด้วย ResNet50 โดยแนวตั้ง แสดงค่าจริงของประเภทสินค้า และแนวนอนคือค่าที่ทำนายได้ พบว่าแบบจำลอง ResNet50 ทำนาย Shirt ผิดมากที่สุด รองลงมาคือ Pullover และ Coat ตามลำดับ โดย Shirt ส่วนใหญ่ที่ทำนายผิดจะสลับกับ T-shirt/top และ Pullover ส่วนใหญ่ที่ทำนายผิดจะสลับกับ Coat เนื่องจากเป็นสินค้าที่มีลักษณะคล้ายคลึงกัน

ตารางที่ 4.6 ผลลัพธ์ของการทำนายหรือความแม่นยำในการจำแนกของแบบจำลองโดย ResNet50

	Precision	Recall	F1 - score	Support
T-shirt/top	0.7631	0.8280	0.7942	1000
Trouser	0.9848	0.9710	0.9778	1000
Pullover	0.7952	0.7650	0.7798	1000
Dress	0.8718	0.8980	0.8847	1000
Coat	0.8111	0.7900	0.8004	1000
Sundal	0.9564	0.9430	0.9496	1000
Shirt	0.6415	0.6120	0.6264	1000
Sneaker	0.9023	0.9420	0.9217	1000
Bag	0.9600	0.9610	0.9605	1000
Ankle boot	0.9509	0.9300	0.9403	1000

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับใช้ในการเรียนการสอนที่มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี ไม่อนุญาตให้นำไปเผยแพร่โดยไม่ได้รับอนุญาต

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.6 (ต่อ)

	Precision	Recall	F1 - score	Support
Accuracy			0.8640	10000
Macro Avg	0.8637	0.8640	0.8636	10000
Weighted Avg	0.8637	0.8640	0.8636	10000

จากตารางที่ 4.6 แสดงผลลัพธ์ของการทำนายหรือความแม่นยำในการจำแนกของแบบจำลองโดย ResNet50 โดยจะแสดง precision, recall, F1-score และ support ของแต่ละคลาสที่ถูกทำนาย พร้อมกับค่าเฉลี่ยของทั้งหมด พบว่า ค่าความเที่ยงตรงเฉลี่ยของทุกคลาส คือ ร้อยละ 86.37 ค่าความไวเฉลี่ยของทุกคลาส คือ ร้อยละ 86.40 ค่า F1-score คือ ร้อยละ 86.36 แบบจำลองนี้มีความถูกต้อง ร้อยละ 86.40 ของการทำนายทั้งหมด

#### 4.1.3 ผลการทดลองจากกระบวนการสร้างแบบจำลองโดย Inception v3

ในการประเมินประสิทธิภาพของแบบจำลอง Inception v3 ในการจำแนกประเภทรูปภาพสินค้าแฟชั่น บนชุดข้อมูลตรวจสอบได้ผลลัพธ์ ดังตารางที่ 4.6

ตารางที่ 4.7 ผลลัพธ์ประสิทธิภาพของการฝึกสอนแบบจำลอง Inception v3 ใน 12 รอบ

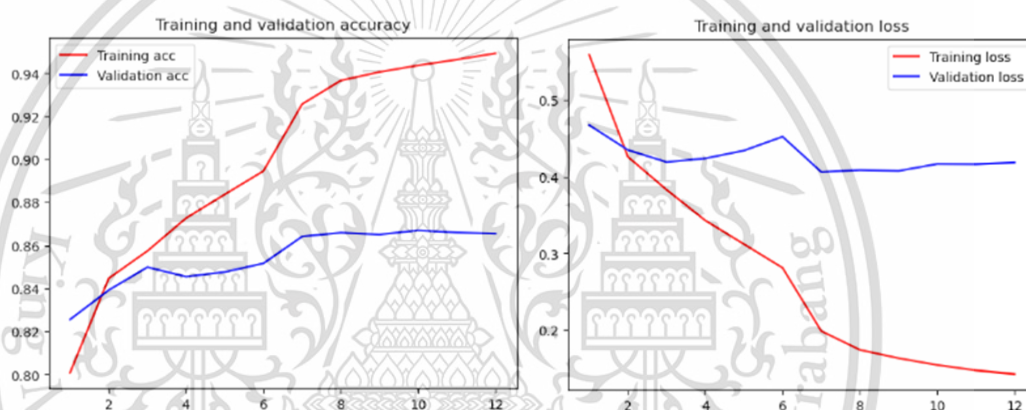
Epoch	Train accuracy	Train loss	Val accuracy	Val loss	Learning Rate
0	0.8009	0.5594	0.8256	0.4676	0.001
1	0.8447	0.4262	0.8393	0.4351	0.001
2	0.8574	0.3832	0.8499	0.4193	0.001
3	0.8727	0.3431	0.8455	0.4240	0.001
4	0.8837	0.3121	0.8477	0.4343	0.001
5	0.8946	0.2811	0.8517	0.4525	0.001
<b>**6</b>	<b>0.9257</b>	<b>0.1986</b>	<b>0.8642</b>	<b>0.4063</b>	<b>0.00005</b>
7	0.9367	0.1740	0.8659	0.4089	0.00005
8	0.9406	0.1631	0.8651	0.4078	0.00005
9	0.9437	0.1543	0.8670	0.4168	0.00005
10	0.9464	0.1473	0.8660	0.4165	0.00005

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.7 (ต่อ)

Epoch	Train accuracy	Train loss	Val accuracy	Val loss	Learning Rate
11	0.9493	0.1423	0.8655	0.4186	0.00005

จากตารางที่ 4.7 ผลลัพธ์ของการฝึกสอนแบบจำลอง Inception v3 พบว่าในรอบที่ 7 ได้ผลลัพธ์ที่ดีที่สุด โดยค่าความแม่นยำของแบบจำลอง Inception v3 บนชุดข้อมูลฝึกสอนคือ ร้อยละ 92 และบนชุดข้อมูลตรวจสอบคือ ร้อยละ 86 ของชุดข้อมูลทั้งหมด ค่าความสูญเสียของแบบจำลอง Inception v3 บนชุดข้อมูลฝึกสอนคือ ร้อยละ 19 และบนชุดข้อมูลตรวจสอบคือ ร้อยละ 40 ของชุดข้อมูลทั้งหมด



ภาพที่ 4.5 ผลลัพธ์ประสิทธิภาพของการฝึกสอนแบบจำลอง Inception v3 ใน 12 รอบ

ภาพที่ 4.5 แสดงการเปรียบเทียบค่าความแม่นยำ และค่าความสูญเสียของชุดข้อมูลฝึกสอน และชุดข้อมูลตรวจสอบ ในแต่ละรอบ แสดงให้เห็นว่า ค่าความแม่นยำมีแนวโน้มเพิ่มขึ้นเรื่อย ๆ ในแต่ละรอบการฝึกสอน และจะเริ่มคงที่เมื่อรอบที่ 8 เป็นต้นไป ทั้งชุดข้อมูลข้อมูลฝึกสอน และชุดข้อมูลตรวจสอบ ในทำนองเดียวกันกับค่าความสูญเสียที่จะลดลงเรื่อย ๆ และจะเริ่มคงที่ตั้งแต่รอบที่ 8 เป็นต้นไป ทั้งชุดข้อมูลข้อมูลฝึกสอน และชุดข้อมูลตรวจสอบ และจากกราฟค่าความสูญเสียของชุดข้อมูลตรวจสอบมีจุดต่ำสุดในรอบที่ 7

เมื่อนำแบบจำลองไปทดสอบกับชุดข้อมูลสำหรับทดสอบ ได้ผลการจำแนกรูปภาพดังนี้

821	1	18	34	1	1	140	0	3	0
1	974	4	16	1	0	3	0	1	0
18	1	812	6	49	1	69	0	4	1
45	16	9	856	30	1	49	0	1	0
1	2	77	33	832	0	78	0	4	0
1	0	0	2	0	943	1	44	6	14
105	5	76	49	84	0	653	0	6	0
0	0	0	0	0	40	0	910	3	43
7	1	4	2	3	2	7	1	965	1
1	0	0	2	0	12	0	45	7	941

ภาพที่ 4.6 Confusion Matrices การจำแนกรูปภาพสินค้าแฟชั่นด้วย Inception v3 โดยแกน y คือค่าจริง (Actual value) และแกน x คือค่าที่ทำนาย (Predicted Value)

จากภาพที่ 4.6 แสดงกราฟ Confusion Matrices การจำแนกรูปภาพสินค้าแฟชั่นด้วย Inception v3 โดยแนวตั้ง แสดงค่าจริงของประเภทสินค้า และแนวนอนคือค่าที่ทำนายได้ พบว่าแบบจำลอง Inception v3 ทำนาย Shirt ผิดมากที่สุด รองลงมาคือ Pullover และ Coat ตามลำดับ โดย Shirt ส่วนใหญ่ที่ทำนายผิดจะสลับกับ T-shirt/top และ Pullover ส่วนใหญ่ที่ทำนายผิดจะสลับกับ Coat เนื่องจากเป็นสินค้าที่มีลักษณะคล้ายคลึงกัน

ตารางที่ 4.8 ผลลัพธ์ของการทำนายหรือความแม่นยำในการจำแนกของแบบจำลองโดย Inception v3

	Precision	Recall	F1 - score	Support
T-shirt/top	0.8057	0.8210	0.8133	1000
Trouser	0.9740	0.9740	0.9740	1000
Pullover	0.8450	0.8120	0.8281	1000
Dress	0.8500	0.8560	0.8530	1000
Coat	0.8101	0.8320	0.8209	1000
Sundal	0.9327	0.9430	0.9378	1000
Shirt	0.6677	0.6530	0.6603	1000
Sneaker	0.9137	0.9100	0.9118	1000

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.8 (ต่อ)

	Precision	Recall	F1 - score	Support
Bag	0.9718	0.9650	0.9684	1000
Ankle boot	0.9335	0.9410	0.9373	1000
Accuracy			0.8707	10000
Macro Avg	0.8704	0.8707	0.8705	10000
Weighted Avg	0.8704	0.8707	0.8705	10000

จากตารางที่ 4.8 แสดงผลลัพธ์ของการทำนายหรือความแม่นยำในการจำแนกของแบบจำลองโดย Inception v3 โดยจะแสดง precision, recall, f1-score และ support ของแต่ละคลาสที่ถูกทำนาย พร้อมกับค่าเฉลี่ยของทั้งหมด พบว่า ค่าความเที่ยงตรงเฉลี่ยของทุกคลาส คือ ร้อยละ 87.04 ค่าความไวเฉลี่ยของทุกคลาส คือ ร้อยละ 87.07 ค่า F1-score คือ ร้อยละ 87.05 แบบจำลองนี้มีความถูกต้อง ร้อยละ 87.07 ของการทำนายทั้งหมด

ผู้ศึกษาได้เปรียบเทียบผลลัพธ์ของการทดสอบประสิทธิภาพของแบบจำลองทั้ง 3 โครงสร้างสำหรับการจำแนกประเภทรูปภาพสินค้าแฟชั่น ด้วยชุดข้อมูลเดียวกัน โดยเปรียบเทียบประสิทธิภาพด้วยค่าความแม่นยำ ได้ผลดังตารางที่ 4.8

ตารางที่ 4.9 เปรียบเทียบประสิทธิภาพของแบบจำลองทั้ง 3 โครงสร้าง

		ResNet50	Inception v3	VGG16
Train	Accuracy	0.8619	0.9257	0.9409
	Loss	0.3667	0.1986	0.1619
Validation	Accuracy	0.8561	0.8642	0.8951
	Loss	0.3851	0.4063	0.3044
Test	Precision	0.8637	0.8704	0.9017
	Recall	0.8640	0.8707	0.9024
	F1 - score	0.8636	0.8705	0.9019
	Accuracy	0.8640	0.8707	0.9024

จากตารางที่ 4.9 พบว่า แบบจำลองที่นำมาเปรียบเทียบทั้ง 3 โครงสร้าง แบบจำลอง VGG16 มีประสิทธิภาพดีที่สุด โดยได้ค่าความเที่ยงตรง ร้อยละ 90.17 ค่าความไวร้อยละ 90.24 ค่า F1 - score คือ ร้อยละ 90.19 และความถูกต้องถึงร้อยละ 90.24 ของชุดข้อมูลทดสอบทั้งหมด รองลงมา เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

คือ Inception v3 และ ResNet50 ที่ได้ค่าความเที่ยงตรง ร้อยละ 87.07 และถึงร้อยละ 86.40 ของชุดข้อมูลทดสอบทั้งหมด ตามลำดับ ค่า F1 - score คือร้อยละ 87.05 และถึงร้อยละ 86.36 ของชุดข้อมูลทดสอบทั้งหมด ตามลำดับ และความถูกต้องของแบบจำลองคือ ร้อยละ 87.07 และร้อยละ 86.40 ตามลำดับ

ทั้งจุดผิดพลาดของการทำนายรูปภาพทั้ง 3 โครงสร้าง ยังมีความผิดพลาดในลักษณะเดียวกัน ก็คือ ส่วนใหญ่ Shirt ทำนายผิดจะสลับกับ T-shirt/top และ Pullover ส่วนใหญ่ที่ทำนายผิดจะสลับกับ Coat ดังนั้น ผู้ศึกษาจึงเลือกแบบจำลอง VGG16 เป็นแบบจำลองที่จะใช้ในขั้นตอนถัดไป

## 4.2 ผลการทดลองจากกระบวนการให้การแนะนำ

ในขั้นตอนนี้เป็นการแนะนำสินค้าแฟชั่นที่มีลักษณะคล้ายกัน โดยใช้แบบจำลอง KNN โดยขั้นตอนก่อนนำชุดข้อมูลอธิบายลักษณะของผลิตภัณฑ์แฟชั่นเข้าแบบจำลอง KNN จะทำการทดสอบเชิงอนุมาน ด้วยการทดสอบความเป็นอิสระด้วยไคกำลังสอง โดยกำหนดให้

$H_0$  : ตัวแปร X และ Y ไม่มีความสัมพันธ์กัน

$H_1$  : ตัวแปร X และ Y มีความสัมพันธ์กัน

ได้ผลแสดงความสัมพันธ์ระหว่างตัวแปรต้น (X) กับตัวแปรตาม (Y) ดังตารางที่ 4.10

ตารางที่ 4.10 ความสัมพันธ์ระหว่างตัวแปรต้น (X) กับตัวแปรตาม (Y)

ตัวแปร X	ประเภทของเสื้อผ้า (Y)	
	$\chi^2$	p-value
เพศที่เป็นกลุ่มเป้าหมายของสินค้า	40002.8880	< 0.0001
หมวดหมู่หลักของสินค้า	102961.5455	< 0.0001
หมวดหมู่ย่อยของสินค้า	205994.2559	< 0.0001
สีของสินค้า	38385.5901	< 0.0001
ฤดูกาลเป้าหมายของสินค้า	60409.0629	< 0.0001
วิธีการใช้งานสินค้า	44722.9333	< 0.0001
แฟชั่นนี้มาจากปี	49797.6807	< 0.0001

จากตารางที่ 4.10 แสดงผลการทดสอบไคกำลังสอง ที่ระดับนัยสำคัญ เท่ากับ 0.05 และ p-value ระหว่างตัวแปร X กับตัวแปร Y (ประเภทของเสื้อผ้า) พบว่า ค่า p-value ทุกตัวแปร X มีค่า

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


น้อยกว่าระดับนัยสำคัญ ดังนั้น จึงปฏิเสธสมมติฐานหลัก สามารถสรุปได้ว่า ตัวแปร  $X$  ทั้งหมด และ  $Y$  มีความสัมพันธ์กัน

ระบบแนะนำเป็นการให้การแนะนำสินค้าแฟชั่นที่มีลักษณะคล้ายกัน โดยใช้แบบจำลอง KNN ที่มีการเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning) ผลลัพธ์จากแบบจำลองจะแสดงสินค้าแฟชั่นที่มีลักษณะคล้ายคลึงกับสินค้าแฟชั่นที่กำลังสนใจมากที่สุดจำนวน 5 สินค้า โดยการคำนวณสินค้าแฟชั่นที่คล้ายคลึงกัน คำนวณจากการวัดระยะห่างยูคลิด (Euclidean Distance) ในกระบวนการให้การแนะนำนี้ไม่ได้มีการวัดประสิทธิภาพ ซึ่งตัวอย่างผลการให้การแนะนำ ดังรูปภาพที่ 4.7 – 4.10




ภาพที่ 4.7 แสดงผลการให้การแนะนำ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




ภาพที่ 4.8 แสดงผลการให้การแนะนำ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



ภาพที่ 4.9 แสดงผลการให้การแนะนำ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



ภาพที่ 4.10 แสดงผลการให้การแนะนำ

จากผลลัพธ์การให้การแนะนำ จะเห็นว่า แบบจำลองได้ผลลัพธ์การแนะนำสินค้าที่มีลักษณะคล้ายคลึงกัน ไม่ว่าจะเป็นในด้านรูปทรง เช่น ขนาด รูปร่าง หรือโครงสร้างภายนอก มีการแนะนำสินค้าที่มีลวดลายหรือลายเส้นที่คล้ายกัน หรือแม้แต่สีที่มีเฉดใกล้เคียงกันเช่นกัน เป็นส่วนใหญ่ โดยแบบจำลองให้น้ำหนักกับลักษณะที่คล้ายคลึงกันมากกว่าประเภทของสินค้า ทำให้บางการแนะนำอาจจะมีสินค้าที่ประเภทต่างกัน แต่ลักษณะคล้ายคลึง การให้น้ำหนักกับลักษณะที่คล้ายคลึงกันมากกว่าประเภทของสินค้าอาจทำให้เกิดความหลากหลายในผลลัพธ์การแนะนำ ซึ่งอาจส่งผลให้มีสินค้าที่มีประเภทต่างกันแสดงออกมา แต่มีลักษณะที่คล้ายคลึงกันอย่างมาก เช่น การแนะนำเสื้อผ้าที่มีลายลวดลายที่คล้ายกันแม้ว่าจะเป็นประเภทของเสื้อผ้าที่แตกต่างกัน เช่น เสื้อกั๊กและกระเป๋

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## บทที่ 5

### สรุป และอภิปรายผลการศึกษา

การศึกษาค้นคว้าอิสระนี้ เพื่อพัฒนาแบบจำลองโครงข่ายประสาทแบบคอนโวลูชันสำหรับค้นหาคุณลักษณะจากรูปภาพสินค้าแฟชั่น และพัฒนาระบบแนะนำสินค้าแบบออนไลน์ เพื่อแนะนำสินค้าที่มีความคล้ายคลึงกัน ในบทนี้จะกล่าวถึงหัวข้อต่าง ๆ ดังนี้

5.1 สรุป และอภิปรายผลการศึกษา

5.2 ข้อจำกัดและการทำงานในอนาคต

#### 5.1 สรุป และอภิปรายผลการศึกษา

ในการศึกษาค้นคว้าครั้งนี้ มีวัตถุประสงค์ เพื่อพัฒนาแบบจำลองโครงข่ายประสาทแบบคอนโวลูชันสำหรับค้นหาคุณลักษณะจากรูปภาพสินค้าแฟชั่น เพื่อเปรียบเทียบประสิทธิภาพของแบบจำลองในการจำแนกกลุ่มรูปภาพสินค้าแฟชั่น โดยโครงข่ายประสาทแบบคอนโวลูชันที่แตกต่างกัน และเพื่อพัฒนาระบบแนะนำสินค้าแบบออนไลน์ โดยใช้วิธีการ K-NN (K-Nearest Neighbor) สำหรับการแนะนำสินค้าที่มีความคล้ายคลึงกัน

ผู้ศึกษาได้ทำการพัฒนาแบบจำลองโครงข่ายประสาทแบบคอนโวลูชัน โดยใช้ภาษา Python ในการดำเนินการเนื่องจากเป็นภาษาคอมพิวเตอร์ระดับสูง ด้วยเครื่องมือ Jupyter Notebook สำหรับการพัฒนาแบบจำลองโครงข่ายประสาทแบบคอนโวลูชันสำหรับค้นหาคุณลักษณะจากรูปภาพสินค้าแฟชั่น ในการศึกษาค้นคว้าอิสระนี้มีแนวคิดที่จะนำเสนอวิธีการจำแนกประเภทสินค้าแฟชั่นโดยโครงข่ายประสาทแบบคอนโวลูชัน จำนวน 3 โครงสร้าง ประกอบด้วย ResNet50, VGG16 และ Inception v3 และจะพิจารณาประสิทธิภาพของแบบจำลองด้วยค่าความแม่นยำบนชุดข้อมูลสำหรับการทดสอบ โดยการนำไปเปรียบเทียบกัน

ในการเปรียบเทียบประสิทธิภาพแบบจำลองในการจำแนกรูปภาพสินค้าแฟชั่น ทั้ง 3 โครงสร้าง โดยจะพิจารณาจากค่าความแม่นยำบนชุดข้อมูลสำหรับการทดสอบ แบบจำลองโครงสร้างใดที่ให้ค่าความแม่นยำสูงกว่าจะเป็นแบบจำลองที่มีประสิทธิภาพดีกว่า จากผลการศึกษาที่ได้พบว่า เมื่อทำการแบ่งชุดข้อมูลรูปภาพเป็น ชุดข้อมูลฝึกสอนจำนวนร้อยละ 80 ของข้อมูลทั้งหมด และชุดข้อมูลสำหรับตรวจสอบ ร้อยละ 20 ของข้อมูลทั้งหมด และข้อมูลสำหรับทดสอบอีก 10,000 รูปภาพ ผลการสร้างแบบจำลองจำแนกภาพ พบว่า แบบจำลอง VGG16 มีประสิทธิภาพดีที่สุด โดยมีค่าความเที่ยงตรงร้อยละ 90.17 ค่าความไวร้อยละ 90.24 ค่า F1-score ร้อยละ 90.19 และความถูกต้องร้อยละ 90.24 รองลงมาคือ Inception v3 และ ResNet50 โดย Inception v3 มีค่า

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปเผยแพร่บนสื่อออนไลน์  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ความเที่ยงตรงร้อยละ 87.07 ค่า F1-score ร้อยละ 87.05 และความถูกต้องร้อยละ 87.07 ส่วน ResNet50 มีค่าความเที่ยงตรงร้อยละ 86.40 ค่า F1-score ร้อยละ 86.36 และความถูกต้องร้อยละ 86.40

แม้ว่า ResNet50 และ Inception v3 จะมีโครงสร้างที่ซับซ้อนกว่า แต่ VGG16 อาจจะเหมาะสมกับลักษณะของข้อมูลสินค้าแฟชั่นที่ใช้ในการทดลอง โดยโครงสร้างที่เรียบง่าย จำนวนชั้นที่ลึกพอสมควร ไม่ซับซ้อนจนเกินไป และประสิทธิภาพของ VGG16 อาจทำให้การเรียนรู้และการทำนายมีความแม่นยำสูงกว่าในกรณีนี้

เมื่อได้แบบจำลองที่ดีที่สุดในการทดลอง จากนั้นจะทำการตัดชั้นสุดท้ายของแบบจำลอง เนื่องจากในขั้นตอนการพัฒนาแบบจำลองนี้ต้องการที่จะค้นหาคุณลักษณะจากรูปภาพสินค้าแฟชั่น ไม่ใช่การจำแนกรูปภาพ สำหรับการพัฒนาระบบแนะนำสินค้าแบบออนไลน์ ในกระบวนการนี้จะนำชุดข้อมูลรูปภาพเข้าแบบจำลองโครงข่ายประสาทแบบคอนโวลูชัน เพื่อให้ได้คุณลักษณะจากรูปภาพสินค้าแฟชั่น แล้วจึงนำคุณลักษณะจากรูปภาพสินค้าแฟชั่นที่ได้มาไปรวมกับข้อมูลอธิบายของสินค้านั้น ๆ ไปเข้าแบบจำลอง KNN เพื่อให้ได้ผลลัพธ์ของรูปภาพที่มีลักษณะคล้ายคลึงกันออกมา

การให้การแนะนำสินค้าผ่านแบบจำลองมักจะเป็นกระบวนการที่ซับซ้อนที่ต้องพิจารณาหลายปัจจัย เพื่อให้ผลลัพธ์ที่แม่นยำและเหมาะสมกับความต้องการและความสนใจของผู้ใช้งาน ความคล้ายคลึงกันของสินค้าที่แนะนำมีความสำคัญในการสร้างประสบการณ์การชื้อขายที่ดีและเป็นที่ยอมรับของผู้ใช้งาน เนื่องจากสิ่งเหล่านี้มักเป็นปัจจัยที่มีอิทธิพลต่อการตัดสินใจของผู้บริโภค โดยเฉพาะในสถานการณ์ที่มีการเปรียบเทียบหลายตัวเลือก เช่น การซื้อสินค้าออนไลน์ การแสดงผลของแบบจำลองที่สนับสนุนความคล้ายคลึงกันนี้สามารถช่วยลดความสับสน และเพิ่มความพอใจให้กับผู้ใช้งานได้ เนื่องจากผู้ใช้งานสามารถเห็นความคล้ายคลึงกันของสินค้าแต่ละชิ้นได้ชัดเจนและเลือกสินค้าที่ตรงกับความต้องการและความสนใจของตนเองได้ง่ายขึ้น และยังช่วยแก้ปัญหาสำหรับลูกค้าใหม่ เนื่องจากระบบการแนะนำสินค้าที่นำเสนอไม่จำเป็นต้องใช้ข้อมูลของลูกค้าเพื่อมาให้การแนะนำ

## 5.2 ข้อจำกัดและการทำงานในอนาคต

5.2.1 ระบบแนะนำสินค้าที่รูปร่าง ลวดลายคล้าย ๆ กัน แต่เป็นสินค้าต่างประเภทกัน ควรเพิ่มค่าถ่วงน้ำหนักกับข้อมูลคุณลักษณะที่อธิบายสินค้ามากกว่าคุณลักษณะที่ได้จากแบบจำลอง

5.2.2 เพิ่มเทคนิค Object Detection ในการหาวัตถุของรูปภาพ เพื่อป้องกัน กรณีที่รูปภาพไม่ได้มีแค่สินค้า เช่น นางแบบ/นายแบบ สวมสินค้าอยู่ ซึ่งอาจจะส่งผลต่อประสิทธิภาพการหาคุณลักษณะของรูปภาพ

## เอกสารอ้างอิง

- M E A W. (2023). **Recommendation System — Part 1 : Introduction**. Retrieved March 5, 2024, from <https://muzikiii.medium.com/recommendation-system-part-1-introduction-ba049558902>
- D.N.V.S.L.S. Indira, Babu, R. M., Kavitha, C., & Rathna, J. C. (2022). **Visual and buying sequence features-based product image recommendation using optimization based deep residual network**. Retrieved November 5, 2024, from [https://www.researchgate.net/publication/361870502\\_Visual\\_and\\_buying\\_sequence\\_features-based\\_product\\_image\\_recommendation\\_using\\_optimization\\_based\\_deep\\_residual\\_network](https://www.researchgate.net/publication/361870502_Visual_and_buying_sequence_features-based_product_image_recommendation_using_optimization_based_deep_residual_network)
- Fabio R. L., Eduardo L., Jose M. & Gustavo P. (2022). **Classify four imagined objects with EEG signals**. Retrieved November 5, 2024, from [https://www.researchgate.net/figure/Schematic-diagram-of-the-convolutional-layer-A-33documentclass12ptminimal\\_fig5\\_349897231](https://www.researchgate.net/figure/Schematic-diagram-of-the-convolutional-layer-A-33documentclass12ptminimal_fig5_349897231).
- Pegah, M. A., Nima, J. N., Mehdi, H., Ali, A. S., & Aso D. (2022). Image-based Product Recommendation Method for E-commerce Applications Using Convolutional Neural Networks. *Acta Informatica Pragensia* (Volume 11, Issue 1, pp. 15–35). Prague University of Economics and Business.
- Shereen, E., Lukas, B., & Lars, S. T. (2022). **End-to-End Image-Based Fashion Recommendation**. (Research Report). Information Systems and Machine Learning Lab. University of Hildesheim.
- Akshit, T., Vidhi, S., & Ankit, K. (2021). **Deep Learning Based Product Recommendation System and its Applications**. International Research Journal of Engineering and Technology (IRJET). K J Somaiya College of Engineering

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Anupama, A., Satya, K. G., Venubabu, R., Yasoda, K., & P Dileep. (2021). Image-based Content Recommendation System with CNN. **Fifth International Pisit B. Conference on I-SMAC**. ISBN 978-1-6654-2642-8.

Shivganga, G., Jayesh, P., Harshal, K., Prajwal, T.,& Sushovan, M. (2020). Recommendation System Using KNN and Cosine similarity. **International Journal of Creative Research Thoughts (IJCRT)**. (1256-1260).

Harikrishnan N B. (2019). Confusion Matrix, Accuracy, Precision, Recall, F1 Score. Retrieved March 5, 2024, from <https://medium.com/analytics-vidhya/confusion-matrix-accuracy-precision-recall-f1-score-ade299cf63cd>

Mr.P L. (2562). **Deep Learning แบบฉบับสามัญชน EP 2 Optimization & Activation Function** เรียนกันสบายๆสไตล์ชิลๆ. สืบค้นวันที่ 20 กุมภาพันธ์ 2567, จาก <https://medium.com/>

Param, A., (2019). **Fashion Product Images Dataset**. Retrieved September 10, 2024, from <https://machinelearningmastery.com/transfer-learning-for-deep-learning/>

Pisit B. (2019). **The concept of Dropout in the deep neural net Vs Implementation**. สืบค้นวันที่ 20 กุมภาพันธ์ 2567, จาก <https://medium.com/boobeejung/the-concept-of-dropout-in-the-deep-neural-net-vs-implementation-67a7d46a0f75>

จักรินทร์ สนุกแสน และโฮฬาริก สุรินตะ. (2561). **โครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึก สำหรับจำแนกพรรณไม้ที่อยู่ในสิ่งแวดล้อมทางธรรมชาติ**. จาก [http://www.journal.msu.ac.th/upload/articles/article2449\\_80536.pdf](http://www.journal.msu.ac.th/upload/articles/article2449_80536.pdf)

Anh V. (2018). **Deep Learning – Computer Vision and Convolutional Neural Networks**. Retrieved March 1, 2024, from <https://anhvnn.wordpress.com/2018/02/01/deep-learning-computer-vision-and-convolutional-neural-networks/>

Mr.P L. (2018). **K-NN กับ Sklearn : Machine Learning 101** from <https://medium.com/mmp-li/k-nn->

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์ไว้สำหรับใช้เพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

%E0%B8%81%E0%B8%B1%E0%B8%9A-sklearn-machine-learning-101-81350e8402f0

Muneeb H. (2018). **VGG16 – Convolutional Network for Classification and Detection.** Retrieved February 20, 2024, from <https://neurohive.io/en/popular-networks/vgg16/>

Pulkit S. (2018). **A Comprehensive Tutorial to learn Convolutional Neural Networks from Scratch (deeplearning.ai Course #4).** Retrieved February 20, 2024, from <https://www.analyticsvidhya.com/blog/2018/12/guide-convolutional-neural-network-cnn/>

Sik-Ho Tsang. (2018). **Review: Inception-v3 — 1st Runner Up (Image Classification) in ILSVRC 2015.** Retrieved March 1, 2024, from <https://sh-tsang.medium.com/review-inception-v3-1st-runner-up-image-classification-in-ilsvrc-2015-17915421f77c>

Jason, B. (2017). **A Gentle Introduction to Transfer Learning for Deep Learning.** Retrieved February 21, 2024, from <https://machinelearningmastery.com/transfer-learning-for-deep-learning/>

Kaiming He, Xiangyu Z., Shaoqing Ren, & Jian Sun. (2015). **Deep Residual Learning for Image Recognition.** Retrieved March 1, 2024, from <https://arxiv.org/pdf/1512.03385.pdf>

Christian, S., Vincent, V., Sergey, I., Jonathon, S., & Zbigniew, W. (2015). **Rethinking the Inception Architecture for Computer Vision.** Retrieved March 1, 2024, from <https://arxiv.org/pdf/1512.00567.pdf>

Karen, S., & Andrew, Z. (2015). **Very Deep Convolutional Networks for Large Scale Image Recognition.** Retrieved March 1, 2024, from <https://arxiv.org/pdf/1409.1556.pdf>

ฐณัฐ วงศ์สายเชื้อ. (2558). **การทดสอบโคสแควร์.** สืบค้นวันที่ 20 พฤษภาคม 2567, จาก <https://www.youtube.com/watch?v=qnyOneEYo7c>

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์สำหรับการใช้งานเพื่อการศึกษาเท่านั้น เมื่ออนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Lecun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278- 2324.

Aakash, K. (n.d.). **Understanding ResNet50 architecture**. Retrieved March 1, 2024, from <https://iq.opengenus.org/resnet50-architecture/>



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## ประวัติผู้เขียน

ชื่อ	นางสาวปิยะวรรณ โนมะวงศ์
วัน เดือน ปีเกิด	11 ตุลาคม 2541
ประวัติการศึกษา	(2564) วิทยาศาสตรบัณฑิต สาขาสถิติ เกรดเฉลี่ย 3.37 (มหาวิทยาลัยเชียงใหม่)
ประสบการณ์การทำงาน	2 ปี 10 เดือน
ตำแหน่งหน้าที่การงานปัจจุบัน	วิศวกรข้อมูล



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้