

เทคนิคการเรียนรู้เชิงลึกสำหรับการรู้จำภาพวัตถุกระดาษถือแบรนด์เนมปลอม



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชาวิศวกรรมคอมพิวเตอร์ ภาควิชาวิศวกรรมคอมพิวเตอร์

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

ปีการศึกษา 2565

ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

Deep Learning Techniques for Image Recognition of Counterfeit  
Brand-name Handbag Materials



A Thesis Submitted in Partial Fulfillment of the Requirements  
for the Degree of Master of Engineering in Computer Engineering

Department of Computer Engineering

FACULTY OF ENGINEERING

Chulalongkorn University

Academic Year 2022

Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์	เทคนิคการเรียนรู้เชิงลึกสำหรับการรู้จำภาพวัตถุระยะใกล้
	แบรนด์เนมปลอม
โดย	นายพศสร อภิวินทวงศ์
สาขาวิชา	วิศวกรรมคอมพิวเตอร์
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก	รองศาสตราจารย์ ดร.ญาใจ ลิมปิยะกรณ์

---

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้หัวข้อวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่ง  
ของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

.....	คณบดีคณะวิศวกรรมศาสตร์
(ศาสตราจารย์ ดร.สุพจน์ เตชวรสินสกุล)	
คณะกรรมการสอบวิทยานิพนธ์	
.....	ประธานกรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.สุกรี สินธุภิญโญ)	
.....	อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก
(รองศาสตราจารย์ ดร.ญาใจ ลิมปิยะกรณ์)	
.....	กรรมการ
(อาจารย์ ดร.ภาสกร อภิรักษ์วรพินิต)	

CHULALONGKORN UNIVERSITY

พศสรล อภิวินท์วงศ์ : เทคนิคการเรียนรู้เชิงลึกสำหรับการรู้จำภาพวัสดุกระเป๋าถือแบบ  
 แบรนด์เนมปลอม. ( Deep Learning Techniques for Image Recognition of  
 Counterfeit Brand-name Handbag Materials) อ.ที่ปรึกษาหลัก : รศ. ดร.ญาใจ  
 ลิมปิยะภรณ์

การปลอมแปลงสินค้าด้านแฟชั่นเป็นปัญหาที่เกิดขึ้นอย่างต่อเนื่องโดยเฉพาะกับกระเป๋า  
 แบรินด์หรู เนื่องจากมีความยากลำบากต่อการตรวจสอบความแท้จริง โดยเฉพาะอย่างยิ่งกับการ  
 ตรวจสอบสินค้ามือสองที่เคยผ่านการใช้งานมาแล้ว ซึ่งทำให้เกิดปัญหาการตรวจสอบกระเป๋าของ  
 แท้และของปลอมทั้งในผู้ซื้อและผู้ขายโดยเฉพาะในช่วงลือคตาวนระหว่างเหตุการณ์โรคระบาด  
 Covid-19 ที่จำกัดการเดินทาง งานวิจัยนี้เสนอการประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึกโครงข่าย  
 ประสาทคอนโวลูชัน เพื่อจำแนกภาพในระดับพิกเซล ร่วมกับการนำการสกัดคุณลักษณะสำคัญ  
 พื้นผิวแบบ LBP มาพัฒนาการเรียนรู้ของแบบจำลอง โดยใช้แบบจำลองวิธีจี 16 และ เดนซ์เน็ต  
 121 โดยใช้ stratified 5-Fold cross validation เพื่อประเมินแบบจำลอง ซึ่งการเปรียบเทียบผล  
 การทดลองของการใช้แบบจำลองพื้นฐาน และการใช้แบบจำลองพื้นฐานร่วมกับการสกัด  
 คุณลักษณะสำคัญแบบ LBP ทั้งนี้แบบจำลอง โครงข่ายประสาทแบบเดนซ์เน็ต121 ร่วมกับการสกัด  
 คุณลักษณะสำคัญแบบ LBP ให้ค่าความแม่นยำสูงสุดที่ 95% จากการจำแนกภาพกระเป๋าของแท้  
 ของปลอม และวัสดุอื่น เป็นการจำแนกรูปภาพแบบหลายประเภท และเมื่อนำการสกัดคุณลักษณะ  
 แบบ LBP ร่วมกับแบบจำลองทำให้ค่าความแม่นยำการทำนายผลลัพธ์ที่สูงขึ้น

จุฬาลงกรณ์มหาวิทยาลัย  
 CHULALONGKORN UNIVERSITY

สาขาวิชา วิศวกรรมคอมพิวเตอร์  
 ปีการศึกษา 2565

ลายมือชื่อนิสิต .....  
 ลายมือชื่อ อ.ที่ปรึกษาหลัก .....

# # 6272057021 : MAJOR COMPUTER ENGINEERING

KEYWORD: Image classification, Deep learning, Counterfeit Luxury handbags,  
Local Binary Pattern

Possarun Apipawinwongsa : Deep Learning Techniques for Image  
Recognition of Counterfeit Brand-name Handbag Materials. Advisor: Assoc.  
Prof. Yachai Limpiyakorn, Ph.D.

Counterfeit of fashion goods is an ongoing problem. Especially, luxury handbags are difficult for authenticity detection, and it is even harder for the cases of secondhand used items. Such limitation of detection causes trouble for both traders and customers to prove authenticity. And it is particularly troublesome due to limitation in traveling during the crisis period of Covid-19 pandemic. This research thus studies and presents implementation of deep learning comprising of Convolutional Neural Networks (CNN) to classify images into pixels, together with texture feature extraction by Local Binary Pattern (LBP). The process is to study models by using pretrained VGG16 and DenseNet121 with stratified 5-Fold cross validation for evaluate model, by comparison between base models without LBP and base models with LBP. The models DenseNet121 with LBP resulted with 95% accuracy from classification of handbags for genuineness, counterfeit, and irrelevant materials, which is multiclassification. Moreover, implementation of LBP with the models resulted with more accuracy.

Field of Study: Computer Engineering

Student's Signature .....

Academic Year: 2022

Advisor's Signature .....

## กิตติกรรมประกาศ

วิทยานิพนธ์เล่มนี้สำเร็จสมบูรณ์ได้ด้วยเพราะได้รับความกรุณาอย่างดียิ่งจาก รองศาสตราจารย์ ดร.ญาใจ ลิ้มปิยะกรณ์ อาจารย์ที่ปรึกษาวิทยานิพนธ์ที่ให้ความรู้ ให้คำแนะนำ คอยผลักดัน และตรวจแก้ไขข้อบกพร่องมาโดยตลอด ผู้วิจัยขอกราบขอบพระคุณด้วยความเคารพอย่างสูงไว้ ณ ที่นี้

ขอขอบพระคุณ ผู้ช่วยศาสตราจารย์ดร.สุกรี สินธุภิญโญ ประธานกรรมการสอบวิทยานิพนธ์ และ อาจารย์ดร.ภาสกร อภิรักษ์วรพิณิต กรรมการสอบวิทยานิพนธ์ที่กรุณาเสียสละเวลาอันมีค่า ในการตรวจสอบและให้คำแนะนำที่เป็นประโยชน์ในการทำวิทยานิพนธ์ในครั้งนี้

ขอขอบคุณสมาคมแบรนต์เนมมีอสองแห่งประเทศไทย ที่ให้เก็บชุดข้อมูลที่สำคัญในการวิจัยครั้งนี้

ท้ายนี้ขอขอบพระคุณบิดามารดา ครอบครัว และขอขอบคุณเพื่อนๆ พี่ๆ น้องๆ ที่สนับสนุน และให้กำลังใจมาตั้งแต่เริ่มต้น คอยให้คำแนะนำ ความช่วยเหลือ ซึ่งทำให้วิทยานิพนธ์สำเร็จลุล่วงไปได้ ด้วยดีผู้วิจัยหวังเป็นอย่างยิ่งว่าวิทยานิพนธ์ฉบับนี้จะเป็นประโยชน์ต่อผู้ที่สนใจต่อไปในภายภาคหน้า

พศสรัล อภิปวินทวงศา

จุฬาลงกรณ์มหาวิทยาลัย  
CHULALONGKORN UNIVERSITY

## สารบัญ

	หน้า
.....	ค
บทคัดย่อภาษาไทย.....	ค
.....	ง
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ฉ
สารบัญตาราง.....	ญ
สารบัญรูปภาพ.....	ฎ
บทที่ 1 บทนำ .....	1
1.1 ที่มาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์.....	2
1.3 ขอบเขตการดำเนินงาน.....	2
1.4 ขั้นตอนการดำเนินงาน.....	3
1.5 ประโยชน์ที่คาดว่าจะได้รับ.....	3
1.6 ลำดับการจัดเรียงวิทยานิพนธ์.....	3
1.7 ผลงานที่ได้รับการตีพิมพ์.....	4
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง .....	5
2.1 ทฤษฎีที่เกี่ยวข้อง .....	5
2.1.1 แบบจำลองของสี (Color Model).....	5
2.1.2 ภาพระดับสีเทา (Grayscale Image) .....	6
2.1.3 ภาพไบนารี (Binary Image) .....	7

2.1.4	โลคอลไบนารีแพทเทิร์น (Local Binary Pattern) .....	8
2.1.5	โครงข่ายประสาทคอนโวลูชัน หรือ ซีเอ็นเอ็น (Convolutional Neural Network– CNN) .....	9
2.1.6	การเรียนรู้ถ่ายโอน (Transfer Learning).....	10
2.1.2.1	วีจีเน็ต (VGGNet) .....	10
2.1.2.2	เดนส์เน็ต (DenseNet).....	11
2.2	งานวิจัยที่เกี่ยวข้อง.....	11
บทที่ 3	แนวคิดและวิธีการวิจัย .....	16
3.1	ศึกษาวิธีการตรวจสอบกระเป๋าของแท้และของปลอมกับสมาคมแบรนด์เนมมือสองแห่ง ประเทศไทย.....	16
3.2	การเตรียมชุดข้อมูล.....	19
3.2.1	การเตรียมชุดข้อมูลกระเป๋าของแท้ และของปลอม.....	19
3.2.2	การเตรียมชุดข้อมูลวัสดุอื่น.....	20
3.2.3	เพิ่มชุดข้อมูลภาพ (Data Augmentation).....	22
3.2.4	การแบ่งชุดข้อมูลภาพ.....	25
3.3	การดึงคุณลักษณะสำคัญของภาพ .....	26
3.4	การออกแบบแบบจำลองในการจำแนกกระเป๋าของแท้ ของปลอม และวัสดุอื่น .....	27
3.5	กระบวนการจำแนกกระเป๋าของแท้ ของปลอม และวัสดุอื่น ของแบบจำลอง.....	29
3.5.1	กระบวนการของแบบจำลองพื้นฐาน (Base Model).....	29
3.5.2	กระบวนการของแบบจำลองพื้นฐานร่วมกับการสกัดคุณลักษณะท้องถิ่นแบบ LBP....	30
3.6	การประเมินสมรรถนะแบบจำลอง .....	30
บทที่ 4	การทดลองและผลการทดลอง .....	36
4.1	สภาพแวดล้อมที่ใช้ในการทดลอง .....	36
4.2	การเตรียมชุดข้อมูลที่ใช้ในการทดลอง .....	36



4.3 การดึงคุณลักษณะสำคัญของภาพ.....	41
4.4 การสร้างแบบจำลอง.....	42
4.4.1 โครงข่ายประสาทคอนโวลูชัน (Convolutional Neural Network–CNN).....	42
4.4.2 โครงข่ายประสาทคอนโวลูชันแบบวีจีจี 16 (VGG-16).....	44
4.4.3 โครงข่ายประสาทแบบ DenseNet 121.....	47
4.5 การฝึกสอนแบบจำลอง.....	48
4.6 ผลการทดลอง.....	49
4.6.1 ผลการทดลองของแบบจำลองโครงข่ายประสาทคอนโวลูชัน .....	49
4.6.2 ผลการทดลองของแบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวีจีจี 16.....	50
4.6.3 ผลการทดลองของแบบจำลองโครงข่ายประสาทแบบเดนซ์เน็ต121 .....	52
4.6.4 เปรียบเทียบผลการทดลองของแบบจำลองพื้นฐาน.....	53
4.6.5 เปรียบเทียบผลการทดลองของแบบจำลองพื้นฐานโดยใช้ Stratified 5-Fold Cross Validation .....	53
4.6.6 เปรียบเทียบผลการทดลองของแบบจำลองพื้นฐานร่วมกับการสกัดคุณลักษณะแบบ LBP โดยใช้ Stratified 5-Fold Cross Validation.....	61
4.6.7 ผลการทดลองของแบบจำลองพื้นฐาน และแบบจำลองพื้นฐานร่วมกับการสกัดคุณลักษณะแบบ LBP โดยใช้ Stratified 5-Fold Cross Validation.....	62
4.6.8 การทดลองเปรียบเทียบด้วยข้อมูลเชิงสถิติ .....	65
บทที่ 5 สรุปผลการวิจัย.....	72
บรรณานุกรม.....	74
ภาคผนวก.....	77
ภาคผนวก ก .....	78
ภาคผนวก ข .....	79
ภาคผนวก ค .....	89
ประวัติผู้เขียน.....	92



จุฬาลงกรณ์มหาวิทยาลัย  
**CHULALONGKORN UNIVERSITY**

## สารบัญตาราง

	หน้า
ตารางที่ 1 วิธีการตรวจสอบกระเป๋าของแท้และของปลอม.....	16
ตารางที่ 2 สรุปจำนวนข้อมูลฝึกสอน ข้อมูลตรวจสอบ ข้อมูลทดสอบของกระเป๋า Gucci GG Canvas ของแท้ ของปลอม และวัสดุอื่น .....	25
ตารางที่ 3 Confusion Matrix แบบ Binary สำหรับกระเป๋า Gucci GG Canvas ของแท้และของปลอม .....	32
ตารางที่ 4 Confusion Matrix แบบ Multi Class สำหรับกระเป๋า Gucci GG Canvas ของปลอม	33
ตารางที่ 5 Confusion Matrix แบบ Multi Class สำหรับกระเป๋า Gucci GG Canvas ของแท้.....	33
ตารางที่ 6 Confusion Matrix แบบ Multi Class สำหรับกระเป๋า Gucci วัสดุอื่น .....	34
ตารางที่ 7 สมรรถนะของการทดสอบแบบจำลอง CNN, VGG16 และ DenseNet121.....	53
ตารางที่ 8 สมรรถนะของการทดสอบแบบจำลอง CNN โดยใช้ Stratified 5-Fold Cross Validation .....	57
ตารางที่ 9 สมรรถนะของการทดสอบแบบจำลอง VGG16 โดยใช้ Stratified 5-Fold Cross Validation .....	58
ตารางที่ 10 สมรรถนะของการทดสอบแบบจำลอง DenseNet121 โดยใช้ Stratified 5-Fold Cross Validation .....	59
ตารางที่ 11 เปรียบเทียบสมรรถนะของการทดสอบแบบจำลองทั้ง 3 แบบโดยใช้ Stratified 5-Fold Cross Validation กับค่าความแม่นยำโดยการแบ่งข้อมูลแบบสุ่ม .....	60
ตารางที่ 12 สมรรถนะของการทดสอบแบบจำลองพื้นฐานร่วมกับการสกัดคุณลักษณะแบบ LBP โดยใช้ Stratified 5-Fold Cross Validation .....	61
ตารางที่ 13 ผลลัพธ์รูปแบบ Confusion Matrix ของแบบจำลองโครงข่ายประสาทคอนโวลูชัน.....	62
ตารางที่ 14 ผลลัพธ์รูปแบบ Confusion Matrix ของแบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวีจีจี	16
จีจี	62

ตารางที่ 15 ผลลัพธ์รูปแบบ Confusion Matrix ของแบบจำลองโครงข่ายประสาทแบบเดนซ์เน็ต121  
 ..... 63

ตารางที่ 16 ผลลัพธ์รูปแบบ Confusion Matrix ของแบบจำลองโครงข่ายประสาทคอนโวลูชัน  
 ร่วมกับการสกัดคุณลักษณะแบบ LBP ..... 63

ตารางที่ 17 ผลลัพธ์รูปแบบ Confusion Matrix ของแบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวี  
 จีจี 16 ร่วมกับการสกัดคุณลักษณะแบบ LBP..... 64

ตารางที่ 18 ผลลัพธ์รูปแบบ Confusion Matrix ของแบบจำลองโครงข่ายประสาทแบบเดนซ์เน็ต121  
 ร่วมกับการสกัดคุณลักษณะแบบ LBP ..... 64

ตารางที่ 19 เปรียบเทียบสมรรถนะของการทดสอบแบบจำลองพื้นฐานกับแบบจำลองพื้นฐานร่วมกับการ  
 การสกัดคุณลักษณะแบบ LBP ทั้ง 3 แบบ โดยใช้ Stratified 5-Fold Cross Validation..... 65

ตารางที่ 20 เปรียบเทียบผลการทดสอบที่ระหว่างแบบจำลองพื้นฐานกับแบบจำลองพื้นฐานร่วมกับการ  
 การสกัดคุณลักษณะแบบ LBP ..... 70



## สารบัญรูปภาพ

	หน้า
รูปที่ 1 ปริภูมิสีแบบอาร์จีบี .....	5
รูปที่ 2 สีอาร์จีบี .....	6
รูปที่ 3 ระดับความเข้มสีเทา.....	7
รูปที่ 4 เปรียบเทียบระหว่างภาพระดับสีเทา (ซ้าย) กับภาพไบนารี (ขวา).....	7
รูปที่ 5 ตัวอย่างภาพหลังจากการคำนวณด้วยเทคนิค Local Binary Pattern [5].....	8
รูปที่ 6 โครงสร้างโครงข่ายประสาทคอนโวลูชัน [7].....	9
รูปที่ 7 แบบจำลองการเรียนรู้ถ่ายโอน [8].....	10
รูปที่ 8 โครงสร้างโครงข่ายประสาทคอนโวลูชันแบบ VGG-16 [10].....	11
รูปที่ 9 โครงสร้างโครงข่ายประสาทแบบ Dense Block in DenseNet.....	11
รูปที่ 10 ตัวอย่างรูปภาพผลลากสีดำ ของแท้(ซ้าย) ของปลอม(ขวา) .....	12
รูปที่ 11 ตัวอย่างรูปภาพ Use-case Scenario แบบหลายขั้นตอน [14].....	13
รูปที่ 12 โครงสร้างการเรียนรู้เชิงลึกแบบสองขั้นตอน [20].....	15
รูปที่ 13 ตัวอย่างวัสดุกระเป๋าของ Gucci.....	18
รูปที่ 14 ตัวอย่างภาพกระเป๋าวัสดุออริจินัลจีจีแคนवास .....	18
รูปที่ 15 ตัวอย่างภาพกระเป๋าวัสดุจีจีซูพรีมแคนवास .....	18
รูปที่ 16 ตัวอย่างกระเป๋า Gucci GG Canvas จากสมาคมแบรนด์เนมมือสองแห่งประเทศไทย.....	19
รูปที่ 17 ตัวอย่างภาพถ่ายกระเป๋า Gucci GG Canvas ก) ด้านหน้า ข) ด้านหลัง ค) ด้านข้างซ้าย ง) ด้านข้างขวา จ) ด้านล่าง.....	20
รูปที่ 18 ตัวอย่างการตัดส่วนภาพเฉพาะส่วนพื้นผิววัสดุ GG Canvas.....	20
รูปที่ 19 ตัวอย่างกระเป๋า Gucci วัสดุอื่นจากสมาคมแบรนด์เนมมือสองแห่งประเทศไทยและเว็บไซต์ทางการของ Gucci.....	21
รูปที่ 20 ตัวอย่างการตัดส่วนภาพเฉพาะส่วนวัสดุอื่น.....	21

รูปที่ 21 ตัวอย่างการเพิ่มจำนวนข้อมูลภาพโดยใช้ Adobe Photoshop Slice Tool.....	23
รูปที่ 22 ตัวอย่างการปรับขนาดภาพนำเข้าเป็นขนาด 224 x 224 x 3 พิกเซล.....	24
รูปที่ 23 ตัวอย่างการพลิกภาพแนวนอนร่วมกับแนวตั้ง .....	24
รูปที่ 24 ตัวอย่างการหมุนภาพด้านซ้าย 90 องศา.....	24
รูปที่ 25 ตัวอย่างการหมุนภาพด้านขวา 90 องศา .....	25
รูปที่ 26 ตัวอย่างภาพการดึงคุณลักษณะแบบ LBP ของพื้นผิวออร์จินัลจีจีแคนวาส (บนของแท้) (ล่างของปลอม) .....	26
รูปที่ 27 ตัวอย่างภาพการดึงคุณลักษณะแบบ LBP ของพื้นผิวจีจีซูพรีมแคนวาส (บนของแท้) (ล่างของปลอม) .....	26
รูปที่ 28 ตัวอย่างภาพการดึงคุณลักษณะแบบ LBP ของพื้นผิววัสดุอื่น .....	27
รูปที่ 29 โครงสร้างแบบจำลองโครงข่ายประสาทคอนโวลูชันร่วมกับการเรียนรู้การถ่ายโอน .....	28
รูปที่ 30 กระบวนการของแบบจำลองพื้นฐาน (Base model).....	29
รูปที่ 31 กระบวนการของแบบจำลองพื้นฐานร่วมกับการสกัดคุณลักษณะท้องถิ่นแบบ LBP .....	30
รูปที่ 32 การแบ่งข้อมูลแบบ K-Fold Cross Validation (K=5).....	35
รูปที่ 33 การแบ่งข้อมูลแบบ Stratified K-Fold Cross Validation (K=5) .....	35
รูปที่ 34 โครงสร้างโพลีเตอร์ชุดข้อมูลที่ใช้ในการจำแนกกระเป๋า Gucci GG Canvas ของแท้ ของปลอม และวัสดุอื่น .....	37
รูปที่ 35 ตัวอย่างภาพกระเป๋าแท้ Gucci GG Canvas ในชุดข้อมูลฝึกสอนบน Google Drive .....	37
รูปที่ 36 ตัวอย่างภาพกระเป๋าปลอม Gucci GG Canvas ในชุดข้อมูลฝึกสอนบน Google Drive ...	38
รูปที่ 37 ตัวอย่างภาพกระเป๋า Gucci วัสดุอื่นในชุดข้อมูลฝึกสอนบน Google Drive .....	38
รูปที่ 38 ชุดคำสั่งในการเชื่อมต่อชุดข้อมูลจาก Google Drive กับ Google Colab.....	39
รูปที่ 39 ชุดคำสั่งการกำหนดไคเรทอรีของชุดข้อมูลฝึกสอน ข้อมูลตรวจสอบ และข้อมูลทดสอบ..	39
รูปที่ 40 ชุดคำสั่งการพลิกภาพแนวนอนร่วมกับแนวตั้งของชุดข้อมูลฝึกสอน.....	40
รูปที่ 41 ชุดคำสั่งการหมุนภาพของชุดข้อมูลฝึกสอน .....	40
รูปที่ 42 ชุดคำสั่งการเพิ่มจำนวนข้อมูลสำหรับชุดข้อมูลที่ใช้ในการทดลอง .....	41

รูปที่ 43 ชุดคำสั่งการดึงคุณลักษณะสำคัญด้วยเทคนิค Local Binary Pattern .....	41
รูปที่ 44 ชุดคำสั่งการรวมคุณลักษณะภาพ .....	42
รูปที่ 45 ชุดคำสั่งการสร้างของแบบจำลองโครงข่ายประสาทคอนโวลูชัน .....	43
รูปที่ 46 โครงสร้างของแบบจำลองโครงข่ายประสาทคอนโวลูชัน .....	44
รูปที่ 47 ชุดคำสั่งการสร้างของแบบจำลองการเรียนรู้แบบถ่ายโอนแบบวิธีจีจี 16.....	45
รูปที่ 48 โครงสร้างแบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวิธีจีจี 16.....	46
รูปที่ 49 ชุดคำสั่งการสร้างของแบบจำลองการเรียนรู้แบบถ่ายโอนแบบเดนซ์เน็ต121.....	47
รูปที่ 50 โครงสร้างแบบจำลองโครงข่ายประสาทแบบเดนซ์เน็ต121.....	48
รูปที่ 51 ชุดคำสั่งการบันทึกค่าน้ำหนักที่ให้ค่าความแม่นยำสูงสุดของแบบจำลองในไฟล์นามสกุล.h5 .....	48
รูปที่ 52 ชุดคำสั่งการฝึกสอนแบบจำลองด้วยโครงข่ายประสาทคอนโวลูชัน .....	49
รูปที่ 53 ชุดคำสั่งการวัดผลแบบ macro average.....	49
รูปที่ 54 ผลลัพธ์การทดสอบแบบจำลองโครงข่ายประสาทคอนโวลูชันที่ Learning Rate เท่ากับ 0.01 รูปแบบ Confusion Matrix และแสดงผลการทำนายด้วย Classification Report .....	50
รูปที่ 55 ผลลัพธ์การทดสอบแบบจำลองโครงข่ายประสาทคอนโวลูชันที่ Learning Rate เท่ากับ 0.001 รูปแบบ Confusion Matrix และแสดงผลการทำนายด้วย Classification Report .....	50
รูปที่ 56 ผลลัพธ์การทดสอบแบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวิธีจีจี 16 ที่ Learning Rate เท่ากับ 0.01 รูปแบบ Confusion Matrix และแสดงผลการทำนายด้วย Classification Report ...	51
รูปที่ 57 ผลลัพธ์การทดสอบแบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวิธีจีจี 16 ที่ Learning Rate เท่ากับ 0.001 รูปแบบ Confusion Matrix และแสดงผลการทำนายด้วย Classification Report .	51
รูปที่ 58 ผลลัพธ์การทดสอบแบบจำลองโครงข่ายประสาทแบบเดนซ์เน็ต121 ที่ Learning Rate เท่ากับ 0.01 รูปแบบ Confusion Matrix และแสดงผลการทำนายด้วย Classification Report ...	52
รูปที่ 59 ผลลัพธ์การทดสอบแบบจำลองโครงข่ายประสาทแบบเดนซ์เน็ต121 ที่ Learning Rate เท่ากับ 0.001 รูปแบบ Confusion Matrix และแสดงผลการทำนายด้วย Classification Report .	52
รูปที่ 60 ตัวอย่างชุดคำสั่งการใช้ Stratified 5-Fold Cross Validation.....	54

รูปที่ 61 ผลลัพธ์การทดสอบแบบจำลองโครงข่ายประสาทคอนโวลูชันที่ Learning Rate เท่ากับ 0.001 แบบ Macro average ของ Fold ที่ 1.....	55
รูปที่ 62 ผลลัพธ์การทดสอบแบบจำลองโครงข่ายประสาทคอนโวลูชันที่ Learning Rate เท่ากับ 0.001 แบบ Macro average ของ Fold ที่ 2.....	55
รูปที่ 63 ผลลัพธ์การทดสอบแบบจำลองโครงข่ายประสาทคอนโวลูชันที่ Learning Rate เท่ากับ 0.001 แบบ Macro average ของ Fold ที่ 3.....	55
รูปที่ 64 ผลลัพธ์การทดสอบแบบจำลองโครงข่ายประสาทคอนโวลูชันที่ Learning Rate เท่ากับ 0.001 แบบ Macro average ของ Fold ที่ 4.....	56
รูปที่ 65 ผลลัพธ์การทดสอบแบบจำลองโครงข่ายประสาทคอนโวลูชันที่ Learning Rate เท่ากับ 0.001 แบบ Macro average ของ Fold ที่ 5.....	56
รูปที่ 66 ผลลัพธ์การทดสอบแบบจำลองโครงข่ายประสาทคอนโวลูชันที่ Learning Rate เท่ากับ 0.001 แบบ Macro average รวม 5 Fold.....	56
รูปที่ 67 ผลการทดสอบการแจกแจงแบบปกติ .....	66
รูปที่ 68 ผลการทดสอบที่ระหว่างแบบจำลองโครงข่ายประสาทคอนโวลูชันกับแบบจำลองโครงข่ายประสาทคอนโวลูชันร่วมกับการสกัดคุณลักษณะแบบ LBP.....	68
รูปที่ 69 ผลการทดสอบที่ระหว่างแบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวิธีจี 16 กับแบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวิธีจี 16 ร่วมกับการสกัดคุณลักษณะแบบ LBP.....	69
รูปที่ 70 ผลการทดสอบที่ระหว่างแบบจำลองโครงข่ายประสาทแบบเดนซ์เน็ต121 กับแบบจำลองโครงข่ายประสาทแบบเดนซ์เน็ต121 ร่วมกับการสกัดคุณลักษณะแบบ LBP.....	70
รูปที่ ข.71 ตัวอย่างภาพกระเป่าพื้นผิวออริจินัลจีจีแคนวาส ลักษณะโทนสีน้ำตาล (ของแท้).....	80
รูปที่ ข.72 ตัวอย่างภาพกระเป่าพื้นผิวออริจินัลจีจีแคนวาส ลักษณะโทนสีเทา (ของแท้) .....	81
รูปที่ ข.73 ตัวอย่างภาพกระเป่าพื้นผิวจีจีซูพรีมแคนวาส ลักษณะโทนสีน้ำตาล (ของแท้) .....	82
รูปที่ ข.74 ตัวอย่างภาพกระเป่าพื้นผิวจีจีซูพรีมแคนวาส ลักษณะโทนสีเทา (ของแท้).....	83
รูปที่ ข.75 ตัวอย่างภาพกระเป่าพื้นผิวออริจินัลจีจีแคนวาส ลักษณะโทนสีน้ำตาล (ของปลอม) .....	84
รูปที่ ข.76 ตัวอย่างภาพกระเป่าพื้นผิวออริจินัลจีจีแคนวาส ลักษณะโทนสีเทา (ของปลอม) .....	85
รูปที่ ข.77 ตัวอย่างภาพกระเป่าพื้นผิวจีจีซูพรีมแคนวาส ลักษณะโทนสีน้ำตาล (ของปลอม) .....	86



รูปที่ ข.78 ตัวอย่างภาพกระเป่าพื้นผิวจีจีซูพรีมแคนวาส ลักษณะโทนสีเทา (ของปลอม)..... 87

รูปที่ ข.79 ตัวอย่างภาพกระเป่าพื้นผิววัสดุอื่น..... 88



# บทที่ 1

## บทนำ

### 1.1 ที่มาและความสำคัญของปัญหา

ปัจจุบัน สินค้าลอกเลียนแบบเป็นปัญหาใหญ่ทั่วโลก และมักเกิดขึ้นกับสินค้าหรือผลิตภัณฑ์ที่มีมูลค่าสูง โดยปัญหาดังกล่าวส่งผลกระทบต่อธุรกิจการค้าและเกิดแหล่งเงินทุนที่ผิดกฎหมาย อีกทั้งธุรกิจแอบแฝงของการปลอมแปลงสินค้าได้แพร่กระจายทั่วโลกจนกลายเป็นอุตสาหกรรมมูลค่ากว่า 5 แสนล้านเหรียญ [1] ตามแนวโน้มการค้าสินค้าลอกเลียนแบบและสินค้าละเมิดลิขสิทธิ์ โดยรายงานร่วมที่ออกโดยองค์กรเพื่อความร่วมมือทางเศรษฐกิจและการพัฒนา OECD และสำนักงานทรัพย์สินทางปัญญาของสหภาพยุโรป (EUIPO) ในปี 2019 ได้ชี้แจงมูลค่าของสินค้าปลอมที่นำเข้าทั่วโลกมีมูลค่าถึง 509,000 ล้านดอลลาร์ ซึ่งคิดเป็น 2.5% ของการค้าโลก [1] วิธีป้องกันสินค้าลอกเลียนแบบต่างๆ อาทิ การนำเทคโนโลยีมาแก้ปัญหาเพื่อตรวจจับของปลอม [2] เช่น การติดบาร์โค้ด หรือ RFID อย่างไรก็ตาม วิธีนี้ก็มีข้อจำกัด เช่น แท็กสามารถถูกลบ ปลอมแปลง ทำซ้ำได้ ส่วนวิธีอื่นๆ เช่น Taggants และ Physical Unclonable Functions (PUFs) ที่ให้คุณภาพที่ดีกว่า รับประกันความถูกต้องนั้น วิธีนี้มักจะมีต้นทุนจัดทำสูงและหากใช้สำหรับสินค้าหรูหรา แพชั่นหรืองานศิลปะมักจะมีข้อจำกัดในเรื่องของการแสดงแท็ก (tag) เป็นต้น

สินค้าแบรนด์หรูที่มักมีการปลอมแปลงมากที่สุด ได้แก่ Chanel, Louis Vuitton, Prada, Fendi, Gucci และ Dior ตามรายงานการปลอมแปลงแบรนด์ระดับโลกปี 2018 [3] สินค้าแบรนด์หรูมักมีการส่งต่อการใช้งานเป็นสินค้ามือสองซึ่งทำให้การแยกของแท้และของปลอมยากยิ่งขึ้น เนื่องจากการใช้งานและไม่ได้ซื้อจากร้านทางการโดยตรง ส่วนมากจะเป็นการฝากขายผ่านคนกลางหรือแลกเปลี่ยนกันตามช่องทางโซเชียลมีเดียที่มีการประกาศซื้อขาย โดยเฉพาะช่วงสถานการณ์โรคระบาดโควิด-19 ที่ผ่านมา ทางสมาคมแบรนด์เนมมือสองแห่งประเทศไทยพบว่าปัญหาของลูกค้าสำหรับการซื้อขายกระเป๋า คือ การส่งสินค้ามาตรวจสอบเพราะมีข้อจำกัดที่ไม่สามารถเดินทางเพื่อนำกระเป๋ามาให้ทางสมาคมได้โดยตรง ต้องใช้การถ่ายรูปกระเป๋าและส่งภาพให้ทางสมาคมเพื่อใช้ในการตรวจสอบ อย่างไรก็ตาม ด้วยข้อจำกัดของหลักการตรวจสอบกระเป๋าของแท้และของปลอมในแต่ละรุ่นนั้นแตกต่างกัน ทำให้ยากต่อการตรวจสอบในแต่ละจุดของแต่ละรุ่น ซึ่งจุดสำคัญที่ตรงกันและเป็นเอกลักษณ์คือ วัสดุหลักของกระเป๋า (Canvas หรือ หนังสัตว์) งานวิจัยนี้จึงเลือกการตรวจสอบการปลอมแปลงจากวัสดุที่ใช้ทำกระเป๋า กล่าวคือ Canvas โดยใช้เทคนิคการเรียนรู้เชิงลึก ได้แก่ โครงข่ายประสาทคอนโวลูชัน (Convolutional Neural Networks) และการเรียนรู้ถ่ายโอน (Transfer Learning) เพื่อจำแนกประเภทภาพวัสดุกระเป๋าถือแบรนด์เนมปลอมร่วมกับการสกัดคุณลักษณะ


สำคัญแบบ Local Binary Pattern (LBP) ทั้งนี้ จะประเมินสมรรถนะของแบบจำลองที่สร้างขึ้นด้วยค่าตัววัด Accuracy, Precision, Recall และ F1-score

## 1.2 วัตถุประสงค์

1. เพื่อศึกษาการใช้เทคนิค Transfer Learning ร่วมกับโครงข่ายประสาทคอนโวลูชันในปัญหาการจำแนกภาพวัสดุกระเป๋าถือแบรนด์เนมปลอม
2. เพื่อสร้างแบบจำลองโครงข่ายประสาทคอนโวลูชันร่วมกับ Pretrained Model ที่เลือกใช้สำหรับจำแนกประเภทภาพวัสดุกระเป๋าถือแบรนด์เนมปลอม สำหรับการคัดกรองสินค้าปลอมในเบื้องต้น

## 1.3 ขอบเขตการดำเนินงาน

1. ภาพที่ใช้ในการตรวจสอบจำแนกกระเป๋าแบรนด์เนมของแท้ และของปลอมคือภาพถ่ายของพื้นผิววัสดุกระเป๋า Gucci โดยใช้วัสดุ GG Canvas จากสมาคมแบรนด์เนมมือสองแห่งประเทศไทย ประกอบด้วย มี 1 รูปแบบตัวอักษร โดยแบ่งเป็น 2 พื้นผิวคือ ออริจินัลจีจีแคนวาส และจีจีซูพรีมแคนวาส แต่ละพื้นผิวจะแบ่งออกเป็น 2 โทนสี ได้แก่ โทนสีน้ำตาล และโทนสีเทา ดังรูป



พื้นผิวออริจินัลจีจีแคนวาส

พื้นผิวจีจีซูพรีมแคนวาส

2. แบบจำลองสามารถตรวจสอบกระเป๋าวัสดุออริจินัลจีจีแคนวาสและจีจีซูพรีมแคนวาสครอบคลุมเฉพาะรุ่นที่แสดงในภาคผนวก ค
3. ภาพวัสดุอื่นที่ใช้ในการทำนายผลคือภาพถ่ายของพื้นผิววัสดุกระเป๋าจากสมาคมแบรนด์เนมมือสองแห่งประเทศไทยและเว็บไซต์ทางการของ Gucci
4. Pre-trained Models ที่ใช้ในงานวิจัยนี้ประกอบด้วย VGG-16 และ DenseNet121
5. ใช้เทคนิคการสกัดคุณลักษณะแบบ LBP ร่วมกับแบบจำลองพื้นฐานสำหรับการจำแนกประเภทของกระเป๋า
6. ผลลัพธ์แบบจำลองสามารถทำนายผล ประกอบด้วย ของแท้ ของปลอม และ วัสดุอื่น

7. เปรียบเทียบสมรรถนะแบบจำลองระหว่างแบบจำลองพื้นฐานและแบบจำลองพื้นฐานร่วมกับการสกัดคุณลักษณะแบบ LBP ด้วย K-fold Cross Validation ค่าตัววัดประกอบด้วย Accuracy, Confusion Matrix และ F1-score และหาค่านัยสำคัญทางสถิติ (Statistical Significant)

#### 1.4 ขั้นตอนการดำเนินงาน

1. ศึกษาค้นคว้าความรู้จากทฤษฎีและงานวิจัยที่เกี่ยวข้อง
2. ถ่ายภาพและรวบรวมข้อมูลภาพกระเป๋า Gucci วัสดุ GG Canvas ของแท้ ของปลอม และ วัสดุอื่น
3. ทำการเตรียมข้อมูลสำหรับใช้ในการสร้างแบบจำลอง
4. เลือกแบบจำลองที่ใช้ในการทำ Deep Learning ที่เหมาะสม
5. ออกแบบและสร้างแบบจำลองเพื่อจำแนกกระเป๋าของแท้ ของปลอม และ วัสดุอื่น
6. ทดสอบและประเมินผลวิธีวิจัย
7. สรุปผลการดำเนินงาน
8. เรียบเรียงและจัดทำบทความวิชาการ
9. เรียบเรียงและจัดทำเล่มวิทยานิพนธ์

#### 1.5 ประโยชน์ที่คาดว่าจะได้รับ

ได้แบบจำลองต้นแบบในการจำแนกภาพวัสดุกระเป๋า Gucci GG Canvas ของแท้ และของปลอม ซึ่งจะลดขั้นตอนการตรวจสอบกระเป๋าเบื้องต้น และเป็นประโยชน์สำหรับผู้ซื้อและผู้ขายในสถานการณ์โรคระบาด

#### 1.6 ลำดับการจัดเรียงวิทยานิพนธ์

เนื้อหาในวิทยานิพนธ์แบ่งออกเป็น 5 บท ได้แก่

บทที่ 1 บทนำ

บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

บทที่ 3 แนวคิดและวิธีการวิจัย

บทที่ 4 การทดลองและผลการทดลอง

บทที่ 5 สรุปผลการวิจัย และข้อเสนอแนะ

## 1.7 ผลงานที่ได้รับการตีพิมพ์

- 1) Apipawinwongsa, P. & Limpiyakorn, Y. (2022). Deep Learning Techniques for Image Recognition of Counterfeited Luxury Handbags Materials. In 14th International Conference on Digital Image Processing. Wuhan, China.
- 2) Apipawinwongsa, P. & Limpiyakorn, Y. (2022). Counterfeit Luxury Handbag Materials Image Classification using Deep learning and Local Binary Pattern. International Journal of Emerging Technology and Advanced Engineering (IJETA), 12(9), pp.41-48.



## บทที่ 2


### ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

#### 2.1 ทฤษฎีที่เกี่ยวข้อง

##### 2.1.1 แบบจำลองของสี (Color Model)

มาตรฐานของสีที่ใช้ในปัจจุบันมีอยู่หลากหลายแบบจำลองการนำไปใช้ขึ้นอยู่กับความเหมาะสมสำหรับวัตถุประสงค์ด้านประมวลผลภาพ ค่าของข้อมูลสีจากภาพดิจิทัลจะถูกเก็บอยู่ในรูปแบบขององค์ประกอบฐานสี (Color Basis) เข้าเป็นสีต่างๆในหนึ่งจุดภาพ (Pixel) เช่น ปริภูมิสีแบบอาร์จีบี (RGB Color Space) ดังรูปที่ 1 โดยแต่ละช่องสีแสดงตั้งแต่ 0 ถึง 255 ซึ่งหมายความว่าสามารถแสดงสีต่างกันถึง 16,777,216 เฉดสีในพื้นที่สีอาร์จีบี

##### ปริภูมิสีแบบอาร์จีบี (RGB Color Space)



รูปที่ 1 ปริภูมิสีแบบอาร์จีบี

จุฬาลงกรณ์มหาวิทยาลัย

โหมดสีอาร์จีบี RGB [3] เกิดจากแสงที่มีความยาวคลื่นที่ต่างกันมารวมตัวกันเกิดเป็นสีต่าง ๆ เรียกว่า การผสมสีแบบบวก RGB Color ย่อมาจาก RED, GREEN และ BLUE คือแม่สี 3 สี แดง, เขียวและ น้ำเงิน ด้วยการผสมสีทั้งสามในสัดส่วนต่าง สามารถสร้างเฉดสีทั้งหมดประมาณ 16,777,216 เฉด ระบบสีอาร์จีบีเป็นระบบสีของแสงที่เกิดจากการหักเหของแสงผ่านแท่งแก้วปริซึม เกิดแถบสีที่เรียกว่า สีรุ้ง แยกสีตามที่สายตามองเห็นได้ 7 สีคือแดง, แสด, เหลือง, เขียว, น้ำเงิน, คราม และ ม่วง ดังรูปที่ 2 เป็นพลังงานในรูปของรังสี ที่มีคลื่นที่สายตามองเห็นได้แสงสีม่วงมีความถี่คลื่นสูงสุด เรียกว่า อุลตราไวโอเล็ต และคลื่นแสงสีแดงมีความถี่คลื่นต่ำเรียกว่า อินฟราเรด คลื่นแสงที่มีความถี่สูงกว่าสีม่วงและต่ำกว่าสีแดงเป็นคลื่นที่สายตามนุษย์ไม่สามารถรับได้



รูปที่ 2 สีอาร์จีบี

แสงสีทั้ง 3 สี สีแดง สีน้ำเงิน สีเขียว ถือเป็นแม่สีของแสง เมื่อนำมาฉายรวมกันจะทำให้เกิดสีใหม่อีก 3 สี สีแดง+สีเขียว = สีเหลือง Yellow, สีเขียว+สีน้ำเงิน = สีฟ้า Cyan, สีแดง+สีน้ำเงิน = สีแดงอมชมพู Magenta. เมื่อนำแม่สีของแสงทั้ง 3 มาผสมกัน ในปริมาณแสงสว่างเท่ากัน นำมาฉายรวมกันจะได้แสงสีขาว อาศัยหลักการผสมสีจากสามสีหลักดังกล่าวด้วยค่าเฉดที่แตกต่างกัน เพื่อสร้างสีต่างๆ ขึ้นมา ตัวอย่างเช่น

สีขาว = 255, 255, 255

สีดำ = 0, 0, 0

สีน้ำเงิน = 0, 0, 255

สีแดง = 255, 0, 0

สีเทากลาง = 122, 122, 122

ด้วยหลักการดังกล่าว ทำให้ RGB สามารถสร้างสีได้จำนวนสูงสุดถึง 16,777,216 สี

### 2.1.2 ภาพระดับสีเทา (Grayscale Image)

ภาพระดับสีเทาเป็นภาพที่แต่ละจุดภาพแสดงถึงความเข้มของสี มีความเข้มของสีในแต่ละระดับที่แตกต่างกันตั้งแต่ระดับสีดำ ไปยังระดับสีขาว ดังรูปที่ 3 ซึ่งสามารถกำหนดเป็นค่าระดับความเข้มของสีโดยใช้ค่าระดับความเข้มสีเทา (Gray Scale) โดยที่ค่าระดับความเข้มสีเทาในแต่ละจุดภาพสามารถคำนวณได้จากค่าแต่ละจุดของภาพแบบจำลองสี RGB ดังในสมการที่ 1



รูปที่ 3 ระดับความเข้มสีเทา

$$Y(i,j) = 0.3 R(i,j) + 0.59 G(i,j) + 0.11 B(i,j) \quad (1)$$

โดย  $Y$  แทนค่าระดับความเข้มสีเทาในตำแหน่งจุดภาพ  $i,j$

$R$  แทนค่าระดับความเข้มสีแดงในตำแหน่งจุดภาพ  $i,j$

$G$  แทนค่าระดับความเข้มสีเขียวในตำแหน่งจุดภาพ  $i,j$

$B$  แทนค่าระดับความเข้มสีน้ำเงินในตำแหน่งจุดภาพ  $i,j$

### 2.1.3 ภาพไบนารี (Binary Image)

ภาพไบนารีแสดงอยู่ในรูปแบบขาวดำ โดยข้อมูลภาพในแต่ละจุดภาพของภาพจะถูกกำหนดด้วยค่าไบนารี (Binary) ที่มีขนาด 1 บิต ซึ่งในแต่ละบิตจะกำหนดด้วยค่า 0 หรือ 1 โดยที่ 0 หมายถึงจุดสีดำและ 1 หมายถึงจุดสีขาวโดยการแปลงภาพระดับสีเทาให้กลายเป็นภาพไบนารี จะต้องกำหนดค่าขีดแบ่ง (Threshold) เพื่อกำหนดค่าระดับความเข้มสีเทาที่จะถูกแปลงเป็นสีขาวหรือสีดำ ดังรูปที่ 4




รูปที่ 4 เปรียบเทียบระหว่างภาพระดับสีเทา (ซ้าย) กับภาพไบนารี (ขวา)



### 2.1.4 โลกอลไบนารีแพทเทิร์น (Local Binary Pattern)

Local Binary Patterns [4] เป็นหนึ่งในวิธีการที่นิยมใช้ในการสกัดคุณลักษณะทางด้านพื้นผิว ซึ่งการทำงานของ LBP เป็นการทำให้ระดับพิกเซลของรูปภาพ โดยจุดของพิกเซลที่มีพื้นที่ขนาด  $3 \times 3$  พิกเซล และใช้จุดศูนย์กลางของพื้นที่ ที่มี 8 พิกเซลรอบข้างดูว่ามีขนาดเข้มมากกว่าพิกเซลตรงจุดกลางหรือไม่ ถ้ามากกว่าจะมีค่าเป็น 1 น้อยกว่าจะมีค่าเป็น 0 จากนั้นจะได้เป็นรหัสตัวเลขฐานสอง ความยาว 8 หลักแล้วจึงแปลงเป็นตัวเลขฐานสิบ เป็นผลที่ได้จะเป็นค่าตัวเลขใหม่ในทุกจุดพิกเซลตรงกลาง และทำทุกๆพิกเซลในภาพจะได้ ดังรูปที่ 5 และจากการคำนวณสามารถนำมาเขียนเป็นสมการเพื่อคำนวณหาค่า LBP ของแต่ละพื้นที่ได้ดังสมการที่ 2 และสมการที่ 3



รูปที่ 5 ตัวอย่างภาพหลังจากการคำนวณด้วยเทคนิค Local Binary Pattern [5]

$$LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p \quad (2)$$

โดย  $LBP_{P,R}$  คือ ค่า LBP ณ ตำแหน่งจุดภาพ

$P$  คือ จำนวนตำแหน่งรอบจุดศูนย์กลาง

$R$  คือ รัศมีระหว่างจุดศูนย์กลาง และตำแหน่งรอบจุดศูนย์กลาง

$g_p$  คือ ค่าของจุดภาพที่ตำแหน่งรอบจุดศูนย์กลาง


$g_c$  คือ ค่าของจุดภาพที่จุดศูนย์กลาง

ฟังก์ชัน  $S$  มีค่าดังนี้

$$s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (3)$$

### 2.1.5 โครงข่ายประสาทคอนโวลูชัน หรือ ซีเอ็นเอ็น (Convolutional Neural Network- CNN)

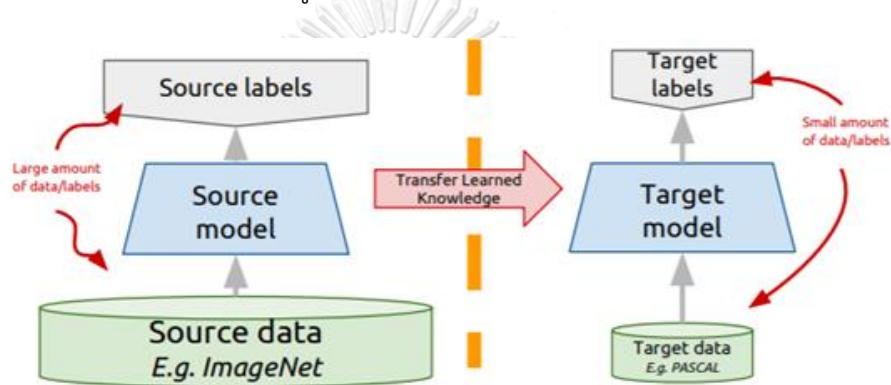
การเรียนรู้เชิงลึกเป็นแนวคิดที่ให้คอมพิวเตอร์สามารถเรียนรู้ด้วยตัวเองเหมือนการทำงานของโครงข่ายประสาทของมนุษย์โดยเรียนรู้โดยนำระบบโครงข่ายประสาท (Neural Network) มาผ่านลำดับชั้นซ่อน (Hidden Layer) จำนวนหลายชั้นซึ่งเปรียบเสมือนเป็นความลึกของชั้น และได้ทำการเรียนรู้ข้อมูลตัวอย่าง จากชุดข้อมูลจำนวนหนึ่ง เพื่อให้คอมพิวเตอร์เข้าใจแพตเทิร์น (Pattern) ของข้อมูล อัลกอริทึมการเรียนรู้เชิงลึกได้ถูกพัฒนาต่อในปัจจุบันได้แก่ Deep Neural Network, Recurrent Neural Network และ Convolutional Neural Network เป็นต้น ซึ่งโครงข่ายประสาทคอนโวลูชันเป็นการเรียนรู้เชิงลึกที่ถูกพัฒนาขึ้นเพื่อใช้ในการเรียนรู้ด้วยภาพ [6] ภาพในคอมพิวเตอร์จะประกอบด้วยพิกเซลจำนวนมากเรียงต่อกัน ด้วยวิธีการ CNN จึงใช้วิธีเปลี่ยนพิกเซลของรูปภาพให้อยู่ในรูปแบบการเข้ารหัส (Encoding) ตัวเลขโดยใช้ความเข้มสี RGB แทนข้อมูลในแต่ละพิกเซล ซึ่งจะมีค่าได้ตั้งแต่ 0-255 โดยมีชั้น Convolution เป็นชั้นแรกและมีชั้น Pooling ซ้อนกันหลายชั้น ในการลดขนาดพารามิเตอร์และดึงคุณลักษณะที่สำคัญของข้อมูล ที่ผ่านตัวกรอง (Filter) แล้วจึงมีชั้นสุดท้ายเป็น Fully Connected Layer เป็นการนำข้อมูลจากชั้นก่อนหน้าเชื่อมกันทั้งหมด และได้ทำนายผลลัพธ์ (Output Predictions) ด้วย Activation Function ที่กำหนด ให้เป็นความน่าจะเป็นของ Class ต่างๆ ดังรูปที่ 6



รูปที่ 6 โครงสร้างโครงข่ายประสาทคอนโวลูชัน [7]

### 2.1.6 การเรียนรู้ถ่ายโอน (Transfer Learning)


การเรียนรู้ถ่ายโอนเป็นแบบจำลองที่ได้รับการฝึกสอน และทดสอบก่อนซึ่งให้ผลลัพธ์การทำนายที่แม่นยำ ในการเรียนรู้แบบ Transfer Learning ดังรูปที่ 7 จะใช้ Pretrained Weights ในการเรียนรู้มาแล้วกับชุดข้อมูลอื่น มาช่วยในการเรียนรู้ของแบบจำลองที่ต้องการจะเรียนรู้ใหม่ได้ โดยตัว Pretrained Weights นี้ มักจะถูกเรียนรู้มากับชุดข้อมูลที่มีขนาดใหญ่มากเช่น ชุดข้อมูล ImageNet ที่เป็นชุดข้อมูลภาพขนาดใหญ่ที่มีจำนวนภาพมากกว่า 14 ล้านภาพ และมีจำนวนคลาสมากกว่า 1000 คลาส โดย Pretrained Weights สามารถสืบค้นได้จากอินเทอร์เน็ตที่ถูกเรียนรู้ด้วยสถาปัตยกรรมของแบบจำลองที่เป็นที่รู้จักทั่วไปเช่น VGGNet และ DenseNet



รูปที่ 7 แบบจำลองการเรียนรู้ถ่ายโอน [8]

#### 2.1.2.1 วิธีจีเน็ต (VGGNet)


Simonyan และ Zisserman เสนอ VGGNet [9] เป็นที่รู้จักในปี 2014 ในฐานะผู้ชนะใน ILSVRC 2014 VGGNet มีจำนวนเลเยอร์แบบจำลองเป็น 16 และ 19 เช่น VGG16 และ VGG19 ตามลำดับ โดยใช้ Convolution Layers ขนาด 3x3, 1 Stride ทั้งโครงสร้าง ดังรูปที่ 8 พารามิเตอร์สำหรับ VGG16 คือประมาณ 138 ล้านพารามิเตอร์ และสำหรับ VGG19 คือ ประมาณ 144 ล้านพารามิเตอร์



รูปที่ 8 โครงสร้างโครงข่ายประสาทคอนโวลูชันแบบ VGG-16 [10]

### 2.1.2.2 เดนซ์เน็ต (DenseNet)

Huang และคณะ ในปี 2018 ได้เสนองานวิจัย Densely Connected Convolutional Networks (DenseNet) [11] คือ การเชื่อมต่อของบล็อกภายใน ซึ่งบล็อกแต่ละชั้นเชื่อมต่อกับชั้นก่อนหน้าทั้งหมด ดังรูปที่ 9 เมื่อรวมชั้นก่อนหน้าแล้ว DenseNet จะรวมฟังก์ชันลักษณะก่อนหน้าทั้งหมดเข้าด้วยกัน ดังนั้นแบบจำลองจึงไม่ต้องการชั้นที่กว้าง และสามารถลดจำนวนฟังก์ชันลักษณะลงได้ DenseNet121 มีจำนวนโครงสร้างลึก 121 ชั้นซึ่งมีจำนวนพารามิเตอร์ประมาณ 8 ล้านพารามิเตอร์ และยังมีแบบจำลอง DenseNet169 และ DenseNet201 ที่มีโครงสร้างลึกตามตัวเลขที่ต่อท้ายของแบบจำลอง จุฬาลงกรณ์มหาวิทยาลัย



รูปที่ 9 โครงสร้างโครงข่ายประสาทแบบ Dense Block in DenseNet

## 2.2 งานวิจัยที่เกี่ยวข้อง

2.2.1 The fake vs Real Goods Problem: Microscopy and Machine Learning to the Rescue [12]

Sharma และคณะได้นำแนวคิดหลักของระบบโดยใช้อัลกอริทึมเรียนรู้รู้ลักษณะวัตถุจากภาพโดยนำภาพมาจากกล้องจุลทรรศน์ขนาดของวัตถุทางกายภาพความละเอียดสูงด้วยกำลังขยายระหว่าง

100 ถึง 300 เท่า โดยให้ระบบเรียนรู้ชุดข้อมูลภาพจากสินค้าของแท้และสินค้าลอกเลียนแบบทำการทดสอบกับวัตถุในกลุ่มผลิตภัณฑ์นั้นๆโดยใช้อัลกอริทึม Support Vector Machine และ CNN โดยสรุปอัลกอริทึม SVM ให้ผลลัพธ์ความถูกต้อง 95% สำหรับการตรวจสอบภาพขนาดเล็กเพียงภาพเดียวและโครงข่ายประสาทคอนโวลูชันให้ความแม่นยำเพิ่มขึ้นที่ 98% ต่อภาพ

### 2.2.2 Real and Fake Label Image Classification Algorithm Based on HOG and SVM [13]

Li และคณะได้นำภาพถ่ายฉลากสีดำขนาดเล็กภายในกระเป๋า Gucci ทั้งของแท้และของปลอมจำนวนทั้งหมด 600 ภาพ ดังรูปที่ 10 ซึ่งใช้ Histogram of Oriented Gradients (HOG) เป็นตัวแยกคุณลักษณะ และใช้การเรียนรู้ของเครื่องด้วยอัลกอริทึม Support Vector Machine ในการจำแนกของแท้และของปลอม โดย Linear Kernel Function ให้ความแม่นยำ 86.75% และ Gaussian kernel function ให้ความแม่นยำ 90.25%




รูปที่ 10 ตัวอย่างรูปภาพฉลากสีดำ ของแท้(ซ้าย) ของปลอม(ขวา)

### 2.2.3 SpotTheFake: An Initial Report on a New CNN-Enhanced Platform for Counterfeit Goods Detection [14]

Şerban และคณะทำการออกแบบและพัฒนาแพลตฟอร์มการตรวจจับสินค้าปลอมโดยใช้ VGG16 Convolutional โดยใช้ในการแปลงวิดีโอเป็นภาพด้วยเครื่องมือ MATLAB ที่บันทึกวีดีโอของกระเป๋า แวนตา และนาฬิกาข้อมือ โดยฝึกผ่านกระบวนการเรียนรู้ถ่ายโอนและขั้นตอนการตรวจจับของปลอมแบบหลายขั้นตอนโดยมีขั้นตอน ดังรูปที่ 11 ดังนี้

1. ผู้ใช้ ใช้กล้องสมาร์ทโฟนถ่ายภาพวัตถุทั้งหมดจากนั้นระบบจะแจ้งว่ารูปนั้นอยู่ในฐานข้อมูล
2. หากภาพที่ถ่ายมีในฐานข้อมูลผู้ใช้จะต้องถ่ายภาพหลายมุมของวัตถุเพื่อส่งไปในระบบอีกครั้ง
3. ระบบจะนำคะแนนการทำนายจากแต่ละแบบจำลองมารวมกันเป็นค่าเฉลี่ยเปอร์เซ็นต์ความถูกต้อง โดยถือเป็นเทคนิคการตรวจจับแบบหลายขั้นตอน

จากการทดสอบทั้ง 3 ขั้นตอนได้ค่าความแม่นยำใกล้เคียง 100%



รูปที่ 11 ตัวอย่างรูปภาพ Use-case Scenario แบบหลายขั้นตอน [14]

2.2.4 Classification of Images of Childhood Pneumonia using Convolutional Neural Networks [15]

Saraiva และคณะจำแนกประเภทของโรคปอดบวมโดยใช้โครงข่ายประสาทคอนโวลูชัน (CNN) โดยมีชุดข้อมูล Labeled Optical Coherence Tomography (OCT) และภาพ Chest X-Ray จาก Kermany และคณะ [16] มีทั้งหมด 5863 ภาพแบ่งเป็น 2 ประเภทคือ ปอดปกติและโรคปอดบวมโดยมีการประเมินแบบจำลองด้วยการใช้ K-fold Cross Validation ซึ่งทำให้ได้ค่าความแม่นยำมากขึ้นจาก Kermany และคณะที่ 92.8% เพิ่มขึ้นเป็นค่าความแม่นยำเฉลี่ย 95.3%

2.2.5 Classification of Images of Childhood Pneumonia using Convolutional Neural Networks [17]

Adagbasa และคณะจำแนกพันธุ์ของหญ้าในพื้นที่ภูเขาด้วยการเรียนรู้เชิงลึกแบบ Multi-layer Perceptron: MLP โดยใช้ชุดข้อมูลดัชนีพืชพรรณ Sentinel-2 ซึ่ง Sentinel-1 และ ASTER DEM ถูกรวมเข้ากับภาพ Sentinel-2 เพื่อปรับปรุงความแม่นยำในการจำแนกประเภทโดยใช้ Stratified K-fold เพื่อให้ข้อมูลมีความสมดุลของชุดข้อมูลฝึกสอนและชุดข้อมูลทดสอบผลลัพธ์เมื่อเปรียบเทียบกับแบบจำลองอื่นๆเช่น LR, LDA, SVM, KNN, CART และ RF แบบจำลองของ MLP ได้

ค่าความแม่นยำแบบ Cross Validation สูงที่สุด 92% และได้ค่าเฉลี่ย F1-score ของ 10 fold ที่ 92%

#### 2.2.6 Local Binary Pattern and Deep Learning Feature Extraction Fusion for COVID-19 Detection on Computed Tomography Images [18]

Mubarak และคณะ เสนอวิธีการจำแนกโรค Covid-19 จากภาพ CT-scan ทั้ง 3 ประเภท ได้แก่ ปอดติดเชื้อจากโรค Covid-19 โรคปอดบวมและ ปอดปกติ ซึ่งใช้การสกัดคุณลักษณะด้วยมือแบบ Local Binary Pattern (LBP) และใช้การสกัดคุณลักษณะอัตโนมัติด้วยการเรียนรู้เชิงลึก โดยใช้ตัวจำแนกด้วย Support Vector Machines (SVM) และ K-Nearest Neighbors (KNN) เพื่อปรับปรุงประสิทธิภาพของการจำแนกจึงใช้ การต่อกัน (Concatenated) ของการสกัดคุณลักษณะด้วย LBP และการสกัดคุณลักษณะด้วยการเรียนรู้เชิงลึก ทำให้ความแม่นยำสูงสุดในการจำแนกของแบบจำลอง VGG16+LBP ที่ 99.4%

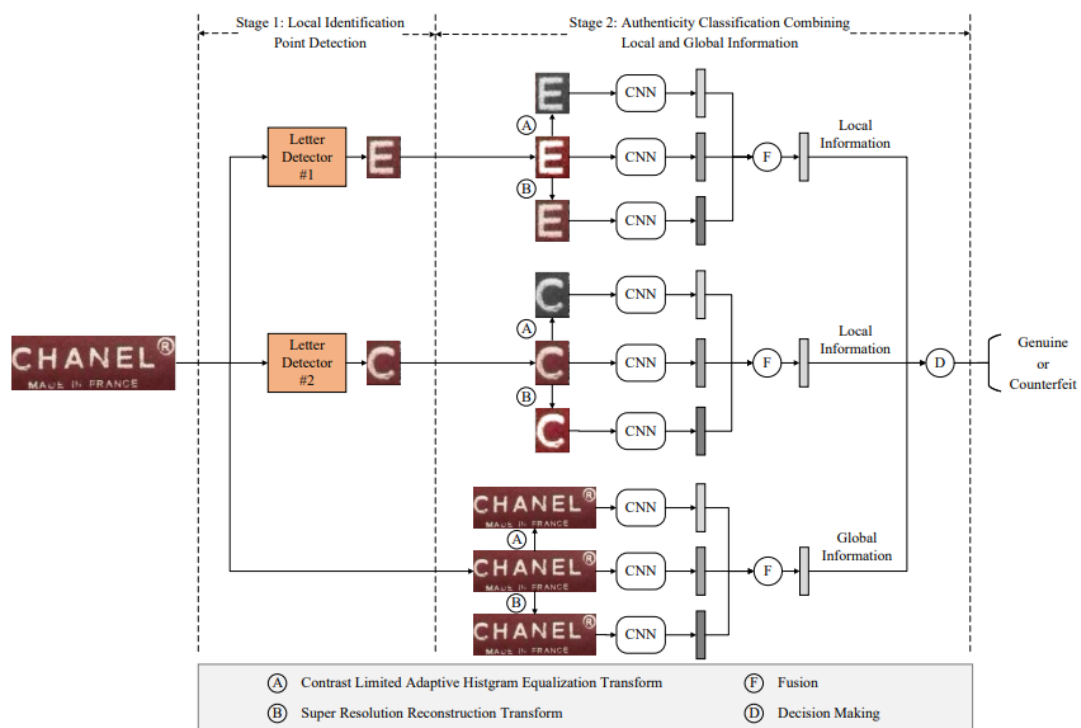
#### 2.2.7 Refined Color Texture Classification Using CNN and Local Binary Pattern [19]

Hosny และคณะเสนอเทคนิคการสกัดคุณลักษณะสำหรับการจำแนกและจดจำพื้นผิวสีด้วยวิธี LBP และ CNN ทำให้แบบจำลองเห็นคุณลักษณะเพิ่มขึ้นช่วยในการจำแนกพื้นผิวที่ดีขึ้น โดยใช้ชุดข้อมูล ALOT, CBT และ Outex ซึ่งเป็นข้อมูลประเภทพื้นผิวสี โดยการใช้ตัวจำแนก SVM ที่ใช้การสกัดคุณลักษณะแบบ LBP เพียงอย่างเดียวได้ค่าความแม่นยำที่ 70.3% 73.45% และ 66.2% จากชุดข้อมูล ALOT, CBT และ Outex ตามลำดับ ส่วนการใช้การสกัดคุณลักษณะแบบ CNN เพียงอย่างเดียวโดยการใช้ตัวจำแนก SVM ได้ค่าความแม่นยำสูงสุดที่ 90.89% 91.78% และ 86.45% จากชุดข้อมูล ALOT, CBT และ Outex ตามลำดับ โดยการใช้การสกัดคุณลักษณะแบบ LBP ร่วมกับ CNN ช่วยเพิ่มความแม่นยำจากการสกัดคุณลักษณะ CNN แบบดั้งเดิมได้ถึง 25% ซึ่งทำให้ค่าความแม่นยำเพิ่มขึ้นถึง 100% 96.67% และ 100% จากชุดข้อมูล ALOT, CBT และ Outex ตามลำดับ แนวทางนี้ยังทนทานต่อชุดข้อมูลที่มีการปรับขนาดภาพ การหมุนของภาพ และความสว่างที่แตกต่างกัน

#### 2.2.8 A Two-Stage Deep Learning Framework for Counterfeit Luxury Handbag Detection in Logo Images [20]

Peng และคณะได้เสนอการเรียนรู้เชิงลึกแบบสองขั้นตอนสำหรับการตรวจจับภาพโลโก้ของกระเป๋าถือแบรนด์เนมปลอมโดยใช้ภาพโลโก้ของกระเป๋า CHANEL และ Louis Vuitton จำนวน

ทั้งหมด 639 ภาพ ขั้นตอนแรกใช้แบบจำลองของ YOLO v5 ที่มี Resnet เป็น Backbone ในการตรวจจับวัตถุเพื่อระบุตำแหน่งของตัวอักษรบนโลโก้ในแต่ละตัวอักษรต่อจากนั้นในขั้นตอนที่สองใช้แบบจำลองโครงข่ายประสาทเชิงลึกแบบ Resnet จำแนกประเภทของข้อมูลที่รวมทั้งรูปแบบแต่ละตัวอักษร (Local) และภาพรวมของตัวอักษรที่เรียงกัน (Global) เพื่อทำนายผลลัพธ์ของแท้และของปลอม ดังรูปที่ 12 โดยการทำให้แบบสองขั้นตอนช่วยเพิ่มค่าความแม่นยำของผลลัพธ์การทำนายโลโก้ CHANEL ประมาณ 4-5% เป็นค่าความแม่นยำที่ 96% และของโลโก้ Louis Vuitton เพิ่มค่าความแม่นยำขึ้น 10% เป็น 98% เปรียบเทียบกับการทำให้แบบขั้นตอนเดียว



รูปที่ 12 โครงสร้างการเรียนรู้เชิงลึกแบบสองขั้นตอน [20]



### บทที่ 3


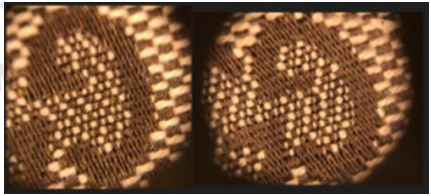
#### แนวคิดและวิธีการวิจัย

#### 3.1 ศึกษาวิธีการตรวจสอบกระเป๋าของแท้และของปลอมกับสมาคมแบรนด์เนมมือสองแห่งประเทศไทย

ศึกษาวิธีการตรวจสอบกระเป๋าของแท้และของปลอมกับสมาคมแบรนด์เนมมือสองแห่งประเทศไทยจากการศึกษาหลักการในการตรวจสอบกระเป๋าของแท้และของปลอมซึ่งประกอบไปด้วย 5 จุดสำคัญในการสังเกต ประกอบด้วย อะไหล่ (Hardware), โลโก้, ฝีเข็ม, Date Code และวัสดุ โดยมีรายละเอียด ดังตารางที่ 1

ตารางที่ 1 วิธีการตรวจสอบกระเป๋าของแท้และของปลอม

จุดสำคัญ	วิธีการตรวจสอบ	ภาพประกอบ
1.อะไหล่ (Hardware) เช่น หมุด ซิป รางซิป อื่นๆ	สังเกตวัสดุที่ใช้ชุบ Hardware จะมีความเงาที่แตกต่างกัน และสังเกตรูปแบบตัวอักษรบนอะไหล่	
2. ฝีเข็ม	สังเกตแนวการเรียงตัวของฝีเข็ม, ขนาด และสีของวัสดุที่ใช้เย็บ	
3. โลโก้กระเป๋า / รูปแบบอักษร	สังเกตรูปร่างขนาดโลโก้ และสังเกตความเงาของวัสดุที่เคลือบโลโก้	


จุดสำคัญ	วิธีการตรวจสอบ	ภาพประกอบ
4. Date Code เช่น Model Number, Serial Number/ QR tag	<p>Serial Number สังเกต โดยดูจำนวนหลักและรูปแบบของตัวเลข ซึ่งเลขด้านบนจะเป็น Model Number ต้องเหมือนกับของแท้ และเลขแฉากล่างจะเป็น Serial Number ซึ่งกระเป๋าแต่ละใบมีเลขเฉพาะไม่ซ้ำกัน</p> <p>ส่วน QR tag นั้นจะสังเกตความเงาของ tag โดยส่วนบนตัวอักษรเป็นแถบด้านซึ่งตัดกับส่วนล่างที่เป็นแถบเงา</p>	
5. วัสดุ เช่น หนัง/ ผ้า	ใช้กล้องส่องขยายเพื่อสังเกตการเรียงตัวของลายผ้า, ความถี่ของวัสดุ และใช้มือสัมผัสผิววัสดุ ความนุ่ม-แข็งของหนัง	

จากการศึกษาและวิเคราะห์จะเห็นว่า Hardware โลโก้ และผีเข็มเป็นองค์ประกอบที่แตกต่างกันไปในแต่ละรุ่นโดยจะต้องใช้หลักการตรวจสอบที่แตกต่างกันไปสำหรับรุ่นนั้นๆ ส่วน Date Code และ QR tag เป็นเพียงเลขประจำตัวของกระเป๋าที่ไม่สามารถตรวจสอบเองได้หากต้องการตรวจสอบ QR tag จะต้องไปตรวจสอบที่ร้านค้าทางการของ Gucci เท่านั้น ส่วนที่ตรวจสอบได้ยากที่สุดคือวัสดุผ้า และหนัง ซึ่งเป็นวัสดุหลักที่เป็นเอกลักษณ์ของกระเป๋าเมื่อเทียบกับหลักการตรวจสอบอื่นๆและจากการสัมภาษณ์นายกสมาคมและผู้เชี่ยวชาญในการตรวจสอบพบว่าในส่วนนี้ต้องใช้กล้อง


ส่องขยายภาพขนาดมากกว่า 10 เท่าในการสังเกตและยังมีข้อจำกัดหากไม่ได้สัมผัสผิวของวัสดุโดยตรง จากการสำรวจวัสดุที่ใช้ทำกระเป๋าจากเว็บไซต์ทางการของกระเป๋า Gucci มีจำนวนกระเป๋าทันหมด 387 รุ่น [21] แบ่งเป็นวัสดุตั้งรูปที่ 13 โดยมีวัสดุที่ทำจากหนังสัตว์จำนวน 162 รุ่น และวัสดุ GG Canvas จำนวน 134 รุ่นซึ่งหนังจะแบ่งแยกย่อยได้หลายประเภทตามหนังสัตว์ต่างๆ ดังนั้นวัสดุ GG Canvas จึงเป็นวัสดุหลักที่มากที่สุดของกระเป๋า Gucci โดยมีตัวอย่างภาพกระเป๋าวัสดุออริจินัลจีจีแคนวาส ดังรูปที่ 14 และตัวอย่างภาพกระเป๋าวัสดุจีจีซูพรีมแคนวาส ดังรูปที่ 15



รูปที่ 13 ตัวอย่างวัสดุกระเป๋าของ Gucci



รูปที่ 14 ตัวอย่างภาพกระเป๋าวัสดุออริจินัลจีจีแคนวาส



รูปที่ 15 ตัวอย่างภาพกระเป๋าวัสดุจีจีซูพรีมแคนวาส

## 3.2 การเตรียมชุดข้อมูล

### 3.2.1 การเตรียมชุดข้อมูลกระเป๋าของแท้ และของปลอม

จัดเตรียมกระเป๋า Gucci GG Canvas ของแท้และของปลอมจากสมาคมแบรนด์เนมมือสองแห่งประเทศไทย รวมถึงการรวบรวมภาพกระเป๋าเพิ่มเติมจากสมาคมที่บันทึกไว้ในคลังข้อมูลจากประวัติการให้บริการตรวจสอบกระเป๋าซื้องแท้และของปลอมแก่ลูกค้า ดังรูปที่ 16 โดยผู้วิจัยได้ทำการถ่ายภาพกระเป๋าแบบเต็มใบทั้งสี่ด้าน ได้แก่ ด้านหน้า ด้านหลัง ด้านข้าง (ซ้าย-ขวา) และด้านล่างของกระเป๋าแต่ละใบดังรูปที่ 17 งานวิจัยนี้ใช้วัสดุหลักของกระเป๋าในการตรวจสอบ มีวิธีการทำความสะอาดข้อมูล (Data Cleaning) ในขั้นแรก โดยการนำภาพกระเป๋าแบบเต็มใบมาทำการตัดส่วนภาพ (crop) เฉพาะส่วนพื้นผิววัสดุ GG Canvas โดยไม่ติดองค์ประกอบอื่น เช่น อะไหล่ ลวดลาย หรือสายกระเป๋า ดังรูปที่ 18



รูปที่ 16 ตัวอย่างกระเป๋า Gucci GG Canvas จากสมาคมแบรนด์เนมมือสองแห่งประเทศไทย



รูปที่ 17 ตัวอย่างภาพถ่ายกระเป๋า Gucci GG Canvas ก) ด้านหน้า ข) ด้านหลัง ค) ด้านข้างซ้าย ง) ด้านข้างขวา จ) ด้านล่าง




รูปที่ 18 ตัวอย่างการตัดส่วนภาพเฉพาะส่วนพื้นผิววัสดุ GG Canvas

### 3.2.2 การเตรียมชุดข้อมูลวัสดุอื่น

งานวิจัยนี้นำเสนอการตรวจสอบกระเป๋า Gucci โดยใช้วัสดุหลักคือ GG Canvas แบบออริจินัลจีจีแคนวาสและจีจีซูพรีมแคนวาส ครอบคลุม 2 โทนสี ได้แก่ โทนสีน้ำตาล และโทนสีเทาเท่านั้น เพื่อให้แบบจำลองสามารถจำแนกวัสดุอื่นที่ไม่เกี่ยวข้องได้ ดังนั้นจึงมีกระบวนการจัดเก็บภาพพื้นผิวของวัสดุอื่นที่ไม่เกี่ยวข้องโดยให้แบบจำลองเรียนรู้เพื่อสามารถทำนายผลลัพธ์เป็นอื่นๆ ดังนั้นจึงรวบรวมรูปกระเป๋าที่เป็นวัสดุอื่นที่ไม่เกี่ยวข้องจากเว็บไซต์ทางการของ Gucci และสมาคมแบรนด์เนม

มือสองแห่งประเทศไทยโดยประเภทวัสดุอื่นๆที่ไม่เกี่ยวข้องได้แก่ หนึ่งทุกประเภท, GG Canvas สี  
 อื่นๆนอกเหนือจากสีน้ำตาลและเทา, GG Canvas แบบสกรีนลวดลาย และยีนส์ ดังรูปที่ 19 จากนั้น  
 นำภาพเข้าสู่กระบวนการทำความสะอาดข้อมูลโดยการนำภาพกระเป๋าแบบเต็มใบมาทำการตัดส่วน  
 ภาพ (Crop) เฉพาะส่วนพื้นผิววัสดุกระเป๋าโดยไม่ติดองค์ประกอบอื่น ดังรูปที่ 20



รูปที่ 19 ตัวอย่างกระเป๋า Gucci วัสดุอื่นจากสมาคมแบรนด์เนมมือสองแห่งประเทศไทยและเว็บไซต์  
 ทางการของ Gucci



รูปที่ 20 ตัวอย่างการตัดส่วนภาพเฉพาะส่วนวัสดุอื่น


### 3.2.3 เพิ่มชุดข้อมูลภาพ (Data Augmentation)

การเพิ่มจำนวนชุดข้อมูลสำหรับชุดข้อมูลฝึกสอนแบบจำลองเป็นการช่วยให้แบบจำลองเรียนรู้ชุดข้อมูลอย่างมีประสิทธิภาพมากยิ่งขึ้น ในกระบวนการนี้แบ่งออกเป็น 2 ส่วน คือ แบบใช้มนุษย์ และแบบใช้ไลบรารีอัตโนมัติ

1. การเพิ่มชุดข้อมูลแบบจำลองโดยใช้มนุษย์ ขั้นแรกนำภาพที่ได้จากการตัดเฉพาะส่วนวัสดุโดยไม่ติดองค์ประกอบอื่น นำเข้าโปรแกรม Adobe Photoshop Slice tool ดังรูปที่ 21 จากนั้นทำการแบ่งภาพเป็นส่วนเพื่อเพิ่มจำนวนภาพชุดข้อมูลสำหรับจำแนกและตรวจจับกระเป๋าของแท้ ของปลอม และวัสดุอื่น ดังนี้

1. พื้นผิวออริจินัลจีจีแคนवास ลักษณะโทนสีน้ำตาล (ของแท้)
2. พื้นผิวออริจินัลจีจีแคนवास ลักษณะโทนสีเทา (ของแท้)
3. พื้นผิวจีจีซูพรีมแคนवास ลักษณะโทนสีน้ำตาล (ของแท้)
4. พื้นผิวจีจีซูพรีมแคนवास ลักษณะโทนสีเทา (ของแท้)
5. พื้นผิวออริจินัลจีจีแคนवास ลักษณะโทนสีน้ำตาล (ของปลอม)
6. พื้นผิวออริจินัลจีจีแคนवास ลักษณะโทนสีเทา (ของปลอม)
7. พื้นผิวจีจีซูพรีมแคนवास ลักษณะโทนสีน้ำตาล (ของปลอม)
8. พื้นผิวจีจีซูพรีมแคนवास ลักษณะโทนสีเทา (ของปลอม)
9. พื้นผิววัสดุอื่น

เพื่อให้ได้ชุดข้อมูลตัวอย่างภาพวัสดุของกระเป๋าแต่ละส่วนไม่ซ้ำกันซึ่งจะช่วยเพิ่มประสิทธิภาพการเรียนรู้ของแบบจำลองได้ดียิ่งขึ้น ดังแสดงใน ภาคผนวก ข




รูปที่ 21 ตัวอย่างการเพิ่มจำนวนข้อมูลภาพโดยใช้ Adobe Photoshop Slice Tool


2. การเพิ่มชุดข้อมูลแบบใช้ไลบรารีอัตโนมัติในการฝึกสอน การจัดเตรียมข้อมูลนำเข้า (Input Data) เพื่อเข้าสู่กระบวนการเรียนรู้ของแบบจำลอง เป็นขั้นตอนที่สำคัญหลักอีกหนึ่งประการ ในขั้นตอนนี้จะเป็นการปรับให้ชุดข้อมูลเหมาะสมต่อการเรียนรู้ของแบบจำลอง ดังนี้

ขั้นแรกกำหนดขนาดภาพของชุดข้อมูลให้เป็นขนาดเดียวกันโดยใช้ไลบรารีในภาษา Python เพื่อปรับขนาดภาพให้เป็นมาตรฐาน  $224 \times 224 \times 3$  พิกเซล ดังรูปที่ 22 ขั้นที่สองทำการ Normalized เนื่องจากแบบจำลองมีกระบวนการเรียนรู้โดยใช้การอ่านค่า  $0 - 1$  ซึ่งชุดข้อมูลรูปภาพที่เตรียมไว้เบื้องต้นเป็นรูปภาพสีที่มีค่า RGB อยู่ระหว่าง  $0 - 255$  ดังนั้นจึงใช้คำสั่ง `ImageDataGenerator(rescale=1./255)` เพื่อแปลงค่ารูปภาพให้แทนด้วยค่าข้อมูลเมทริกซ์ให้อยู่ในช่วง  $0 - 1$  เท่านั้น ถ้าดับสุดท้ายเป็นการเพิ่มชุดข้อมูลให้มีความหลากหลายยิ่งขึ้น ตามหลักการหากแบบจำลองทำการเรียนรู้เพียงแบบชุดข้อมูลที่มีอยู่เท่านั้น ซึ่งอาจจะได้ค่าความแม่นยำสูง แต่อาจเกิดปัญหากับข้อมูลที่ไม่เคยเรียนรู้มาก่อนก็จะนำมาซึ่งปัญหา Overfitting ดังนั้นในขั้นนี้จึงมีการเพิ่มชุดข้อมูลให้หลากหลายยิ่งขึ้น โดยคำนึงถึงหลักการที่อาจเกิดขึ้นจริงของข้อมูลที่นำเข้าซึ่งอาจพบได้โดยใช้คำสั่ง `transpose(Image.FLIP_LEFT_RIGHT).transpose(Image.FLIP_TOP_BOTTOM)` เพื่อทำการพลิกภาพแนวนอนร่วมกับแนวตั้ง ดังรูปที่ 23






รูปที่ 22 ตัวอย่างการปรับขนาดภาพนำเข้าเป็นขนาด  $224 \times 224 \times 3$  พิกเซล




รูปที่ 23 ตัวอย่างการพลิกภาพแนวนอนร่วมกับแนวตั้ง

และเพื่อเพิ่มชุดข้อมูลให้มีความหลากหลายขึ้นจึงได้ใช้คำสั่ง Rotate เพื่อให้ภาพหมุนไปทางด้านซ้าย 90 องศา ดังรูปที่ 24 และ หมุนไปทางด้านขวา 90 องศา ดังรูปที่ 25 ในขั้นตอนวิธีนี้จะช่วยให้แบบจำลองมีการเรียนรู้ภาพที่หลากหลายมากยิ่งขึ้นซึ่งจะช่วยลดปัญหา Overfitting



รูปที่ 24 ตัวอย่างการหมุนภาพด้านซ้าย 90 องศา



รูปที่ 25 ตัวอย่างการหมุนภาพด้านขวา 90 องศา

การเพิ่มชุดข้อมูลภาพที่อธิบายไว้ข้างต้นเป็นกระบวนการจัดการชุดข้อมูลนำเข้า (input data) สำหรับแบบจำลองโครงข่ายประสาทคอนโวลูชัน แบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวีจีจี 16 (VGG16) และโครงข่ายประสาทแบบเดนส์เน็ต 121 (DenseNet121)

### 3.2.4 การแบ่งชุดข้อมูลภาพ


ชุดข้อมูลภาพกระเป๋าสามารถแบ่งออกเป็นสามประเภท ได้แก่ : ภาพกระเป๋าของแท้ ภาพกระเป๋าของปลอม และภาพวัสดุอื่น โดยมีการจัดเตรียมชุดข้อมูลสำหรับแบบจำลองออกเป็น 3 ส่วน ได้แก่: ชุดข้อมูลฝึกสอน ข้อมูลตรวจสอบ และข้อมูลทดสอบ ดังตารางที่ 2

ตารางที่ 2 สรุปจำนวนข้อมูลฝึกสอน ข้อมูลตรวจสอบ ข้อมูลทดสอบของกระเป๋า Gucci GG Canvas ของแท้ ของปลอม และวัสดุอื่น


ประเภทรูปภาพ (Image Class)	ข้อมูลฝึกสอน (Training Data)	ข้อมูลตรวจสอบ (Validation Data)	ข้อมูลทดสอบ (Test Data)	จำนวนทั้งหมด (Total)
กระเป๋าของแท้	640	160	200	1000
กระเป๋าของปลอม	640	160	200	1000
วัสดุอื่น	320	80	100	500
<b>รวม</b>	<b>1600</b>	<b>400</b>	<b>500</b>	<b>2500</b>

### 3.3 การดึงคุณลักษณะสำคัญของภาพ


ในขั้นตอนนี้จะเป็นการดึงคุณลักษณะสำคัญของภาพ จากชุดข้อมูลภาพที่มีลักษณะเป็นเอกลักษณ์การสกัดคุณลักษณะสำคัญ โดยใช้เทคนิค Local Binary Patterns (LBP) เป็นหนึ่งในเทคนิคการสกัดคุณลักษณะของพื้นผิวภาพซึ่งเป็นการกระทำในระดับพิกเซล ณ จุดพิกเซลใดๆ ในรูปภาพโดยจะถูกกำหนดเส้นขีดแบ่งขนาด  $3 \times 3$  พิกเซลโดยผลแบ่งพิกเซลจะอยู่ในรูปแบบของไบนารี 0 – 1 ดังนั้นจึงใช้วิธี LBP ในการดึงคุณลักษณะสำคัญของพื้นผิวเพื่อช่วยให้แบบจำลองเรียนรู้ได้อย่างมีประสิทธิภาพยิ่งขึ้นโดยตัวอย่างภาพการดึงคุณลักษณะสำหรับพื้นผิวออร์จินัลจีจีแคนवास ดังรูปที่ 26 พื้นผิวจีจีซูพรีมแคนवास ดังรูปที่ 27 และพื้นผิววัสคูอื่น ดังรูปที่ 28



รูปที่ 26 ตัวอย่างภาพการดึงคุณลักษณะแบบ LBP ของพื้นผิวออร์จินัลจีจีแคนवास (บนของแท้) (ล่างของปลอม)



รูปที่ 27 ตัวอย่างภาพการดึงคุณลักษณะแบบ LBP ของพื้นผิวจีจีซูพรีมแคนवास (บนของแท้) (ล่างของปลอม)




รูปที่ 28 ตัวอย่างภาพการดึงคุณลักษณะแบบ LBP ของพื้นผิววัสดุอื่น

จากชุดภาพตัวอย่างของวัสดุ โดยใช้วิธี LBP ในการดึงคุณลักษณะสำคัญท้องถิ่นของพื้นผิววัสดุออกมา ภาพพื้นผิววัสดุข้างต้นจะมีคุณลักษณะสำคัญแตกต่างกันออกไปแม้จะเป็นวัสดุประเภทเดียวกันก็ตาม ดังเช่นภาพปกติจะเห็นได้ว่ามนุษย์สามารถมองเห็นความต่างระหว่างของแท้และของปลอมด้วยตาเปล่าได้น้อยมาก แต่เมื่อใช้เทคนิค LBP เข้าไปสกัดคุณลักษณะสำคัญในการเปรียบเทียบพื้นผิววัสดุของแท้ ของปลอม และวัสดุอื่นทำให้ได้ผลลัพธ์ที่เห็นได้ชัด สำหรับพื้นผิววัสดุออริจินัลจีจีแคนวาสเมื่อสังเกตไปยังภาพปกติด้วยตาเปล่าของมนุษย์การเรียงตัวและความหนาของเส้นวัสดุนั้นมีความใกล้เคียงกันอย่างมาก แต่เมื่อสังเกตภาพพื้นผิวที่ผ่านกระบวนการสกัดคุณลักษณะแบบ LBP ผลลัพธ์แสดงให้เห็นถึงการเรียงตัวและขนาดของเส้นวัสดุที่แตกต่างกัน ดังนี้ วัสดุออริจินัลจีจีแคนวาสของแท้จะใช้เส้นวัสดุที่มีความถี่ของเส้นใยผ้าเรียงกันอย่างเป็นระเบียบ แต่สำหรับเส้นวัสดุของปลอมจะมีความถี่การจัดเรียงที่ไม่สม่ำเสมอ อีกหนึ่งวัสดุหลักคือจีจีซูพรีมแคนวาสได้แสดงคุณลักษณะสำคัญของพื้นผิวโดยของแท้จะมีลักษณะพื้นผิวที่ลึกกว่าของปลอม และบริเวณพื้นผิวดัอักซอร์ GG ของแท้จะมีความตื้นกว่าของปลอม ลำดับสุดท้ายคือวัสดุอื่น จะเห็นได้ว่าคุณลักษณะสำคัญของพื้นผิวมีความแตกต่างกับวัสดุ GG Canvas ทั้งสองแบบอย่างชัดเจน จากวิธีการสกัดคุณลักษณะสำคัญข้างต้นจึงเป็นประโยชน์อย่างมากที่จะทำให้แบบจำลองเรียนรู้ได้เห็นคุณลักษณะเพิ่มเติมของวัสดุซึ่งจะช่วยเพิ่มประสิทธิภาพการจำแนกกระเป๋าของแท้ ของปลอม และวัสดุอื่นได้อย่างมีประสิทธิภาพมากยิ่งขึ้น

### 3.4 การออกแบบแบบจำลองในการจำแนกกระเป๋าของแท้ ของปลอม และวัสดุอื่น

ในงานวิจัยนี้เป็นการจำแนกข้อมูลภาพ จากการศึกษาทฤษฎีที่เกี่ยวข้อง โครงข่ายประสาทคอนโวลูชันเป็นหนึ่งในแบบจำลองที่ใช้งานด้านการประมวลผลภาพกับชุดข้อมูลภาพขนาดเล็กไป

จนถึงขนาดใหญ่ได้ดี จึงได้นำโครงข่ายประสาทคอนโวลูชันมาพัฒนา และจากการศึกษาข้อมูลเพิ่มเติม จากงานวิจัยและทฤษฎีที่เกี่ยวข้องเกี่ยวกับการจำแนกข้อมูลภาพ จึงได้นำแบบจำลองโครงข่ายประสาทคอนโวลูชันมาพัฒนาร่วมกับการเรียนรู้ถ่ายโอนจากแบบจำลองที่ถูกฝึกมาแล้วล่วงหน้า (Pretrained Model) ได้แก่ VGG16 และ AlexNet โดยนำ Pretrained Model ข้อดีสำหรับการใช้แบบจำลองที่ถูกฝึกสอนมาแล้วช่วยลดระยะเวลาการเรียนรู้ของแบบจำลอง ขั้นตอนแรกทำการตรึง (Frozen) ชั้นคอนโวลูชันของ Pretrained Model จากนั้นตัดส่วนของชั้น Fully Connected ที่จำแนกออก และเปลี่ยนเป็นชั้น Fully Connected ที่เตรียมการจำแนกกระเป๋าแท้ ปลอม และอื่นๆ เข้าไปแทน โดยมีการใช้ Pretrained Weight ของ ImageNet ร่วมกัน หลังจากนั้นเพิ่มฟังก์ชันกระตุ้นสำหรับการจำแนกประเภท คือ ฟังก์ชันค่าสูงสุดอย่างอ่อน (Softmax Function) ในชั้น Fully Connected โดยมีโครงสร้างแบบจำลองดังรูปที่ 29



รูปที่ 29 โครงสร้างแบบจำลองโครงข่ายประสาทคอนโวลูชันร่วมกับการเรียนรู้การถ่ายโอน

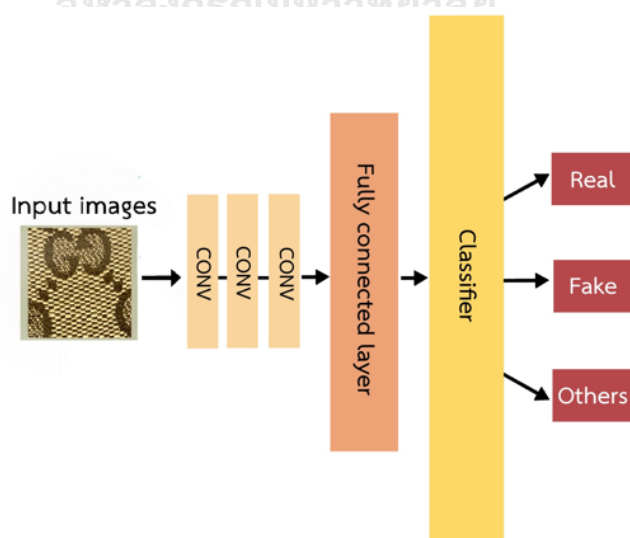
### 3.5 กระบวนการจำแนกกระเป๋าของแท้ ของปลอม และวัสดุอื่น ของแบบจำลอง

การออกแบบกระบวนการจำแนกกระเป๋าจะแบ่งออกเป็น 2 แบบเพื่อเปรียบเทียบประสิทธิภาพระหว่างการใช้แบบจำลองพื้นฐาน (Base Model) และ วิธีการแบบใหม่คือแบบจำลองพื้นฐานร่วมกับการสกัดคุณลักษณะท้องถิ่นแบบ LBP โดยมีข้อกำหนด Input Images ของผู้ใช้งาน ระบบแสดงเพิ่มเติมดัง ภาคผนวก ก

#### 3.5.1 กระบวนการของแบบจำลองพื้นฐาน (Base Model)

ในงานวิจัยนี้ได้เลือกแบบจำลองพื้นฐานทั้งหมด 3 แบบจำลอง ได้แก่ โครงข่ายประสาทคอนโวลูชัน โครงข่ายประสาทคอนโวลูชันแบบบีวีจีจี16 และ โครงข่ายประสาทแบบเดนส์เน็ต121 โดยทำการปรับแต่งชั้น Fully Connected ดังอธิบายในข้างต้น โดยมีกระบวนการทำงานดังนี้

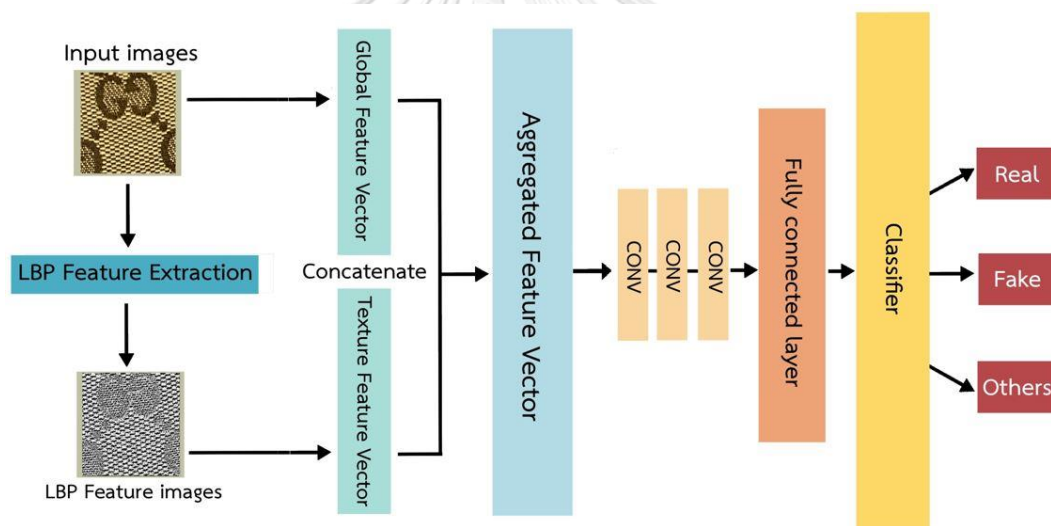
นำข้อมูลภาพตั้งต้นที่ผ่านกระบวนการ Data Cleaning ทั้งหมด 2500 ภาพโดยแบ่งเป็นชุดข้อมูลฝึกสอน (Train Dataset) ชุดข้อมูลทดสอบ (Test Dataset) และชุดข้อมูลตรวจสอบ (Validation Dataset) เข้าสู่แบบจำลอง โดยผ่านชั้นคอนโวลูชันประกอบด้วย 3 ชั้นย่อย ได้แก่ ชั้นคอนโวลูชัน ชั้นพูลลิง และชั้นกระตุ้น เพื่อสกัดคุณลักษณะข้อมูลภาพที่นำเข้ามา สำหรับชั้นคอนโวลูชันสุดท้ายจะถูกส่งเข้าชั้นแผ่ออก (Flatten Layer) เพื่อแปลงเป็นเวกเตอร์ที่สามารถป้อนเข้าสู่ชั้นเชื่อมต่อแบบทั่วถึง (Fully Connected Layer) ของโครงข่ายประสาทคอนโวลูชันเพื่อจำแนกโดยใช้ฟังก์ชันกระตุ้น Softmax เพื่อจำแนกประเภทกระเป๋าของแท้ ของปลอม และวัสดุอื่น ดังรูปที่ 30



รูปที่ 30 กระบวนการของแบบจำลองพื้นฐาน (Base model)

### 3.5.2 กระบวนการของแบบจำลองพื้นฐานร่วมกับการสกัดคุณลักษณะท้องถิ่นแบบ LBP

การสร้างแบบจำลองพื้นฐานร่วมกับการสกัดคุณลักษณะท้องถิ่นแบบ LBP ที่นำมาประยุกต์ใช้กับชุดข้อมูลภาพพื้นผิววัสดุกระเป๋า มีกระบวนการทำงานดังนี้ ขั้นแรกนำรูปภาพนำเข้า (Input Images) เข้าสู่กระบวนการสกัดคุณลักษณะสำคัญพื้นผิวภาพแบบ LBP (LBP Feature Extraction) จะได้ผลลัพธ์ภาพไบนารีแสดงอยู่ในรูปแบบขาวดำ (LBP Feature Images) แต่เนื่องจากภาพไบนารีแสดงอยู่ในขนาดอาร์เรย์ 2 มิติจึงต้องทำการแปลงภาพรูปแบบขาวดำไปเป็นขนาดอาร์เรย์ 3 มิติ ให้อยู่ในรูปแบบ Texture Feature Vector และใช้คำสั่ง Concatenate ในการต่อ Global Feature Vector กับ Texture Feature Vector เพื่อทำการรวมเวกเตอร์คุณลักษณะ (Aggregated Feature Vector) จากนั้นข้อมูลเวกเตอร์จะถูกส่งต่อไปยังแบบจำลองเพื่อจำแนกกระเป๋าของแท้ ของปลอม และวัสดุอื่น ดังรูปที่ 31



รูปที่ 31 กระบวนการของแบบจำลองพื้นฐานร่วมกับการสกัดคุณลักษณะท้องถิ่นแบบ LBP

### 3.6 การประเมินสมรรถนะแบบจำลอง

ตัววัดในการประเมินสมรรถนะแบบจำลองโครงข่ายประสาทคอนโวลูชันสำหรับการตรวจสอบภาพกระเป๋า Gucci GG Canvas ของแท้ ของปลอม และวัสดุอื่นนั้น ใช้ค่าความแม่นยำ (Accuracy) สามารถคำนวณได้จากสมการที่ 4 และตัววัดสำหรับการจำแนกคือ Confusion Matrix แบบ Multi Class [22] ดังแสดงในตารางที่ 4 ซึ่งอ้างอิงจากราย Confusion Matrix แบบ Binary ดังแสดงในตารางที่ 3 ค่าความเที่ยงตรง (Precision) สามารถคำนวณได้จากสมการที่ 5 ค่าความ

ครบถ้วน (Recall) สามารถคำนวณได้จากสมการที่ 6 และ ค่าเอฟวัน (F1-score) สามารถคำนวณได้จากสมการที่ 7

- 1) ค่าความแม่นยำ (Accuracy)

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (4)$$

- 2) ค่าความเที่ยงตรง (Precision)

$$Precision = \frac{TP}{TP + FP} \quad (5)$$

- 3) ค่าความครบถ้วน (Recall)

$$Recall = \frac{TP}{TP + FN} \quad (6)$$

- 4) ค่าเอฟวัน (F1-score)

$$F1 - score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (7)$$

โดย True Positive (TP) คือ ผลลัพธ์ที่แบบจำลองทำนายภาพกระเป๋าของแท้ได้อย่างถูกต้อง  
True Negative (TN) คือ ผลลัพธ์ที่แบบจำลองทำนายกระเป๋าปลอมได้อย่างถูกต้อง  
False Positive (FP) คือ ผลลัพธ์ที่แบบจำลองทำนายภาพกระเป๋าของแท้เป็นเท็จ  
False Negative (FN) คือ ผลลัพธ์ที่แบบจำลองทำนายภาพกระเป๋าปลอมเป็นเท็จ

เนื่องจากชุดข้อมูลที่ใช้เป็นชุดข้อมูลที่ไม่สมดุล (imbalance data) โดยวัสดุอื่นมีชุดข้อมูล 500 ภาพซึ่งน้อยกว่าชุดข้อมูลของกระเป๋าแท้และกระเป๋าปลอมที่มีอย่างละ 1000 ภาพ อีกทั้งเพื่อความสำคัญกับทุกคลาสเท่าๆ กันโดยไม่คำนึงว่าแต่ละคลาสจะมีจำนวนข้อมูลมากน้อยเพียงใดจึงเลือกใช้การวัดผลแบบ Macro average ในการคำนวณเพื่อทำให้ค่าเฉลี่ยของน้ำหนักแต่ละคลาสเท่ากัน และให้มั่นใจว่าการวัดผลมีความสมดุล ซึ่งค่าความเที่ยงตรงแบบมาโคร (Macro-Precision) สามารถคำนวณได้จากสมการที่ 8 ค่าความครบถ้วนแบบมาโคร (Macro-Recall) สามารถคำนวณได้จากสมการที่ 9 และค่าเอฟวันแบบมาโคร (Macro-F1-score) สามารถคำนวณได้จากสมการที่ 10 ดังนี้

- 1) ค่าความเที่ยงตรงแบบมาโคร (Macro-Precision)

$$Macro - Precision = \frac{Precision_1 + Precision_2 + Precision_3}{3} \quad (8)$$

- 2) ค่าความครบถ้วนแบบมาโคร (Macro-Recall)

$$Macro - Recall = \frac{Recall_1 + Recall_2 + Recall_3}{3} \quad (9)$$



3) ค่าเอฟวันแบบมาโคร (Macro-F1-score)

$$\text{Macro - F1 - score} = 2 \times \frac{\text{Macro - Precision} \times \text{Macro - Recall}}{\text{Macro - Precision} + \text{Macro - Recall}} \quad (10)$$

ตารางที่ 3 Confusion Matrix แบบ Binary สำหรับกระเป๋า Gucci GG Canvas ของแท้และของปลอม

		ผลการทำนาย	
		กระเป๋า Gucci GG Canvas ของปลอม	กระเป๋า Gucci GG Canvas ของแท้
แท้จริง	กระเป๋า Gucci GG Canvas ของปลอม	True Negative (TN)	False Positive (FP)
	กระเป๋า Gucci GG Canvas ของแท้	False Negative (FN)	True Positive (TP)

ส่วนตาราง Confusion Matrix แบบ Multi Class การจะหา TP, TN, FP, FN จะต้องหาแยกแต่ละ Class ถ้าจะหาประเภทกระเป๋า Gucci GG Canvas ของปลอม ผลลัพธ์ที่ได้จะเป็นดังตารางที่ 4 ประเภทกระเป๋า Gucci GG Canvas ของแท้จะเป็น ดังตารางที่ 5 และกระเป๋า Gucci วัสดุอื่นจะเป็น ดังตารางที่ 6

ตารางที่ 4 Confusion Matrix แบบ Multi Class สำหรับกระเป๋า Gucci GG Canvas ของปลอม

		ผลการทำนาย		
		กระเป๋า Gucci GG Canvas ของปลอม	กระเป๋า Gucci GG Canvas ของแท้	กระเป๋า Gucci วัสดุอื่น
แท้จริง	กระเป๋า Gucci GG Canvas ของปลอม	TP	FN	FN
	กระเป๋า Gucci GG Canvas ของแท้	FP	TN	TN
	กระเป๋า Gucci วัสดุอื่น	FP	TN	TN

ตารางที่ 5 Confusion Matrix แบบ Multi Class สำหรับกระเป๋า Gucci GG Canvas ของแท้

		ผลการทำนาย		
		กระเป๋า Gucci GG Canvas ของปลอม	กระเป๋า Gucci GG Canvas ของแท้	กระเป๋า Gucci วัสดุอื่น
แท้จริง	กระเป๋า Gucci GG Canvas ของปลอม	TN	FP	TN
	กระเป๋า Gucci GG Canvas ของแท้	FN	TP	FN
	กระเป๋า Gucci วัสดุอื่น	TN	FP	TN


ตารางที่ 6 Confusion Matrix แบบ Multi Class สำหรับกระเป๋า Gucci วัสดุอื่น

		ผลการทำนาย		
		กระเป๋า Gucci GG Canvas ของปลอม	กระเป๋า Gucci GG Canvas ของแท้	กระเป๋า Gucci วัสดุอื่น
แท้จริง	กระเป๋า Gucci GG Canvas ของปลอม	TN	TN	FP
	กระเป๋า Gucci GG Canvas ของแท้	TN	TN	FP
	กระเป๋า Gucci วัสดุอื่น	FN	FN	TP

### Stratified K-Fold Cross Validation

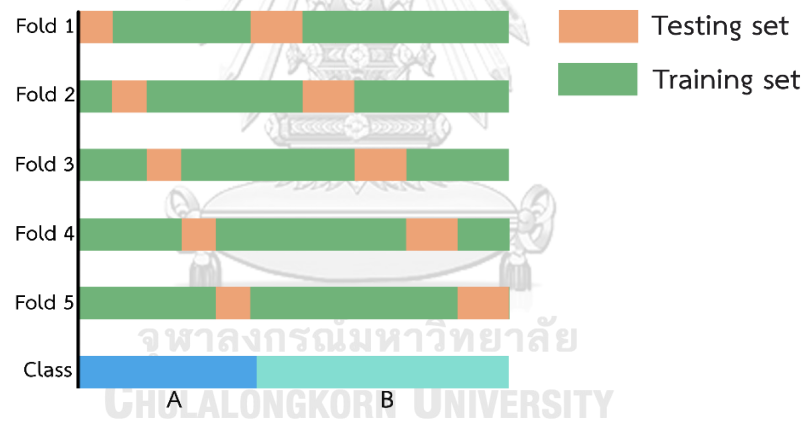
การใช้ K-Fold Cross Validation เพื่อช่วยลด Bias ในการแบ่งชุดข้อมูลของแบบจำลอง โดยจะแบ่งเป็น 5 ส่วน (K=5) ซึ่งข้อมูลจะถูกแบ่งย่อยเป็น 2 ส่วนคือ ชุดข้อมูลทดสอบ และชุดข้อมูลฝึกสอนทำการวนทดสอบในแต่ละ Fold เป็นจำนวน 10 Epochs จากนั้นนำผลสมรรถนะแบบจำลองมาเฉลี่ย โดยการแบ่งข้อมูลแบบ K-Fold Cross Validation อาจทำให้เกิด Bias ของ Class ในการแบ่งของชุดข้อมูล ดังรูปที่ 32 จึงได้นำ Stratified K-Fold Cross Validation มาแก้ปัญหาในการแบ่งข้อมูลในแต่ละคลาสที่ไม่เท่ากัน โดยจะแบ่งเป็น 5 ส่วนที่มีแต่ละคลาสเท่ากันในแต่ละรอบของการวนทดสอบ ดังรูปที่ 33

## KFold



รูปที่ 32 การแบ่งข้อมูลแบบ K-Fold Cross Validation (K=5)

## StratifiedKFold



รูปที่ 33 การแบ่งข้อมูลแบบ Stratified K-Fold Cross Validation (K=5)

## บทที่ 4

### การทดลองและผลการทดลอง

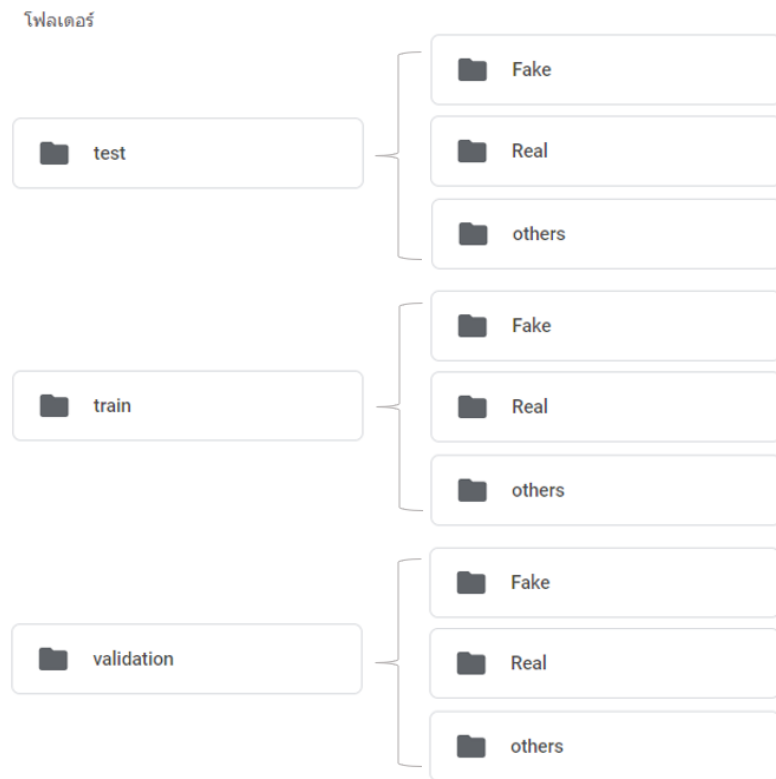
#### 4.1 สภาพแวดล้อมที่ใช้ในการทดลอง

ใช้ Google Colaboratory Pro คือ jupyter notebook ที่ทำงานอยู่บน Cloud ของ Google ซึ่งจะใช้ประโยชน์จากประสิทธิภาพของ hardware จาก Google โดยใช้ Graphic Processing Unit (GPU) เป็นหน่วยประมวลผลกราฟิกช่วยในการประมวลผลและคำนวณซึ่งสามารถใช้หน่วยความจำแรมขนาด 25 กิกะไบต์ในการทำงานภาษาที่ใช้เขียนคือภาษา Python ร่วมกับการใช้ไลบรารีจาก numpy, pandas, matplotlib, OpenCV, Pillow, scikit-image, Keras และ scikit-learn

#### 4.2 การเตรียมชุดข้อมูลที่ใช้ในการทดลอง


ขั้นตอนแรกทำการแบ่งโฟลเดอร์ชุดข้อมูลออกเป็นสามส่วน ได้แก่ ชุดข้อมูลฝึกสอน (Train Dataset) ชุดข้อมูลทดสอบ (Test Dataset) และชุดข้อมูลตรวจสอบ (Validation Dataset) ซึ่งในแต่ละโฟลเดอร์จะประกอบด้วยชุดข้อมูลภาพทั้งสามประเภท ได้แก่ Fake Real และ Others ตามสัดส่วนชุดข้อมูลที่กำหนดไว้ จากนั้นอัปโหลดชุดข้อมูลภาพกระเป๋า Gucci ทั้งหมดไปยัง Google Drive โดยใช้ชื่อโฟลเดอร์ Thesis\_Gucci\_bag ดังรูปที่ 34

ไดรฟ์ของฉัน > Thesis\_Gucci\_bag ▾




รูปที่ 34 โครงสร้างโฟลเดอร์ชุดข้อมูลที่ใช้ในการจำแนกกระเป๋า Gucci GG Canvas ของแท้ ของปลอม และวัสดุอื่น

สำหรับชุดข้อมูลกระเป๋า Gucci GG Canvas ของแท้บันทึกไว้ในโฟลเดอร์ที่มีชื่อว่า Real อยู่ในไดเรกทอรี ~/My Drive/Thesis\_Gucci\_bag/train/Real ดังรูปที่ 35




รูปที่ 35 ตัวอย่างภาพกระเป๋าแท้ Gucci GG Canvas ในชุดข้อมูลฝึกสอนบน Google Drive

สำหรับชุดข้อมูลกระเป๋า Gucci GG Canvas ของปลอมบันทึกไว้ในโฟลเดอร์ที่มีชื่อว่า Fake อยู่ในไดเรกทอรี ~/My Drive/Thesis\_Gucci\_bag/train/Fake ดังรูปที่ 36



รูปที่ 36 ตัวอย่างภาพกระเป๋าปลอม Gucci GG Canvas ในชุดข้อมูลฝึกสอนบน Google Drive และสำหรับชุดข้อมูลกระเป๋า Gucci วัสดุอื่นบันทึกไว้ในโฟลเดอร์ที่มีชื่อว่า others อยู่ในไดเรกทอรี ~/My Drive/Thesis\_Gucci\_bag/train/others ดังรูปที่ 37



รูปที่ 37 ตัวอย่างภาพกระเป๋า Gucci วัสดุอื่นในชุดข้อมูลฝึกสอนบน Google Drive

ขั้นตอนแรกทำการ Mount Drive เพื่อนำข้อมูลจาก Google Drive มาใช้งานใน Google Colab โดยใช้คำสั่ง `drive.mount('/content/drive')` จากไลบรารี `Google.colab` และกำหนดไดเรกทอรีของ Drive ด้วยคำสั่ง `%cd /content/drive/My Drive` ดังรูปที่ 38

```

▶ from google.colab import drive
drive.mount('/content/drive')

#Path : /content/drive/My Drive
%cd /content/drive/My Drive

Mounted at /content/drive
/content/drive/My Drive

```

รูปที่ 38 ชุดคำสั่งในการเชื่อมต่อชุดข้อมูลจาก Google Drive กับ Google Colab

กำหนดไต่แรกทอรีของชุดข้อมูลฝึกสอน (Train Dataset) ชุดข้อมูลตรวจสอบ (Validation Dataset) และชุดข้อมูลทดสอบ (Test Dataset) ของแต่ละโพลเดอร์ได้แก่ train, validation และ test ตามลำดับที่แยกระหว่างภาพกระเป๋า Gucci GG Canvas ของแท้ที่อยู่ในไต่แรกทอรีที่ชื่อว่า Real ส่วนภาพกระเป๋า Gucci GG Canvas ของปลอมอยู่ในไต่แรกทอรี ที่ชื่อว่า Fake และภาพกระเป๋า Gucci วัสดุอื่นอยู่ในไต่แรกทอรี ที่ชื่อว่า others ดังรูปที่ 39

```

base_dir = os.getcwd() + '/Thesis_Gucci_bag'
train_dir = os.path.join(base_dir, 'train')
validation_dir = os.path.join(base_dir, 'validation')
test_dir = os.path.join(base_dir, 'test')

# Directory training real pictures
train_real_dir = os.path.join(train_dir, 'Real')

# Directory training fake pictures
train_fake_dir = os.path.join(train_dir, 'Fake')

# Directory training other pictures
train_others_dir = os.path.join(train_dir, 'others')

# Directory validation real pictures
validation_real_dir = os.path.join(validation_dir, 'Real')

# Directory validation fake pictures
validation_fake_dir = os.path.join(validation_dir, 'Fake')

# Directory validation other pictures
validation_others_dir = os.path.join(validation_dir, 'others')

# Directory test real pictures
test_real_dir = os.path.join(test_dir, 'Real')

# Directory test fake pictures
test_fake_dir = os.path.join(test_dir, 'Fake')

# Directory test other pictures
test_others_dir = os.path.join(test_dir, 'others')

```

รูปที่ 39 ชุดคำสั่งการกำหนดไต่แรกทอรีของชุดข้อมูลฝึกสอน ข้อมูลตรวจสอบ และข้อมูลทดสอบ



ทำการเพิ่มจำนวนชุดข้อมูลฝึกสอน (Training Dataset) เพื่อลดปัญหา Overfitting ที่อาจเกิดขึ้นได้จึงเพิ่มข้อมูลภาพในหลายมุมมองให้แก่แบบจำลอง โดยใช้ไลบรารีของ PIL ด้วยคำสั่ง `.transpose(Image.FLIP_LEFT_RIGHT).transpose(Image.FLIP_TOP_BOTTOM)` เพื่อทำการพลิกภาพแนวอนรวมกับการพลิกภาพแนวตั้ง ทำให้ได้ชุดข้อมูลฝึกสอนเพิ่มขึ้นเป็น 2 เท่าจากเดิม ดังรูปที่ 40 และ สร้างฟังก์ชันสำหรับการหมุนภาพตั้งฉาก (Orthogonal) โดยการใช้การพลิกภาพ ด้านซ้าย 90 องศา และด้านขวา 90 องศา ด้วยชุดคำสั่ง `np.rot90` ดังรูปที่ 41

```
from PIL import Image
import PIL

# Directory training real pictures
train_real_dir = os.path.join(train_dir, 'Real')

# Directory training fake pictures
train_fake_dir = os.path.join(train_dir, 'Fake')

path = os.path.join(base_dir, 'Real_flip')

for file in os.listdir(train_real_dir):
    img = Image.open(train_real_dir + "/" + file)
    img.transpose(Image.FLIP_LEFT_RIGHT).transpose(Image.FLIP_TOP_BOTTOM).save(path + file, "JPEG")

path2 = os.path.join(base_dir, 'Fake_flip')

for file in os.listdir(train_fake_dir):
    img = Image.open(train_fake_dir + "/" + file)
    img.transpose(Image.FLIP_LEFT_RIGHT).transpose(Image.FLIP_TOP_BOTTOM).save(path2 + file, "JPEG")
```

รูปที่ 40 ชุดคำสั่งการพลิกภาพแนวอนรวมกับแนวตั้งของชุดข้อมูลฝึกสอน

```
def orthogonal_rot(image):
    return np.rot90(image, np.random.choice([-1, 0, 1]))
```

รูปที่ 41 ชุดคำสั่งการหมุนภาพของชุดข้อมูลฝึกสอน

กำหนดขนาดพารามิเตอร์ของรูปภาพ  $224 \times 224 \times 3$  และจำนวน Batch Size เท่ากับ 10 จากนั้นทำการ Normalized ข้อมูลของรูปภาพสี RGB ที่มีช่วงระหว่าง 0 – 255 ให้อยู่ในช่วง 0 -1 ด้วยคำสั่ง `ImageDataGenerator(rescale=1./255)` สำหรับ ชุดข้อมูลฝึกสอน (Training- Dataset) ชุดข้อมูลตรวจสอบ (Validation Dataset) และชุดข้อมูลทดสอบ (Test Dataset) ดังรูปที่ 42

```

#Parameters
IMG_SIZE = 224
BATCH = 10

# Adding rescale, rotate 90 degree
train_datagen = ImageDataGenerator(rescale=1./255, preprocessing_function = orthogonal_rot)

# Validation and test data rescale
val_datagen = ImageDataGenerator(rescale=1./255)
test_datagen = ImageDataGenerator(rescale=1./255)

#training images in batches
train_generator = train_datagen.flow_from_directory(train_dir,
                                                    target_size=(IMG_SIZE, IMG_SIZE),
                                                    batch_size=BATCH,
                                                    class_mode = "categorical")

#validation images in batches
validation_generator = val_datagen.flow_from_directory(validation_dir,
                                                       target_size=(IMG_SIZE, IMG_SIZE),
                                                       batch_size=BATCH,
                                                       class_mode = "categorical")

#test images in batches
test_generator = test_datagen.flow_from_directory(test_dir,
                                                  target_size=(IMG_SIZE, IMG_SIZE),
                                                  batch_size=BATCH,
                                                  class_mode = "categorical", shuffle = False)

```

รูปที่ 42 ชุดคำสั่งการเพิ่มจำนวนข้อมูลสำหรับชุดข้อมูลที่ใช้ในการทดลอง

#### 4.3 การดึงคุณลักษณะสำคัญของภาพ

ทำการ Import ไลบรารีของ skimage เพื่อสกัดคุณลักษณะท้องถิ่นด้วยเทคนิค Local Binary Pattern ของชุดข้อมูลภาพด้วยชุดคำสั่ง ดังรูปที่ 43

```

import cv2
import os
from skimage import feature

for file in os.listdir(train_dir_com1):
    img = cv2.imread(train_dir_com1 + "\\\" + file,0)
    lbp = feature.local_binary_pattern(img,8,1,"default")
    img2 = cv2.imwrite(path + "\\\" + "lbp_" + file, lbp)

```

รูปที่ 43 ชุดคำสั่งการดึงคุณลักษณะสำคัญด้วยเทคนิค Local Binary Pattern

ผลลัพธ์จากการแปลงภาพ LBP จะอยู่ในขนาดอาร์เรย์ 2 มิติ จึงต้องทำการแปลงมิติของภาพ LBP ให้อยู่ในมิติเดียวกับภาพตั้งต้น RGB ขนาดอาร์เรย์ 3 มิติ เพื่อทำการรวม Feature Vector เข้าด้วยกันโดยใช้ชุดคำสั่ง Concatenate ดังรูปที่ 44

```

for file in sorted(os.listdir(train_dir_com1)):
    lbp = cv2.imread(train_dir_com1 + "\\\" + "lbp_" + file)
    lbp1 = cv2.cvtColor(lbp, cv2.COLOR_GRAY2RGB)
    img2 = cv2.imread(train_dir_com1 + "\\\" + file, 1)
    img_co = np.concatenate((lbp1, img2), axis=1)
    img2 = cv2.imwrite(path + "\\\" + "lbp_co_" + file, img_co)

```

รูปที่ 44 ชุดคำสั่งการรวมคุณลักษณะภาพ

#### 4.4 การสร้างแบบจำลอง

สร้างแบบจำลองทั้งหมด 3 แบบ ดังนี้ แบบจำลองแรกเป็นการสร้างแบบจำลองโครงข่ายประสาทคอนโวลูชันที่ฝึกสอนใหม่ตั้งแต่เริ่มต้น (CNN from scratch) ซึ่งจะนำไปพัฒนาต่อเป็นแบบจำลองที่สองโดยการนำแบบจำลองโครงข่ายประสาทคอนโวลูชันร่วมกับแบบจำลองการเรียนรู้ถ่ายโอนของ VGG16 และ แบบจำลองสุดท้ายเป็นการนำแบบจำลองโครงข่ายประสาทคอนโวลูชันร่วมกับแบบจำลองการเรียนรู้ถ่ายโอนของ DenseNet121

##### 4.4.1 โครงข่ายประสาทคอนโวลูชัน (Convolutional Neural Network–CNN)

แบบจำลองโครงข่ายประสาทคอนโวลูชันประกอบด้วย 3 ชั้นคอนโวลูชัน (Conv Layer) แต่ละชั้นของ คอนโวลูชันมี 16, 32 และ 64 layer รับข้อมูลนำเข้าขนาด  $224 \times 224 \times 3$  ใช้ขนาดตัวกรอง (Filter)  $3 \times 3$  และใช้ชั้นการรวมที่มีค่ามากที่สุด (Max Pooling Layer) มีขนาด  $2 \times 2$  จำนวน 3 ชั้น กำหนดค่าสไตรด์ (Stride) เท่ากับ 1 ในการเลื่อนแต่ละพิกเซลมีฟังก์ชันกระตุ้น (Activation Function) ที่ใช้ในแต่ละชั้นคือ Relu Function ผ่านการทำ Flatten เปลี่ยนข้อมูลให้เป็นเวกเตอร์ขนาด 1 มิติ และส่งเข้าชั้น Dense ขนาด 1024 ซึ่งในชั้นสุดท้ายที่เป็น Fully Connected Layer จะใช้ฟังก์ชันกระตุ้นเป็น Softmax Function ดังรูปที่ 45 ซึ่งเป็นขั้นที่ไว้ทำนายภาพกระเป๋าของแท้ กระเป๋าของปลอม และวัสดุอื่น

```


img_input = layers.Input(shape=(IMG_SIZE, IMG_SIZE, DIM_SIZE))

# First convolution extracts 16 filters that are 3x3
# Convolution is followed by max-pooling layer with a 2x2 window
x = layers.Conv2D(16, 3, activation='relu')(img_input)
x = layers.MaxPooling2D(2)(x)

# Second convolution extracts 32 filters that are 3x3
# Convolution is followed by max-pooling layer with a 2x2 window
x = layers.Conv2D(32, 3, activation='relu')(x)
x = layers.MaxPooling2D(2)(x)

# Third convolution extracts 64 filters that are 3x3
# Convolution is followed by max-pooling layer with a 2x2 window
x = layers.Conv2D(64, 3, activation='relu')(x)
x = layers.MaxPooling2D(2)(x)

# Flatten feature map to a 1-dim tensor so we can add fully connected layers
x = layers.Flatten()(x)

# Create a fully connected layer with ReLU activation and 1024 hidden units
x = layers.Dense(1024, activation='relu')(x)

# Create output layer with 3 node and softmax activation
output = layers.Dense(3, activation='softmax')(x)

# Create model:
cnn_model = Model(img_input, output)

```

#### รูปที่ 45 ชุดคำสั่งการสร้างของแบบจำลองโครงข่ายประสาทคอนโวลูชัน

หลังจากการปรับแต่งโครงสร้างแบบจำลองให้เหมาะสมกับการจำแนกกระเป๋าของแท้ ของปลอม และวัสดุอื่น จะได้โครงสร้างแบบจำลองโครงข่ายประสาทคอนโวลูชัน ดังรูปที่ 46

Model: "model"

Layer (type)	Output Shape	Param #
input_1 (InputLayer)	[(None, 224, 224, 3)]	0
conv2d (Conv2D)	(None, 222, 222, 16)	448
max_pooling2d (MaxPooling2D)	(None, 111, 111, 16)	0
conv2d_1 (Conv2D)	(None, 109, 109, 32)	4640
max_pooling2d_1 (MaxPooling2D)	(None, 54, 54, 32)	0
conv2d_2 (Conv2D)	(None, 52, 52, 64)	18496
max_pooling2d_2 (MaxPooling2D)	(None, 26, 26, 64)	0
flatten (Flatten)	(None, 43264)	0
dense (Dense)	(None, 1024)	44303360
dense_1 (Dense)	(None, 3)	3075

=====  
 Total params: 44,330,019  
 Trainable params: 44,330,019  
 Non-trainable params: 0

รูปที่ 46 โครงสร้างของแบบจำลองโครงข่ายประสาทคอนโวลูชัน

#### 4.4.2 โครงข่ายประสาทคอนโวลูชันแบบวีจีจี 16 (VGG-16)

สร้างแบบจำลอง วีจีจี-16 ด้วยการนำเข้าไลบรารีจาก Keras โดยจะนำเข้าข้อมูลขนาด 224 x 224 x 3 ตามขนาดตั้งต้นของแบบจำลองวีจีจี-16 จากนั้นตัดชั้น Fully connected layer ออกโดยใช้คำสั่ง `include_top = False` และนำค่า Weight ของ ImageNet ที่ผ่านการเรียนรู้ล่วงหน้าโดยทำการตรึงค่า (Freeze) ของชั้นคอนโวลูชันก่อนหน้าไว้เพื่อให้ไม่ฝึกสอนซ้ำด้วยคำสั่ง `trainable = False` โดยชั้นสุดท้ายจะใช้แบบจำลองโครงข่ายประสาทคอนโวลูชันมาเชื่อมต่อซึ่งจะทำการ Flatten เปลี่ยนข้อมูลให้เป็นเวกเตอร์ขนาด 1 มิติ และส่งเข้าชั้น Dense ขนาด 1024 ซึ่งในชั้นนี้จะใช้ฟังก์ชันกระตุ้นเป็น Relu Function และชั้นสุดท้าย Fully Connected Layer จะใช้ฟังก์ชันกระตุ้นเป็น Softmax Function โดยชุดคำสั่งการสร้างแบบจำลอง วีจีจี-16 จะแสดงดังรูปที่ 47

```

from tensorflow.keras.applications.vgg16 import VGG16

# base model with pre-trained weights.
pretrained_model = VGG16(input_shape=(IMG_SIZE, IMG_SIZE, DIM_SIZE),
                        include_top = False,
                        weights= "imagenet")

# freeze base model.
for layer in pretrained_model.layers:
    layer.trainable = False

# add new model on top.
pt_output = pretrained_model.output

# flatten the output layer to 1 dimension
x = layers.Flatten()(pt_output)
# add a fully connected layer with 1024 hidden units and ReLU activation
x = layers.Dense(1024, activation='relu')(x)
# add softmax activation for classification
x = layers.Dense(3, activation='softmax')(x)

vgg16_model = Model(pretrained_model.input, x)

```

รูปที่ 47 ชุดคำสั่งการสร้างของแบบจำลองการเรียนรู้แบบถ่ายโอนแบบวีจีจี 16


หลังจากการปรับแต่งโครงสร้างแบบจำลองให้เหมาะสมกับการจำแนกกระเป๋าของแท้ ของปลอม และ  
วัสดุอื่นจะได้โครงสร้างแบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวีจีจี 16 ดังรูปที่ 48

Layer (type)	Output Shape	Param #
input_2 (InputLayer)	[(None, 224, 224, 3)]	0
block1_conv1 (Conv2D)	(None, 224, 224, 64)	1792
block1_conv2 (Conv2D)	(None, 224, 224, 64)	36928
block1_pool (MaxPooling2D)	(None, 112, 112, 64)	0
block2_conv1 (Conv2D)	(None, 112, 112, 128)	73856
block2_conv2 (Conv2D)	(None, 112, 112, 128)	147584
block2_pool (MaxPooling2D)	(None, 56, 56, 128)	0
block3_conv1 (Conv2D)	(None, 56, 56, 256)	295168
block3_conv2 (Conv2D)	(None, 56, 56, 256)	590080
block3_conv3 (Conv2D)	(None, 56, 56, 256)	590080
block3_pool (MaxPooling2D)	(None, 28, 28, 256)	0
block4_conv1 (Conv2D)	(None, 28, 28, 512)	1180160
block4_conv2 (Conv2D)	(None, 28, 28, 512)	2359808
block4_conv3 (Conv2D)	(None, 28, 28, 512)	2359808
block4_pool (MaxPooling2D)	(None, 14, 14, 512)	0
block5_conv1 (Conv2D)	(None, 14, 14, 512)	2359808
block5_conv2 (Conv2D)	(None, 14, 14, 512)	2359808
block5_conv3 (Conv2D)	(None, 14, 14, 512)	2359808
block5_pool (MaxPooling2D)	(None, 7, 7, 512)	0
flatten_1 (Flatten)	(None, 25088)	0
dense_2 (Dense)	(None, 1024)	25691136
dense_3 (Dense)	(None, 3)	3075
=====		
Total params: 40,408,899		
Trainable params: 25,694,211		
Non-trainable params: 14,714,688		

รูปที่ 48 โครงสร้างแบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวีจีจี 16

### 4.4.3 โครงข่ายประสาทแบบ DenseNet 121

สร้างแบบจำลองการเรียนรู้แบบถ่ายโอนจาก เดนซ์เน็ต121 (DenseNet121) ด้วยการนำเข้าไลบรารีจาก Keras โดยจะนำเข้าข้อมูลขนาด  $224 \times 224 \times 3$  จากนั้นตัดชั้น Fully connected layer ออกโดยใช้คำสั่ง `include_top = False` และนำค่า Weight ของ ImageNet ที่ได้ผ่านการเรียนรู้ล่วงหน้า โดยทำการตรึงค่า (Freeze) ของชั้นคอนโวลูชันก่อนหน้านี้ไว้เพื่อให้ไม่ฝึกสอนซ้ำด้วยคำสั่ง `trainable = False` โดยชั้นสุดท้ายจะใช้แบบจำลองโครงข่ายประสาทคอนโวลูชันมาเชื่อมต่อซึ่งจะทำการ Flatten เปลี่ยนข้อมูลให้เป็นเวกเตอร์ขนาด 1 มิติ และส่งเข้าชั้น Dense ขนาด 1024 ซึ่งในชั้นนี้จะใช้ฟังก์ชันกระตุ้นเป็น Relu Function และชั้นสุดท้าย Fully Connected Layer จะใช้ฟังก์ชันกระตุ้นเป็น Softmax Function โดยชุดคำสั่งการสร้างแบบจำลอง เดนซ์เน็ต121 จะแสดงดังรูปที่ 49



```
from tensorflow.keras.applications.densenet import DenseNet121

# base model with pre-trained weights.
pretrained_model = DenseNet121(input_shape=(IMG_SIZE, IMG_SIZE, DIM_SIZE),
                               include_top = False,
                               weights= "imagenet")

# freeze the base model.
for layer in pretrained_model.layers:
    layer.trainable = False

# create a new model on top.
pt_output = pretrained_model.output


# flatten the output layer to 1 dimension
x = layers.Flatten()(pt_output)
# add a fully connected layer with 1024 hidden units and ReLU activation
x = layers.Dense(1024, activation='relu')(x)
# add softmax activation for classification
x = layers.Dense(3, activation='softmax')(x)

DN121_model = Model(pretrained_model.input, x)
```

รูปที่ 49 ชุดคำสั่งการสร้างของแบบจำลองการเรียนรู้แบบถ่ายโอนแบบเดนซ์เน็ต121

โดยมีโครงสร้างแบบจำลองที่ใช้กับการจำแนกกระเป๋าของแท้ ของปลอม และวัสดุอื่น จะได้โครงสร้างแบบจำลองโครงข่ายประสาทแบบเดนซ์เน็ต121 แสดงดังรูปที่ 50





รูปที่ 50 โครงสร้างแบบจำลองโครงข่ายประสาทแบบเดนซ์เน็ต121

#### 4.5 การฝึกสอนแบบจำลอง

การฝึกสอนแบบจำลอง (Model Training) จะนำแบบจำลองที่สร้างมาฝึกสอนเพื่อทำนายกระเป๋าสตางค์ ของปลอม และวัสดุอื่นโดยมีการเก็บ weight จากค่าความแม่นยำ (Accuracy) ที่ดีที่สุด บันทึกไว้ในไฟล์นามสกุล .h5 ดังรูปที่ 51 จากนั้นทำการฝึกสอนแบบจำลองที่ตั้งค่าพารามิเตอร์การคิดค่า loss แบบ categorical crossentropy ใช้ Adam เป็น Optimizer โดยมีการปรับค่า Learning Rate เป็น 0.01 และ 0.001 เพื่อวัดสมรรถนะแบบจำลองกับค่าความแม่นยำ เมื่อใช้คำสั่ง fit กับแบบจำลองในการฝึกสอนแต่ละรอบ (steps\_per\_epoch) ที่คิดจากการนำชุดข้อมูลฝึกสอนทั้งหมดหารด้วยจำนวน Batch Size ที่กำหนดไว้เท่ากับ 10 จะได้จำนวนการฝึกสอนแต่ละรอบเท่ากับ 160 และ จำนวนการตรวจสอบ (val\_steps\_per\_epoch) เท่ากับ 40 โดยฝึกสอนทั้งหมด 30 Epochs ดังรูปที่ 52 และทำการวัดผลแบบ macro average ของแบบจำลองด้วยชุดคำสั่ง ดังรูปที่ 53

```
checkpoint_callback = ModelCheckpoint(
    result_based_dir + 'best_cnn_model.h5',
    monitor='val_accuracy',
    save_best_only=True,
    mode='max')
```

รูปที่ 51 ชุดคำสั่งการบันทึกค่าน้ำหนักที่ให้ค่าความแม่นยำสูงสุดของแบบจำลองในไฟล์นามสกุล.h5

```

cnn_model.compile( loss='categorical_crossentropy',
                  optimizer = Adam(learning_rate=LR),
                  metrics=['acc'])

history_cnn = cnn_model.fit( train_generator,
                             steps_per_epoch=steps_per_epoch,
                             batch_size = BATCH,
                             epochs = EPOCH,
                             validation_data=validation_generator,
                             validation_steps=val_steps_per_epoch,
                             verbose=2,
                             callbacks = [checkpoint_callback])

```

รูปที่ 52 ชุดคำสั่งการฝึกสอนแบบจำลองด้วยโครงข่ายประสาทคอนโวลูชัน

```

def my_metrics(y_true, y_pred):
    accuracy=accuracy_score(y_true, y_pred)
    precision=precision_score(y_true, y_pred,average='macro')
    recall=recall_score(y_true, y_pred,average='macro')
    f1Score=f1_score(y_true, y_pred,average='macro')
    print("Accuracy : {}".format(accuracy))
    print("Precision : {}".format(precision))
    print("Recall : {}".format(recall))
    print("f1Score : {}".format(f1Score))

    cm=confusion_matrix(y_true, y_pred)
    print(cm)

    return accuracy, precision, recall, f1Score

```

รูปที่ 53 ชุดคำสั่งการวัดผลแบบ macro average

## 4.6 ผลการทดลอง

### 4.6.1 ผลการทดลองของแบบจำลองโครงข่ายประสาทคอนโวลูชัน

การทดลองของแบบจำลองโครงข่ายประสาทคอนโวลูชันได้ปรับค่าพารามิเตอร์ Learning Rate เท่ากับ 0.01 ผลลัพธ์แสดง ดังรูปที่ 54 ให้ค่าความแม่นยำจากการทดสอบ 40%

```

===== Confusion Matrix =====
[[200  0  0]
 [200  0  0]
 [100  0  0]]

===== Classification Report =====
              precision    recall  f1-score   support

     0           0.40         1.00         0.57         200
     1           0.00         0.00         0.00         200
     2           0.00         0.00         0.00         100

 accuracy          0.40         0.40         0.40         500
 macro avg         0.13         0.33         0.19         500
 weighted avg      0.16         0.40         0.23         500

```

รูปที่ 54 ผลลัพธ์การทดสอบแบบจำลองโครงข่ายประสาทคอนโวลูชันที่ Learning Rate เท่ากับ 0.01 รูปแบบ Confusion Matrix และแสดงผลการทำนายด้วย Classification Report

การทดลองของแบบจำลองโครงข่ายประสาทคอนโวลูชันได้ปรับค่าพารามิเตอร์ Learning Rate เท่ากับ 0.001 ผลลัพธ์แสดง ดังรูปที่ 55 ให้ค่าความแม่นยำจากการทดสอบ 87%

```

===== Confusion Matrix =====
[[175  25  0]
 [ 26 170  4]
 [  2  6  92]]

===== Classification Report =====
              precision    recall  f1-score   support

     0           0.86         0.88         0.87         200
     1           0.85         0.85         0.85         200
     2           0.96         0.92         0.94         100

 accuracy          0.87         0.87         0.87         500
 macro avg         0.89         0.88         0.89         500
 weighted avg      0.87         0.87         0.87         500

```

รูปที่ 55 ผลลัพธ์การทดสอบแบบจำลองโครงข่ายประสาทคอนโวลูชันที่ Learning Rate เท่ากับ 0.001 รูปแบบ Confusion Matrix และแสดงผลการทำนายด้วย Classification Report

#### 4.6.2 ผลการทดลองของแบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวีจีจี 16

การทดลองของแบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวีจีจี 16 ได้ปรับค่าพารามิเตอร์ Learning Rate เท่ากับ 0.01 ผลลัพธ์แสดง ดังรูปที่ 56 ให้ค่าความแม่นยำจากการทดสอบ 91%

```

===== Confusion Matrix =====
[[189  10   1]
 [ 29 170   1]
 [  1   2  97]]

===== Classification Report =====
              precision    recall  f1-score   support

     0           0.86       0.94       0.90         200
     1           0.93       0.85       0.89         200
     2           0.98       0.97       0.97         100

 accuracy              0.91         500
 macro avg              0.93         500
 weighted avg           0.91         500

```

รูปที่ 56 ผลลัพธ์การทดสอบแบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวีจีจี 16 ที่ Learning Rate เท่ากับ 0.01 รูปแบบ Confusion Matrix และแสดงผลการทำนายด้วย Classification Report

การทดลองของแบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวีจีจี 16 ได้ปรับค่าพารามิเตอร์ Learning Rate เท่ากับ 0.001 ผลลัพธ์แสดง ดังรูปที่ 57 ให้ค่าความแม่นยำจากการทดสอบ 92%

```

===== Confusion Matrix =====
[[177  22   1]
 [ 13 186   1]
 [  0   2  98]]

===== Classification Report =====
              precision    recall  f1-score   support

     0           0.93       0.89       0.91         200
     1           0.89       0.93       0.91         200
     2           0.98       0.98       0.98         100

 accuracy              0.92         500
 macro avg              0.93         500
 weighted avg           0.92         500

```

รูปที่ 57 ผลลัพธ์การทดสอบแบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวีจีจี 16 ที่ Learning Rate เท่ากับ 0.001 รูปแบบ Confusion Matrix และแสดงผลการทำนายด้วย Classification Report

#### 4.6.3 ผลการทดลองของแบบจำลองโครงข่ายประสาทแบบเดนซ์เน็ต121

การทดลองของแบบจำลองโครงข่ายประสาทแบบเดนซ์เน็ต121 ได้ปรับค่าพารามิเตอร์ Learning Rate เท่ากับ 0.01 ผลลัพธ์แสดง ดังรูปที่ 58 ให้ค่าความแม่นยำจากการทดสอบ 90%

```

===== Confusion Matrix =====
[[181  19   0]
 [   4 195   1]
 [   0  28  72]]

===== Classification Report =====
              precision    recall  f1-score   support

     0           0.98         0.91         0.94         200
     1           0.81         0.97         0.88         200
     2           0.99         0.72         0.83         100

 accuracy                   0.90         500
 macro avg                   0.92         0.87         0.88         500
 weighted avg                 0.91         0.90         0.90         500

```

รูปที่ 58 ผลลัพธ์การทดสอบแบบจำลองโครงข่ายประสาทแบบเดนซ์เน็ต121 ที่ Learning Rate เท่ากับ 0.01 รูปแบบ Confusion Matrix และแสดงผลการทำนายด้วย Classification Report

การทดลองของแบบจำลองโครงข่ายประสาทแบบเดนซ์เน็ต121 ได้ปรับค่าพารามิเตอร์ Learning Rate เท่ากับ 0.001 ผลลัพธ์แสดง ดังรูปที่ 59 ให้ค่าความแม่นยำจากการทดสอบ 92%

```

===== Confusion Matrix =====
[[175  25   0]
 [   3 197   0]
 [   2   9  89]]

===== Classification Report =====
              precision    recall  f1-score   support

     0           0.97         0.88         0.92         200
     1           0.85         0.98         0.91         200
     2           1.00         0.89         0.94         100

 accuracy                   0.92         500
 macro avg                   0.94         0.92         0.93         500
 weighted avg                 0.93         0.92         0.92         500

```

รูปที่ 59 ผลลัพธ์การทดสอบแบบจำลองโครงข่ายประสาทแบบเดนซ์เน็ต121 ที่ Learning Rate เท่ากับ 0.001 รูปแบบ Confusion Matrix และแสดงผลการทำนายด้วย Classification Report

#### 4.6.4 เปรียบเทียบผลการทดลองของแบบจำลองพื้นฐาน

จากผลการทดลองแบบจำลองพื้นฐานทั้งสามแบบที่มีค่าพารามิเตอร์ Learning Rate เท่ากับ 0.01 แบบจำลองโครงข่ายประสาทคอนโวลูชันไม่สามารถจำแนกรูปภาพกระเป๋าได้โดยแสดงผลลัพธ์เป็นกระเป๋าปลอมทั้งหมด จากนั้นจึงได้ทำการทดลองปรับค่าพารามิเตอร์ Learning Rate เท่ากับ 0.001 เพื่อให้แบบจำลองปรับ Weight ได้ละเอียดขึ้น ทำการทดสอบแบบจำลองทั้งหมดอีกครั้งทำให้ได้ผลลัพธ์ดีขึ้นอย่างเห็นได้ชัด ดังนี้ แบบจำลองโครงข่ายประสาทคอนโวลูชันแสดงค่าความแม่นยำเพิ่มขึ้นจาก 40% เป็น 87% แบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวีจีจี 16 แสดงค่าความแม่นยำเพิ่มขึ้นจาก 91% เป็น 92% และแบบจำลองโครงข่ายประสาทแบบเดนซ์เน็ต121 แสดงค่าความแม่นยำเพิ่มขึ้นจาก 90% เป็น 92% ดังแสดงในตารางที่ 7

ตารางที่ 7 สมรรถนะของการทดสอบแบบจำลอง CNN, VGG16 และ DenseNet121

Model	Learning Rate	Macro Average			Accuracy
		Precision	Recall	F1 score	
CNN	0.01	0.13	0.33	0.19	0.40
VGG16		0.93	0.92	0.92	0.91
DenseNet121		0.92	0.87	0.88	0.90
CNN	0.001	0.89	0.88	0.89	0.87
VGG16		0.93	<b>0.93</b>	<b>0.93</b>	<b>0.92</b>
DenseNet121		<b>0.94</b>	0.92	<b>0.93</b>	<b>0.92</b>

#### 4.6.5 เปรียบเทียบผลการทดลองของแบบจำลองพื้นฐานโดยใช้ Stratified 5-Fold Cross Validation

เนื่องจากชุดข้อมูลภาพวัสดุอื่นมีจำนวนน้อยกว่าชุดข้อมูลกระเป๋าของแท้และของปลอมจึงทำให้เกิดข้อมูลไม่สมดุล (Imbalance Data) ดังนั้นเพื่อลดความ Bias ของการแบ่งชุดข้อมูลฝึกสอนกับชุดข้อมูลตรวจสอบ จึงมีการนำ Stratified 5-Fold Cross Validation มาใช้ในการแบ่งชุดข้อมูลสำหรับการฝึกสอนแบบจำลองเป็นจำนวน 10 Epochs โดยใช้ชุดคำสั่ง ดังรูปที่ 60 จากนั้นนำผลลัพธ์สมรรถนะของแบบจำลองทั้งหมดในแต่ละรอบมาหาค่าเฉลี่ย ดังแสดงในตารางที่ 8, 9 และ 10

```

from sklearn.model_selection import StratifiedKFold
skf = StratifiedKFold(n_splits= 5, shuffle=True)
skf.get_n_splits(X, Y)
foldNum=0
scores = []

for i, (train_index, test_index) in enumerate(skf.split(X, Y.argmax(1))):
    foldNum+=1
    print("-----")
    print("Results fold ", foldNum)
    X_train, X_test = X[train_index], X[test_index]
    Y_train, Y_test = Y[train_index], Y[test_index]

    train_datagen = ImageDataGenerator(rescale=1./255, preprocessing_function = orthogonal_rot)
    test_datagen = ImageDataGenerator(rescale=1./255)

    train_generator = train_datagen.flow_from_directory(
        train_path,
        target_size=(IMG_SIZE, IMG_SIZE),
        batch_size=BATCH,
        class_mode='categorical',
        subset='training')

    test_generator = test_datagen.flow_from_directory(
        test_path,
        target_size=(IMG_SIZE, IMG_SIZE),
        batch_size=BATCH,
        class_mode=None,
        shuffle=False)

    history=cnn_model.fit(train_generator,epochs=10,verbose=2)

# evaluate
predictions = cnn_model.predict(test_generator, verbose=1)
yPredictions = np.argmax(predictions, axis=1)
true_classes = test_generator.classes

print("Performance")
testAcc, testPrec, testRec, testFScore, = my_metrics(true_classes, yPredictions)
scores.append([testAcc, testPrec, testRec, testFScore])

```

รูปที่ 60 ตัวอย่างชุดคำสั่งการใช้ Stratified 5-Fold Cross Validation  
ของแบบจำลองโครงข่ายประสาทคอนโวลูชัน

ตัวอย่างผลลัพธ์การทดสอบแบบจำลองโครงข่ายประสาทคอนโวลูชัน โดยใช้ผลจาก Stratified 5-Fold Cross Validation ที่ Learning rate เท่ากับ 0.001 แบ่งออกเป็นทั้งหมด 5 Fold ดังรูปที่ 61-65

```
Performance
Accuracy : 0.878
Precision : 0.8886462034719456
Recall : 0.8916666666666666
f1Score : 0.8893015722263969
[[167 33 0]
 [ 17 176 7]
 [ 0 4 96]]
```

รูปที่ 61 ผลลัพธ์การทดสอบแบบจำลองโครงข่ายประสาทคอนโวลูชันที่ Learning Rate เท่ากับ 0.001 แบบ Macro average ของ Fold ที่ 1

```
Performance
Accuracy : 0.876
Precision : 0.8854754092563545
Recall : 0.8816666666666667
f1Score : 0.8828046426861401
[[170 30 0]
 [ 15 177 8]
 [ 1 8 91]]
```

รูปที่ 62 ผลลัพธ์การทดสอบแบบจำลองโครงข่ายประสาทคอนโวลูชันที่ Learning Rate เท่ากับ 0.001 แบบ Macro average ของ Fold ที่ 2

```
Performance
Accuracy : 0.924
Precision : 0.937686084142395
Recall : 0.9266666666666667
f1Score : 0.9318007380698458
[[183 17 0]
 [ 15 185 0]
 [ 2 4 94]]
```

รูปที่ 63 ผลลัพธ์การทดสอบแบบจำลองโครงข่ายประสาทคอนโวลูชันที่ Learning Rate เท่ากับ 0.001 แบบ Macro average ของ Fold ที่ 3



```

Performance
Accuracy : 0.898
Precision : 0.9132371363011607
Recall : 0.9
f1Score : 0.9058428672196978
[[175 25 0]
 [ 15 183 2]
 [ 4 5 91]]

```

รูปที่ 64 ผลลัพธ์การทดสอบแบบจำลองโครงข่ายประสาทคอนโวลูชันที่ Learning Rate เท่ากับ 0.001 แบบ Macro average ของ Fold ที่ 4

```

Performance
Accuracy : 0.912
Precision : 0.9277486572186632
Recall : 0.9166666666666666
f1Score : 0.9218615506726854
[[182 18 0]
 [ 20 180 0]
 [ 2 4 94]]

```

รูปที่ 65 ผลลัพธ์การทดสอบแบบจำลองโครงข่ายประสาทคอนโวลูชันที่ Learning Rate เท่ากับ 0.001 แบบ Macro average ของ Fold ที่ 5

จากผลลัพธ์ Stratified 5-Fold Cross Validation ทั้งหมด 5 Fold ที่ Learning Rate เท่ากับ 0.001 ดังรูปที่ 61-65 สามารถแสดงผลลัพธ์รวม ดังรูปที่ 66

precision	recall	f1-score	accuracy
0.8886462034719456	0.8916666666666666	0.8893015722263969	0.878
0.8854754092563545	0.8816666666666667	0.8828046426861401	0.876
0.937686084142395	0.9266666666666667	0.9318007380698458	0.924
0.9132371363011607	0.9	0.9058428672196978	0.898
0.9277486572186632	0.9166666666666666	0.9218615506726854	0.912

รูปที่ 66 ผลลัพธ์การทดสอบแบบจำลองโครงข่ายประสาทคอนโวลูชันที่ Learning Rate เท่ากับ 0.001 แบบ Macro average รวม 5 Fold

เนื่องจากการใช้ฟังก์ชันโค้ดใน google colab แสดงผลลัพธ์จุดทศนิยมหลายตำแหน่ง เพื่อให้ผลลัพธ์สามารถเปรียบเทียบกับผลลัพธ์การทดสอบจาก Classification report ก่อนหน้าที่แสดงผลด้วยทศนิยมสองตำแหน่ง ดังนั้นจึงนำผลลัพธ์แบบ Macro average ของ precision, recall f1-score และ accuracy แสดงในรูปแบบทศนิยมสองตำแหน่งในตารางผลสมรรถนะของการทดสอบ

แบบจำลอง ดังตารางที่ 8 โดยจะนำค่าที่ได้จากผลลัพธ์โค้ดใน google colab มาแสดงอยู่ในรูปแบบตารางกับทุกแบบจำลอง

ตารางที่ 8 สมรรถนะของการทดสอบแบบจำลอง CNN โดยใช้ Stratified 5-Fold Cross

Validation

Model	Learning Rate	Folds	Macro Average			Accuracy
			Precision	Recall	F1 score	
CNN	0.01	1	0.13	0.33	0.19	0.40
		2	0.13	0.33	0.19	0.40
		3	0.13	0.33	0.19	0.40
		4	0.13	0.33	0.19	0.40
		5	0.13	0.33	0.19	0.40
		<b>Average</b>	<b>0.13</b>	<b>0.33</b>	<b>0.19</b>	<b>0.40</b>
	0.001	1	0.89	0.89	0.89	0.88
		2	0.88	0.88	0.88	0.88
		3	0.94	0.93	0.93	0.92
		4	0.91	0.90	0.91	0.90
		5	0.93	0.92	0.92	0.91
		<b>Average</b>	<b>0.91</b>	<b>0.90</b>	<b>0.91</b>	<b>0.90</b>

ตารางที่ 9 สมรรถนะของการทดสอบแบบจำลอง VGG16 โดยใช้ Stratified 5-Fold Cross

Validation

Model	Learning Rate	Folds	Macro Average			Accuracy
			Precision	Recall	F1 score	
VGG16	0.01	1	0.89	0.83	0.85	0.85
		2	0.86	0.81	0.83	0.83
		3	0.90	0.86	0.88	0.87
		4	0.90	0.88	0.89	0.88
		5	0.91	0.88	0.89	0.89
		<b>Average</b>	<b>0.89</b>	<b>0.85</b>	<b>0.87</b>	<b>0.86</b>
	0.001	1	0.93	0.92	0.93	0.92
		2	0.92	0.91	0.92	0.91
		3	0.93	0.93	0.93	0.92
		4	0.94	0.94	0.94	0.93
		5	0.94	0.94	0.94	0.93
		<b>Average</b>	<b>0.93</b>	<b>0.93</b>	<b>0.92</b>	<b>0.92</b>

ตารางที่ 10 สมรรถนะของการทดสอบแบบจำลอง DenseNet121 โดยใช้ Stratified 5-Fold Cross Validation

Model	Learning Rate	Folds	Macro Average			Accuracy
			Precision	Recall	F1 score	
DenseNet 121	0.01	1	0.87	0.85	0.86	0.85
		2	0.92	0.87	0.88	0.90
		3	0.91	0.88	0.89	0.89
		4	0.92	0.87	0.88	0.90
		5	0.92	0.89	0.88	0.90
		<b>Average</b>	<b>0.91</b>	<b>0.87</b>	<b>0.88</b>	<b>0.90</b>
	0.001	1	0.95	0.94	0.94	0.94
		2	0.92	0.90	0.90	0.90
		3	0.96	0.96	0.96	0.95
		4	0.96	0.96	0.96	0.96
		5	0.96	0.96	0.96	0.96
		<b>Average</b>	<b>0.95</b>	<b>0.94</b>	<b>0.94</b>	<b>0.94</b>

จากการใช้ Stratified 5-Fold Cross Validation กับแบบจำลองทั้งหมดเพื่อช่วยลดความ Bias ของการแบ่งชุดข้อมูลทำให้ได้ผลลัพธ์ใหม่ดังนี้ ผลลัพธ์ของแบบจำลองเมื่อปรับค่าพารามิเตอร์ Learning Rate 0.01 แบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวีจีจี 16 มีค่าความแม่นยำลดลง 5% ส่วนแบบจำลองโครงข่ายประสาทคอนโวลูชัน และแบบจำลองโครงข่ายประสาทแบบเดนซ์เน็ต 121 มีค่าความแม่นยำเท่าเดิม ในขณะที่การปรับค่าพารามิเตอร์ Learning Rate 0.001 ได้ผลลัพธ์ดังนี้ แบบจำลองโครงข่ายประสาทคอนโวลูชัน และแบบจำลองโครงข่ายประสาทแบบเดนซ์เน็ต 121 มีค่าความแม่นยำเพิ่มขึ้น 3% และ 2% ตามลำดับ ส่วนแบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวีจีจี 16 นั้นมีค่าความแม่นยำเท่าเดิมดังแสดงในตารางที่ 11

ตารางที่ 11 เปรียบเทียบสมรรถนะของการทดสอบแบบจำลองทั้ง 3 แบบโดยใช้ Stratified 5-Fold Cross Validation กับค่าความแม่นยำโดยการแบ่งข้อมูลแบบสุ่ม

Model	Learning Rate	Macro Average			Average Accuracy With Kfold	Accuracy Without KFold	Difference Accuracy (%)
		Precision	Recall	F1 score			
CNN	0.01	0.13	0.33	0.19	0.40	0.40	0
VGG16		0.89	0.85	0.87	0.86	0.91	5
DenseNet121		0.91	0.87	0.88	0.90	0.90	0
CNN	0.001	0.90	0.90	0.90	0.90	0.87	3
VGG16		0.93	0.93	0.92	0.92	0.92	0
DenseNet121		<b>0.95</b>	<b>0.94</b>	<b>0.94</b>	<b>0.94</b>	0.92	2

#### 4.6.6 เปรียบเทียบผลการทดลองของแบบจำลองพื้นฐานร่วมกับการสกัดคุณลักษณะแบบ LBP โดยใช้ Stratified 5-Fold Cross Validation

จากการทดลองเบื้องต้นพบว่าการใช้ 5-Fold Cross Validation ให้กับแบบจำลองเพื่อช่วยลดความ Bias ของการแบ่งชุดข้อมูลและใช้ค่าพารามิเตอร์ Learning Rate 0.001 ทำให้แบบจำลองมีความแม่นยำเฉลี่ยที่สูงขึ้น ดังนั้นจึงนำค่าพารามิเตอร์นี้มาใช้ในการทดลองโดยเพิ่มการสกัดคุณลักษณะท้องถิ่นแบบ LBP ร่วมกับแบบจำลองพื้นฐานทั้งสาม และทำการฝึกสอนใหม่อีกครั้ง จากนั้นนำผลลัพธ์สมรรถนะของแบบจำลองทั้งหมดในแต่ละรอบมาหาค่าเฉลี่ย ดังแสดงในตารางที่ 12

ตารางที่ 12 สมรรถนะของการทดสอบแบบจำลองพื้นฐานร่วมกับการสกัดคุณลักษณะแบบ LBP โดยใช้ Stratified 5-Fold Cross Validation

Model	Learning Rate	Folds	Macro Average			Accuracy
			Precision	Recall	F1 score	
CNN +LBP	0.001	1	0.89	0.89	0.89	0.89
		2	0.93	0.93	0.92	0.92
		3	0.92	0.92	0.92	0.92
		4	0.93	0.93	0.93	0.93
		5	0.94	0.94	0.94	0.93
		<b>Average</b>	<b>0.92</b>	<b>0.92</b>	<b>0.92</b>	<b>0.92</b>
VGG16 +LBP	0.001	1	0.92	0.92	0.92	0.91
		2	0.94	0.92	0.93	0.92
		3	0.95	0.94	0.94	0.94
		4	0.95	0.95	0.95	0.94
		5	0.93	0.93	0.93	0.92
		<b>Average</b>	<b>0.94</b>	<b>0.93</b>	<b>0.93</b>	<b>0.93</b>
DenseNet 121+LBP	0.001	1	0.95	0.95	0.95	0.94
		2	0.97	0.97	0.96	0.96
		3	0.95	0.96	0.95	0.95
		4	0.96	0.95	0.95	0.95
		5	0.97	0.97	0.97	0.96
		<b>Average</b>	<b>0.96</b>	<b>0.96</b>	<b>0.96</b>	<b>0.95</b>

#### 4.6.7 ผลการทดลองของแบบจำลองพื้นฐาน และแบบจำลองพื้นฐานร่วมกับการสกัดคุณลักษณะแบบ LBP โดยใช้ Stratified 5-Fold Cross Validation

ผลลัพธ์การทำนายรูปแบบ Confusion Matrix ของแบบจำลองพื้นฐานทั้งสามที่ใช้ค่าพารามิเตอร์ Learning Rate 0.001 ได้แก่ แบบจำลองโครงข่ายประสาทคอนโวลูชัน แบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวีจีจี 16 และแบบจำลองโครงข่ายประสาทแบบเดนส์เน็ต121 ดังตารางที่ 13, 14 และ 15 ตามลำดับ

ตารางที่ 13 ผลลัพธ์รูปแบบ Confusion Matrix ของแบบจำลองโครงข่ายประสาทคอนโวลูชัน

CNN		Predicted		
		Counterfeited Handbags	Authorized Handbags	Other Material Handbags
Actual	Counterfeited Handbags	182	18	0
	Authorized Handbags	20	180	0
	Other Material Handbags	2	4	94

ตารางที่ 14 ผลลัพธ์รูปแบบ Confusion Matrix ของแบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวีจีจี 16

VGG16		Predicted		
		Counterfeited Handbags	Authorized Handbags	Other Material Handbags
Actual	Counterfeited Handbags	181	19	0
	Authorized Handbags	11	188	1
	Other Material Handbags	0	3	97

ตารางที่ 15 ผลลัพธ์รูปแบบ Confusion Matrix ของแบบจำลองโครงข่ายประสาทแบบเดนซ์เน็ต 121

DenseNet121		Predicted		
		Counterfeited Handbags	Authorized Handbags	Other Material Handbags
Actual	Counterfeited Handbags	184	16	0
	Authorized Handbags	6	194	0
	Other Material Handbags	1	6	93

ผลลัพธ์การทำนายรูปแบบ Confusion Matrix ของแบบจำลองพื้นฐานร่วมกับการสกัดคุณลักษณะแบบ LBP ได้แก่ แบบจำลองโครงข่ายประสาทคอนโวลูชันร่วมกับการสกัดคุณลักษณะแบบ LBP แบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวีจีจี 16 ร่วมกับการสกัดคุณลักษณะแบบ LBP และแบบจำลองโครงข่ายประสาทแบบเดนซ์เน็ต121 ร่วมกับการสกัดคุณลักษณะแบบ LBP ดังตารางที่ 16, 17 และ 18 ตามลำดับ

ตารางที่ 16 ผลลัพธ์รูปแบบ Confusion Matrix ของแบบจำลองโครงข่ายประสาทคอนโวลูชันร่วมกับการสกัดคุณลักษณะแบบ LBP

CNN+LBP		Predicted		
		Counterfeited Handbags	Authorized Handbags	Other Material Handbags
Actual	Counterfeited Handbags	186	14	0
	Authorized Handbags	19	179	2
	Other Material Handbags	1	0	99



ตารางที่ 17 ผลลัพธ์รูปแบบ Confusion Matrix ของแบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวี  
จิจี 16 ร่วมกับการสกัดคุณลักษณะแบบ LBP

VGG16+LBP		Predicted		
		Counterfeited Handbags	Authorized Handbags	Other Material Handbags
Actual	Counterfeited Handbags	180	20	0
	Authorized Handbags	8	192	0
	Other Material Handbags	0	1	99

ตารางที่ 18 ผลลัพธ์รูปแบบ Confusion Matrix ของแบบจำลองโครงข่ายประสาทแบบเดนซ์เน็ต  
121 ร่วมกับการสกัดคุณลักษณะแบบ LBP

DenseNet121+LBP		Predicted		
		Counterfeited Handbags	Authorized Handbags	Other Material Handbags
Actual	Counterfeited Handbags	187	13	0
	Authorized Handbags	7	193	0
	Other Material Handbags	0	0	100

สรุปผลการทดลองการสกัดคุณลักษณะสำคัญแบบ LBP ร่วมกับการเรียนรู้ของแบบจำลอง  
พื้นฐานทั้งสามโดยใช้พารามิเตอร์ Learning Rate เท่ากับ 0.001 และใช้ 5-Fold Cross Validation  
ดังแสดงในตารางที่ 19 แบบจำลองโครงข่ายประสาทคอนโวลูชัน มีค่าเฉลี่ยความแม่นยำเพิ่มขึ้นจาก  
90% เป็น 92% แบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวีจิจี 16 มีค่าเฉลี่ยความแม่นยำเพิ่มขึ้น  
จาก 92% เป็น 93% และแบบจำลองโครงข่ายประสาทแบบเดนซ์เน็ต121 มีค่าเฉลี่ยความแม่นยำ  
เพิ่มขึ้นจาก 94 เป็น 95% ซึ่งให้ค่าความแม่นยำสูงที่สุด จากการจำแนกภาพกระเป๋าของแท้ ของ  
ปลอม และวัสดุอื่นๆ เป็นการจำแนกรูปภาพแบบหลายประเภท เมื่อนำการสกัดคุณลักษณะแบบ LBP

ร่วมกับแบบจำลองเพื่อเรียนรู้ ทำให้ผลลัพธ์การทำนายกระเปาะของแท้ ของปลอม และวัสดุอื่นในรูปแบบ Confusion Matrix ถูกต้องมากยิ่งขึ้นซึ่งจะช่วยเพิ่มค่าความแม่นยำที่สูงขึ้น

ตารางที่ 19 เปรียบเทียบสมรรถนะของการทดสอบแบบจำลองพื้นฐานกับแบบจำลองพื้นฐานร่วมกับการสกัดคุณลักษณะแบบ LBP ทั้ง 3 แบบ โดยใช้ Stratified 5-Fold Cross Validation

Model	Learning Rate	Macro Average			Average Accuracy With Kfold
		Precision	Recall	F1 score	
CNN	0.001	0.90	0.90	0.90	0.90
VGG16		0.93	0.93	0.92	0.92
DenseNet121		0.95	0.94	0.94	0.94
CNN+LBP		0.92	0.92	0.92	0.92
VGG16+LBP		0.94	0.93	0.93	0.93
DenseNet121+LBP		<b>0.96</b>	<b>0.96</b>	<b>0.96</b>	<b>0.95</b>

ซึ่งค่าเมตริกที่ได้มีความใกล้เคียงกันเนื่องจากชุดข้อมูลภาพมีแพตเทิร์นอักษร GG และการเรียงตัวของพื้นผิววัสดุที่มีความคล้ายคลึงกัน เมื่อแบบจำลองทั้งหมดได้เรียนรู้ชุดข้อมูลที่มีความคล้ายคลึงกันของแพตเทิร์นร่วมกับการสกัดคุณลักษณะแบบ LBP ที่ทำให้เห็นคุณลักษณะของพื้นผิวแพตเทิร์นชัดเจนยิ่งขึ้น ทำให้ค่าผลลัพธ์มีค่าที่ใกล้เคียงกัน ดังนั้นจึงทำการวิเคราะห์เปรียบเทียบด้วยข้อมูลเชิงสถิติในลำดับต่อไป

#### 4.6.8 การทดลองเปรียบเทียบด้วยข้อมูลเชิงสถิติ

การวิเคราะห์ข้อมูลในเชิงสถิติอ้างอิง โดยมีวัตถุประสงค์ต้องการนำค่าสถิติมาสรุปและอ้างอิงว่าค่าพารามิเตอร์ที่สนใจสอดคล้องกับสมมติฐานที่ตั้งไว้อย่างมีนัยสำคัญ โดยใช้วิธีการในการวิเคราะห์ข้อมูลคือการทดสอบสมมติฐาน (hypothesis testing) ด้วยการทดสอบการแจกแจงแบบปกติ และการทดสอบที

### การทดสอบการแจกแจงแบบปกติ (Normality Test)

การทดสอบการแจกแจงแบบปกติเนื่องจากข้อมูลกลุ่มสำหรับการวนทดสอบด้วย Stratified K-Fold Cross Validation (K=5) มีน้อยกว่า 50 จึงใช้การทดสอบการแจกแจงแบบปกติ ด้วย The Shapiro-Wilk Test โดย

ค่า Sig. ของ Shapiro-Wilk  $> 0.05$  ข้อมูลมีการแจกแจงปกติ

ค่า Sig. ของ Shapiro-Wilk  $< 0.05$  ข้อมูลมีการแจกแจงไม่ปกติ

นำค่าความแม่นยำของผลการทดลองแบบจำลองพื้นฐานที่ Learning Rate เท่ากับ 0.001 จากตารางที่ 8, 9, 10 และ ค่าความแม่นยำของผลการทดลองแบบจำลองพื้นฐานร่วมกับการสกัดคุณลักษณะแบบ LBP จากตารางที่ 12 มาทำการทดสอบการแจกแจงแบบปกติ ได้ผลการทดสอบ ดังรูปที่ 67

**Tests of Normality**

	Shapiro-Wilk		
	Statistic	df	Sig.
CNN	.894	5	.377
VGG16	.881	5	.314
DenseNet121	.806	5	.090
CNN+LBP	.779	5	.054
VGG16+LBP	.852	5	.201
DenseNet121+LBP	.881	5	.314

รูปที่ 67 ผลการทดสอบการแจกแจงแบบปกติ

จากผลการทดสอบการแจกแจงแบบปกติของแบบจำลองทั้ง 6 พบว่า ค่า Sig. ของ Shapiro-Wilk เป็นดังนี้

1. แบบจำลองโครงข่ายประสาทคอนโวลูชันผลลัพธ์ค่า Sig. เท่ากับ  $0.377 > 0.05$
2. แบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวีจีจี 16 ผลลัพธ์ค่า Sig. เท่ากับ  $0.314 > 0.05$
3. แบบจำลองโครงข่ายประสาทแบบเดนส์เน็ต121 ผลลัพธ์ค่า Sig. เท่ากับ  $0.090 > 0.05$
4. แบบจำลองโครงข่ายประสาทคอนโวลูชันร่วมกับการสกัดคุณลักษณะแบบ LBP ผลลัพธ์ค่า Sig. เท่ากับ  $0.054 > 0.05$

5. แบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวีจีจี 16 ร่วมกับการสกัดคุณลักษณะแบบ LBP ผลลัพธ์ค่า Sig. เท่ากับ  $0.201 > 0.05$
6. แบบจำลองโครงข่ายประสาทแบบเดนซ์เน็ต121 ร่วมกับการสกัดคุณลักษณะแบบ LBP ผลลัพธ์ค่า Sig. เท่ากับ  $0.314 > 0.05$

ดังนั้นจึงสามารถสรุปได้ว่าแบบจำลองทั้ง 6 มีการแจกแจงแบบปกติ

### การทดสอบที (T-Test)

จากผลลัพธ์การแจกแจงแบบปกติของแบบจำลองทั้งหมด เนื่องจากแบบจำลองจำแนกโดยใช้ชุดข้อมูลเดียวกัน ดังนั้นจึงสามารถนำมาทำการทดสอบ Pair sample T-Test ซึ่งเป็นวิธีการทดสอบสมมติฐานทางสถิติ เพื่อเปรียบเทียบค่าเฉลี่ยของกลุ่มตัวอย่างสมมติฐาน ระหว่างแบบจำลองพื้นฐานกับแบบจำลองพื้นฐานร่วมกับการสกัดคุณลักษณะแบบ LBP โดยให้ค่าระดับนัยสำคัญ (Significant level) เท่ากับ 0.05 และกำหนดสมมติฐานเชิงสถิติเป็น 2 ประเภท ได้แก่  $H_0$  คือสมมติฐานว่าง (null hypothesis) ที่แสดงว่าไม่มีการเปลี่ยนแปลงใด ๆ ไม่มีความแตกต่าง หรือความแตกต่างเป็นศูนย์ และ  $H_a$  คือสมมติฐานแย้ง (alternative hypothesis) เป็นสมมติฐานที่ตั้งขึ้นมาเพื่อปฏิเสธสมมติฐานว่าง เป็นสมมติฐานที่แสดงการเปลี่ยนแปลง หรือ มีความแตกต่าง ดังนี้

$$H_0: \mu_1 \geq \mu_2$$

$$H_a: \mu_1 < \mu_2$$

$\mu_1$  คือค่าเฉลี่ยความแม่นยำของแบบจำลองพื้นฐาน

$\mu_2$  คือค่าเฉลี่ยความแม่นยำของแบบจำลองพื้นฐานร่วมกับการสกัดคุณลักษณะแบบ LBP

- การทดสอบ Pair sample T-Test ระหว่างแบบจำลองโครงข่ายประสาทคอนโวลูชันกับแบบจำลองโครงข่ายประสาทคอนโวลูชันร่วมกับการสกัดคุณลักษณะแบบ LBP

โดยกำหนดสมมติฐาน ดังนี้

$$H_0: \mu_1 \geq \mu_2$$

$$H_a: \mu_1 < \mu_2$$

$\mu_1$  คือค่าเฉลี่ยความแม่นยำของแบบจำลองโครงข่ายประสาทคอนโวลูชัน

$\mu_2$  คือค่าเฉลี่ยความแม่นยำของแบบจำลองโครงข่ายประสาทคอนโวลูชันร่วมกับการสกัดคุณลักษณะแบบ LBP

		Paired Samples T-Test							
		Paired Differences					t	df	Sig. (1-tailed)
		Mean	Std. Deviation	Std. Error Mean	95% Confidence Interval of the Difference				
					Lower	Upper			
Pair 1	CNN - CNN+LBP	-.02000	.01581	.00707	-.03963	-.00037	-2.828	4	.024

รูปที่ 68 ผลการทดสอบที่ระหว่างแบบจำลองโครงข่ายประสาทคอนโวลูชันกับแบบจำลองโครงข่ายประสาทคอนโวลูชันร่วมกับการสกัดคุณลักษณะแบบ LBP

การทดสอบทีคู่แรกระหว่างแบบจำลองโครงข่ายประสาทคอนโวลูชันกับแบบจำลองโครงข่ายประสาทคอนโวลูชันร่วมกับการสกัดคุณลักษณะแบบ LBP ดังรูปที่ 68 พบว่า Sig. (1-tailed) ให้ค่า p-value = 0.024 ซึ่ง  $p < 0.05$  จึงปฏิเสธสมมติฐาน  $H_0$  และยอมรับ  $H_a$  หมายความว่าค่าเฉลี่ยความแม่นยำของแบบจำลองโครงข่ายประสาทคอนโวลูชันร่วมกับการสกัดคุณลักษณะแบบ LBP มากกว่าแบบจำลองโครงข่ายประสาทคอนโวลูชันอย่างมีนัยสำคัญ

- การทดสอบ Pair sample T-Test ระหว่างแบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวีจีจี 16 กับแบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวีจีจี 16 ร่วมกับการสกัดคุณลักษณะแบบ LBP

โดยกำหนดสมมติฐาน ดังนี้

$$H_0: \mu_1 \geq \mu_2$$

$$H_a: \mu_1 < \mu_2$$

$\mu_1$  คือค่าเฉลี่ยความแม่นยำของแบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวีจีจี 16

$\mu_2$  คือค่าเฉลี่ยความแม่นยำของแบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวีจีจี 16 ร่วมกับการสกัดคุณลักษณะแบบ LBP

		Paired Samples T-Test							
		Paired Differences							
		Mean	Std. Deviation	Std. Error Mean	95% Confidence Interval of the Difference		t	df	Sig. (1-tailed)
					Lower	Upper			
Pair 2	VGG16 - VGG16+LBP	-.00400	.01342	.00600	-.02066	.01266	-.667	4	.271

รูปที่ 69 ผลการทดสอบที่ระหว่างแบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวีจีจี 16 กับแบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวีจีจี 16 ร่วมกับการสกัดคุณลักษณะแบบ LBP

การทดสอบที่คู่ที่สองระหว่างแบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวีจีจี 16 กับแบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวีจีจี 16 ร่วมกับการสกัดคุณลักษณะแบบ LBP ดังรูปที่ 69 พบว่า Sig. (1-tailed) ให้ค่า p-value = 0.271 ซึ่ง  $p > 0.05$  จึงยอมรับสมมติฐาน  $H_0$  และปฏิเสธ  $H_a$  หมายความว่าค่าเฉลี่ยความแม่นยำของแบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวีจีจี 16 ร่วมกับการสกัดคุณลักษณะแบบ LBP แตกต่างกับแบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวีจีจี 16 อย่างไม่มีนัยสำคัญ

- การทดสอบ Pair sample T-Test ระหว่างแบบจำลองโครงข่ายประสาทแบบเดนซ์เน็ต 121 กับแบบจำลองโครงข่ายประสาทแบบเดนซ์เน็ต 121 ร่วมกับการสกัดคุณลักษณะแบบ LBP

โดยกำหนดสมมติฐาน ดังนี้

$$H_0: \mu_1 \geq \mu_2$$

$$H_a: \mu_1 < \mu_2$$

$\mu_1$  คือค่าเฉลี่ยความแม่นยำของแบบจำลองโครงข่ายประสาทแบบเดนซ์เน็ต 121

$\mu_2$  คือค่าเฉลี่ยความแม่นยำของแบบจำลองโครงข่ายประสาทแบบเดนซ์เน็ต 121 ร่วมกับการสกัดคุณลักษณะแบบ LBP

**Paired Samples T-Test**

		Paired Differences				t	df	Sig. (1-tailed)
		Mean	Std. Deviation	Std. Error Mean	95% Confidence Interval of the Difference Lower Upper			
Pair 3	DenseNet121 - DenseNet121+LBP	-.01000	.02828	.01265	-.04512 .02512	-.791	4	.237

รูปที่ 70 ผลการทดสอบที่ระหว่างแบบจำลองโครงข่ายประสาทแบบเดนซ์เน็ต121 กับแบบจำลองโครงข่ายประสาทแบบเดนซ์เน็ต121 ร่วมกับการสกัดคุณลักษณะแบบ LBP

การทดสอบทีคู่ที่สามระหว่างแบบจำลองโครงข่ายประสาทแบบเดนซ์เน็ต121 กับแบบจำลองโครงข่ายประสาทแบบเดนซ์เน็ต121 ร่วมกับการสกัดคุณลักษณะแบบ LBP ดังรูปที่ 70 พบว่า Sig. (1-tailed) ให้ค่า p-value = 0.237 ซึ่ง  $p > 0.05$  จึงยอมรับสมมติฐาน  $H_0$  และปฏิเสธ  $H_a$  หมายความว่าค่าเฉลี่ยความแม่นยำของแบบจำลองโครงข่ายประสาทแบบเดนซ์เน็ต121 ร่วมกับการสกัดคุณลักษณะแบบ LBP แตกต่างกับแบบจำลองโครงข่ายประสาทแบบเดนซ์เน็ต121 อย่างไม่มีนัยสำคัญ

ตารางที่ 20 เปรียบเทียบผลการทดสอบที่ระหว่างแบบจำลองพื้นฐานกับแบบจำลองพื้นฐานร่วมกับการสกัดคุณลักษณะแบบ LBP

	แบบจำลองพื้นฐาน			แบบจำลองพื้นฐานร่วมกับการสกัดคุณลักษณะแบบ LBP			สถิติทดสอบ	
	จำนวน	ค่าเฉลี่ย (%)	ค่าส่วนเบี่ยงเบนมาตรฐาน	จำนวน	ค่าเฉลี่ย (%)	ค่าส่วนเบี่ยงเบนมาตรฐาน	ค่า T	ค่า p-value
CNN	5	90	1.789	5	92	1.643	-2.228	0.024*
VGG16	5	92	0.837	5	93	1.342	-0.667	0.271
Dense Net121	5	94	2.49	5	95	0.837	-0.791	0.237

\*ระดับนัยสำคัญ 0.05, ค่าเฉลี่ยของค่าความแม่นยำ (Accuracy)

จากตารางที่ 20 การวิเคราะห์เปรียบเทียบผลการทดสอบที่ คู่แรกค่าเฉลี่ยความแม่นยำของแบบจำลองโครงข่ายประสาทคอนโวลูชันร่วมกับการสกัดคุณลักษณะแบบ LBP มากกว่าแบบจำลองโครงข่ายประสาทคอนโวลูชันอย่างมีนัยสำคัญ คู่ที่สองค่าเฉลี่ยความแม่นยำของแบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวีจีจี 16 ร่วมกับการสกัดคุณลักษณะแบบ LBP แตกต่างกับแบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวีจีจี 16 อย่างไม่มีนัยสำคัญ และคู่ที่สามค่าเฉลี่ยความแม่นยำของแบบจำลองโครงข่ายประสาทแบบเดนซ์เน็ต121 ร่วมกับการสกัดคุณลักษณะแบบ LBP แตกต่างกับแบบจำลองโครงข่ายประสาทแบบเดนซ์เน็ต121 อย่างไม่มีนัยสำคัญ





## บทที่ 5

### สรุปผลการวิจัย

เนื่องด้วยตลาดกระเป๋าแบรนด์เนมมือสองที่มีความเติบโตในปัจจุบัน แต่ในขณะเดียวกันก็พบปัญหาการปลอมแปลงสินค้าส่งผลกระทบต่อทั้งผู้ซื้อและผู้ขาย โดยจากการรวบรวมข้อมูลจากสมาคมแบรนด์เนมมือสองแห่งประเทศไทยพบว่า Gucci เป็นแบรนด์ที่ถูกซื้อขาย-แลกเปลี่ยนในตลาดมือสองมากที่สุด แม้จะมีหลักสำคัญในการตรวจสอบกระเป๋าของแท้ของปลอม แต่ยังคงพบข้อจำกัดในการตรวจสอบที่ยากในการสังเกตนั่นคือวัสดุ GG Canvas ที่จะต้องใช้แว่นขยายส่องดูและต้องใช้ผู้เชี่ยวชาญในการประเมิน ผู้วิจัยเห็นว่าหากนำกระเป๋าที่ทำด้วยวัสดุ GG Canvas มาเรียนรู้โดยใช้โครงข่ายประสาทคอนโวลูชันร่วมกับการเรียนรู้ถ่ายโอนนั้น จะช่วยในการจำแนกกระเป๋าของแท้และของปลอม

จากการเก็บรวบรวมข้อมูลรูปภาพจากสมาคมแบรนด์เนมมือสองแห่งประเทศไทยเป็นจำนวน 2500 ภาพโดยแบ่งชุดข้อมูลออกเป็นข้อมูลฝึกสอนแบบจำลอง 1,600 ภาพ ข้อมูลตรวจสอบ 400 ภาพและข้อมูลเพื่อทดสอบแบบจำลอง 500 ภาพโดยใช้การเรียนรู้เชิงลึกของแบบจำลองโครงข่ายประสาทคอนโวลูชันเป็นแบบจำลองพื้นฐาน และนำ Pretrain Model มาพัฒนาได้แก่ แบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวีจีจี 16 และแบบจำลองโครงข่ายประสาทแบบเดนส์เน็ต121 โดยกำหนดค่าพารามิเตอร์ Learning Rate เท่ากับ 0.001 เนื่องจากทำให้แบบจำลองเรียนรู้ได้ละเอียดและให้ค่าความแม่นยำดีกว่าค่า Learning Rate เท่ากับ 0.01 รวมถึงใช้ Stratified 5-Fold Cross Validation ในการแบ่งชุดข้อมูลเพื่อช่วยลดความ Bias ของชุดข้อมูลที่อาจเกิดขึ้นได้ และเพิ่มชุดข้อมูลฝึกสอนโดยใช้การหมุนภาพแบบตั้งฉาก 90 องศาและการพลิกภาพแนวนอนร่วมกับแนวตั้ง เนื่องจากข้อมูลนำเข้าเป็นรูปวัสดุของกระเป๋าที่มีความคล้ายคลึงกันซึ่งแยกด้วยตาเปล่าของมนุษย์ได้ยาก ดังนั้นจึงได้นำหลักการดึงคุณลักษณะสำคัญของภาพแบบ LBP ที่ใช้กับภาพวัสดุพื้นผิวได้ดี มาใช้ร่วมกับแบบจำลองพื้นฐานในการฝึกสอนให้สามารถทำนายผลลัพธ์ได้แก่ กระเป๋าของแท้ ของปลอม และวัสดุอื่น ได้ผลการทดลองการใช้แบบจำลองพื้นฐาน และการใช้แบบจำลองพื้นฐานร่วมกับการสกัดคุณลักษณะแบบ LBP ดังนี้ แบบจำลองโครงข่ายประสาทคอนโวลูชัน มีค่าความเฉลี่ยแม่นยำเพิ่มขึ้นจาก 90% เป็น 92% แบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวีจีจี 16 มีค่าความเฉลี่ยเพิ่มขึ้นจาก 92% เป็น 93% และแบบจำลองโครงข่ายประสาทแบบเดนส์เน็ต121 มีค่าความเฉลี่ยเพิ่มขึ้นจาก 94% เป็น 95% ซึ่งให้ค่าความแม่นยำสูงที่สุด ซึ่งเมื่อนำการสกัดคุณลักษณะแบบ LBP ร่วมกับแบบจำลองพื้นฐานทำให้ค่าความแม่นยำการทำนายผลลัพธ์ที่สูงขึ้น และจากการนำค่า

ความแม่นยำเฉลี่ยมาวิเคราะห์ข้อมูลเชิงสถิติพบว่า การนำแบบจำลองโครงข่ายประสาทคอนโวลูชัน ร่วมกับการสกัดคุณลักษณะแบบ LBP ทำให้ค่าความแม่นยำมากกว่าอย่างมีนัยสำคัญ โดยขณะที่การ นำแบบจำลองโครงข่ายประสาทคอนโวลูชันแบบวีจีจี16 ร่วมกับการสกัดคุณลักษณะแบบ LBP และ แบบจำลองโครงข่ายประสาทแบบเดนส์เน็ต121 ร่วมกับการสกัดคุณลักษณะแบบ LBP ทำให้ค่าความ แม่นยำแตกต่างกันอย่างไม่มีนัยสำคัญ

ประโยชน์จากการทดลองนี้จะช่วยให้ลดขั้นตอนตรวจสอบที่ซับซ้อนและลดข้อจำกัดของ มนุษย์ ซึ่งผลการเรียนรู้จากแบบจำลองสามารถนำไปต่อยอดพัฒนาเป็นแอปพลิเคชันที่สามารถใช้ กล้องตรวจสอบช่วยให้ผู้ซื้อและผู้ขายตรวจสอบได้ง่ายยิ่งขึ้น



## บรรณานุกรม

1. OECD, E., *Trends in Trade in Counterfeit and pirated goods*. 2019.
2. Baldini, G., et al., *Survey of techniques for the fight against counterfeit goods and Intellectual Property Rights (IPR) infringement*. Publ Off Eur Union, 2015: p. 1-130.
3. Schouten, T. *Color models*. [cited 2022; Available from: <http://www.cs.ru.nl/~ths/rt2/col/h2/2fundENG.html#2.2.4>].
4. Porebski, A., N. Vandenbroucke, and L. Macaire. *Haralick feature extraction from LBP images for color texture classification*. in *2008 First Workshops on Image Processing Theory, Tools and Applications*. 2008. IEEE.
5. Truong, H.P. and Y.-G. Kim. *Enhanced line local binary patterns (EL-LBP): an efficient image representation for face recognition*. in *International conference on advanced concepts for intelligent vision systems*. 2018. Springer.
6. LeCun, Y., K. Kavukcuoglu, and C. Farabet. *Convolutional networks and applications in vision*. in *Proceedings of 2010 IEEE international symposium on circuits and systems*. 2010. IEEE.
7. Juan, C.G. *Use of convolutional neural network for image classification*. 2017, [cited 2021 Oct]; Available from: <https://www.apsl.net/blog/2017/11/20/use-convolutional-neural-network-image-classification/>.
8. Sarkar, D. *A Comprehensive Hands-on Guide to Transfer Learning with Real-World Applications in Deep Learning*. 2018 [cited 2021 Oct]; Available from: <https://towardsdatascience.com/a-comprehensive-hands-on-guide-to-transfer-learning-with-real-world-applications-in-deep-learning-212bf3b2f27a>.
9. Simonyan, K. and A. Zisserman, *Very deep convolutional networks for large-scale image recognition*. arXiv preprint arXiv:1409.1556, 2014.
10. Pandiyan, V., et al., *In-process virtual verification of weld seam removal in robotic abrasive belt grinding process using deep learning*. *Robotics and Computer-Integrated Manufacturing*, 2019. **57**: p. 477-487.
11. Huang, G., et al. *Densely connected convolutional networks*. in *Proceedings of*

- the IEEE conference on computer vision and pattern recognition*. 2017.
12. Sharma, A., et al. *The fake vs real goods problem: microscopy and machine learning to the rescue*. in *Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. 2017.
  13. Li, B. and B. Wang. *Real and Fake label image classification algorithm based on HOG and SVM*. in *2020 International Conference on Intelligent Transportation, Big Data & Smart City (ICITBS)*. 2020. IEEE.
  14. Şerban, A., G. Ilaş, and G.-C. Poruşniuc, *SpotTheFake: an initial report on a new CNN-enhanced platform for counterfeit goods detection*. arXiv preprint arXiv:2002.06735, 2020.
  15. Saraiva, A.A., et al. *Classification of Images of Childhood Pneumonia using Convolutional Neural Networks*. in *Bioimaging*. 2019.
  16. Kermany, D., K. Zhang, and M. Goldbaum, *Labeled optical coherence tomography (oct) and chest x-ray images for classification*. *Mendeley data*, 2018(2).
  17. Adagbasa, E.G., S.A. Adelabu, and T.W. Okello, *Application of deep learning with stratified K-fold for vegetation species discrimination in a protected mountainous region using Sentinel-2 image*. *Geocarto International*, 2022(1): p. 142-162.
  18. Mubarak, A.S., et al., *Local binary pattern and deep learning feature extraction fusion for COVID-19 detection on computed tomography images*. *Expert Systems*, 2022: p. e12842.
  19. Hosny, K.M., et al., *Refined Color Texture Classification Using CNN and Local Binary Pattern*. *Mathematical Problems in Engineering*, 2021.
  20. Peng, J., B. Zou, and C. Zhang, *A Two-Stage Deep Learning Framework for Counterfeit Luxury Handbag Detection in Logo Images*. Available at SSRN 4017244.
  21. *GUCCI HANDBAGS*. [cited 2021 Nov]; Available from: [https://www.gucci.com/hk/en\\_gb/ca/women/handbags-c-women-handbags](https://www.gucci.com/hk/en_gb/ca/women/handbags-c-women-handbags).
  22. Grandini, M., E. Bagli, and G. Visani, *Metrics for multi-class classification: an overview*. arXiv preprint arXiv:2008.05756, 2020.



จุฬาลงกรณ์มหาวิทยาลัย  
**CHULALONGKORN UNIVERSITY**



ภาคผนวก

จุฬาลงกรณ์มหาวิทยาลัย  
**CHULALONGKORN UNIVERSITY**

## ภาคผนวก ก

### ข้อกำหนดของ Input Images สำหรับผู้ใช้งานระบบ

1. ผู้ใช้สามารถใช้ภาพถ่ายวัสดุพื้นผิวของกระเป๋า Gucci ด้านใดด้านหนึ่งเพื่อทำนายผลลัพธ์ดังรูป ตัวอย่างรูปภาพนำเข้า โดยสามารถใช้รูปใดรูปหนึ่งดังต่อไปนี้

1.1 ออริจินัลจีจีแคนवास ลักษณะโทนสีน้ำตาล

1.2.ออริจินัลจีจีแคนवास ลักษณะโทนสีเทา

1.3.จีจีซูพรีมแคนवास ลักษณะโทนสีน้ำตาล

1.4.จีจีซูพรีมแคนवास ลักษณะโทนสีเทา



ตัวอย่างรูปภาพนำเข้า

2. ใช้ขนาดภาพสำหรับ input ได้ตั้งแต่ขนาด  $224 \times 224 \times 3$  พิกเซล เป็นต้นไป (อ้างอิงจากการเก็บข้อมูลโดยใช้กล้อง Iphone รุ่น11 และ รุ่น12 ภาพถ่ายแนวตั้งมีขนาด  $3024 \times 4032 \times 3$  พิกเซล และภาพถ่ายแนวนอนมีขนาด  $4032 \times 3024 \times 3$  พิกเซล)

3. ใช้รูปภาพนำเข้าที่เห็นวัสดุชัดเจน ไม่สั่นเบลอ มีแสงสว่างเพียงพอขณะถ่ายภาพ และไม่ใช่ flash ขณะถ่ายภาพ หากผู้ใช้นำรูปภาพพื้นผิวกระเป๋า Gucci วัสดุอื่นที่ไม่ได้กล่าวถึงใน ภาคผนวก ข ข้อที่ 1 – 8 จะทำให้ผลลัพธ์การทำนายเป็นวัสดุอื่น โดยครอบคลุมเฉพาะรุ่นที่แสดงในภาคผนวก ค

## ภาคผนวก ข

ตัวอย่างภาพชุดข้อมูลสำหรับจำแนกจากวัสดุกระเปาะของแท้ ของปลอม และวัสดุอื่น


โดยแบ่งเป็นของแท้ และของปลอมที่มีพื้นผิววัสดุ 2 แบบ แต่ละแบบประกอบด้วย 2 โทนสี และวัสดุอื่น รวมทั้งหมด 9 แบบ ได้แก่

1. พื้นผิวออริจินัลจีจีแคนवास ลักษณะโทนสีน้ำตาล (ของแท้) ดังรูปที่ ข.71
2. พื้นผิวออริจินัลจีจีแคนवास ลักษณะโทนสีเทา (ของแท้) ดังรูปที่ ข.72
3. พื้นผิวจีจีซูพรีมแคนवास ลักษณะโทนสีน้ำตาล (ของแท้) ดังรูปที่ ข.73
4. พื้นผิวจีจีซูพรีมแคนवास ลักษณะโทนสีเทา (ของแท้) ดังรูปที่ ข.74
5. พื้นผิวออริจินัลจีจีแคนवास ลักษณะโทนสีน้ำตาล (ของปลอม) ดังรูปที่ ข.75
6. พื้นผิวออริจินัลจีจีแคนवास ลักษณะโทนสีเทา (ของปลอม) ดังรูปที่ ข.76
7. พื้นผิวจีจีซูพรีมแคนवास ลักษณะโทนสีน้ำตาล (ของปลอม) ดังรูปที่ ข.77
8. พื้นผิวจีจีซูพรีมแคนवास ลักษณะโทนสีเทา (ของปลอม) ดังรูปที่ ข.78
9. พื้นผิววัสดุอื่น ดังรูปที่ ข.79







รูปที่ ข.71 ตัวอย่างภาพกระเป่าพื้นผิวออร์จินัลจีจีแคนวาส ลักษณะโทนสีน้ำตาล (ของแท้)




รูปที่ ข.72 ตัวอย่างภาพกระเป๋าสตางค์หนังวัวสีน้ำตาล ลักษณะโทนสีเทา (ของแท้)



รูปที่ ข.73 ตัวอย่างภาพกระเป๋าสานผิวจีสูพรีเมียมแคนวาส ลักษณะโทนสีน้ำตาล (ของแท้)




รูปที่ ข.74 ตัวอย่างภาพกระเป๋าพื้นผิวจีซูพรีมแคนวาส ลักษณะโทนสีเทา (ของแท้)




รูปที่ ข.75 ตัวอย่างภาพกระเป๋าสานผิวออริจินัลจีจีแคนวาส ลักษณะโทนสีน้ำตาล (ของปลอม)



รูปที่ ข.76 ตัวอย่างภาพกระเป๋าพื้นผิวออริจินัลจีจีแคนवास ลักษณะโทนสีเทา (ของปลอม)




รูปที่ ข.77 ตัวอย่างภาพกระเป๋าสานผิวจิวูฟริมแคนวาส ลักษณะโทนสีน้ำตาล (ของปลอม)



รูปที่ ข.78 ตัวอย่างภาพกระเป๋าพื้นผิวจีจิวูฟริ้มแคนวาส ลักษณะโทนสีเทา (ของปลอม)







รูปที่ ข.79 ตัวอย่างภาพกระเป๋าสตูดอื่น

## ภาคผนวก ค


ตัวอย่างรุ่นกระเป๋าของแท้จำนวน 13 รุ่น

		
1. Gucci Abbey D-Ring shoulder bag	2. Gucci Abbey tote brown bag	3. Gucci Babouska boston tote bag
		
4. Gucci Crystal joy	5. Gucci Dionysus small GG bag	6. Gucci GG small web
		
7. Gucci GG web tote	8. Gucci Horsebit 1955 small shoulder bag	9. Gucci Jackie 1961 medium shoulder bag

		
<p>10. Gucci Jolie small tote</p>	<p>11. Gucci Princy small</p>	<p>12. Gucci tote kid bird</p>

		
<p>13. Gucci Ophidia medium tote with web</p>		

ตัวอย่างรุ่นกระเป๋าของปลอมจำนวน 10 รุ่น

		
<p>1. Gucci Abbey tote vintage</p>	<p>2. Gucci Charmy tote</p>	<p>3. Gucci Duchessa tote</p>

		
<p>4. Gucci Horsebit 1955 small shoulder bag</p>	<p>5. Gucci Sukey large GG canvas tote bag</p>	<p>6. Gucci Dionysus small GG shoulder bag</p>
		
<p>7. Gucci tote kid</p>	<p>8. Gucci Ophidia GG tote</p>	<p>9. Gucci Jackie 1961 medium shoulder bag</p>
		
<p>10. Gucci Ophidia GG small shoulder bag</p>		

## ประวัติผู้เขียน

ชื่อ-สกุล	ยศสรล อภิปวินท์วงศ์
วัน เดือน ปี เกิด	18 เมษายน 2537
สถานที่เกิด	กรุงเทพมหานคร
วุฒิการศึกษา	วิศวกรรมศาสตรบัณฑิต (วศ. บ.) สาขาวิชาวิศวกรรมเครื่องกล มหาวิทยาลัยเกษตรศาสตร์
ที่อยู่ปัจจุบัน	52/6 สวนมะลิซอย 1 เขตป้อมปราบศัตรูพ่าย แขวงวัดเทพศิรินทร์ ถนน มหาจักร กรุงเทพฯ 10100
ผลงานตีพิมพ์	1) Apipawinwongsa, P. & Limpiyakorn, Y. (2022). Counterfeit Luxury Handbag Materials Image Classification using Deep learning and Local Binary Pattern. International Journal of Emerging Technology and Advanced Engineering (IJETA), 12(9), pp.41-48. 2) Apipawinwongsa, P. & Limpiyakorn, Y. (2022). Deep Learning Techniques for Image Recognition of Counterfeited Luxury Handbags Materials. ICDIP 2022 14th International Conference on Digital Image Processing, Virtual Conference.