

การจำแนกพระเครื่องด้วยการเรียนรู้เชิงลึก

DRD
อรรถพล เรืองสุข

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
วิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาวิศวกรรมข้อมูลขนาดใหญ่
วิทยาลัยนวัตกรรมด้านเทคโนโลยีและวิศวกรรมศาสตร์
มหาวิทยาลัยธุรกิจบัณฑิตย์
ปีการศึกษา 2564

**CLASSIFICATION OF BUDDHA AMULETS USING DEEP
CONVOLUTIONAL NEURAL NETWORKS**

ATTAPOL ROUNGSOOK

**A Thesis Submitted in Partial Fulfillment of the Requirements for the
Degree of Master of Engineering, Department of Big Data Engineering**

College of Innovative Technology and Engineering,

Dhurakij Pundit University


Academic Year 2021




ใบรับรองงานวิทยานิพนธ์

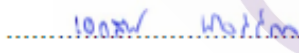
วิทยาลัยนวัตกรรมการด้านเทคโนโลยีและวิศวกรรมศาสตร์ มหาวิทยาลัยธุรกิจบัณฑิตย์
ปรีณญา วิศวกรรมศาสตรมหาบัณฑิต

หัวข้อวิทยานิพนธ์ การจำแนกพระเครื่องด้วยการเรียนรู้เชิงลึก
เสนอโดย อรรถพล เรืองสุข
สาขาวิชา วิศวกรรมข้อมูลขนาดใหญ่
อาจารย์ที่ปรึกษาวิทยานิพนธ์ ดร.ธนภัทร นังคะจิตร
ได้พิจารณาเห็นชอบโดยคณะกรรมการสอบวิทยานิพนธ์แล้ว


..... ประธานกรรมการ
(ดร.สรรพฤทธิ์ มฤคทัต)


..... กรรมการและอาจารย์ที่ปรึกษา
(ดร.ธนภัทร นังคะจิตร)


..... กรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.ดวงใจ จิตคงชื่น)


..... กรรมการ
(ดร.เอกสิทธิ์ พิชรวงศ์ศักดิ์)

วิทยาลัยนวัตกรรมการด้านเทคโนโลยีและวิศวกรรมศาสตร์รับรองแล้ว



.....
(ดร.ชัยพร เจมะภาคะพันธ์)

คณบดีวิทยาลัยนวัตกรรมการด้านเทคโนโลยีและวิศวกรรมศาสตร์

วันที่ 31 เดือน กรกฎาคม พ.ศ. 2565

หัวข้อวิทยานิพนธ์	การจำแนกพระเครื่องด้วยการเรียนรู้เชิงลึก
ชื่อผู้เขียน	อรรถพล เรืองสุข
อาจารย์ที่ปรึกษา	ดร.ธนภัทร นังคะจิตร
สาขาวิชา	วิศวกรรมข้อมูลขนาดใหญ่
ปีการศึกษา	2564

บทคัดย่อ

พระเครื่อง เป็นเครื่องรางที่ชาวพุทธนิยมบูชาแต่เป็นการยากในการที่ชาวพุทธจะสามารถแยกแยะชื่อพระเครื่องได้ทั้งหมดเนื่องจากมีพระเครื่องมีความหลากหลายและมีจำนวนมาก จึงมีงานวิจัยที่มีประสิทธิภาพดีในการจำแนกพระเครื่องจากภาพถ่ายจากสภาพแวดล้อมที่คงที่ งานวิจัยเหล่านั้นส่วนใหญ่ใช้เทคนิคการประมวลผลภาพหลายรูปแบบเพื่อสกัดคุณลักษณะต่างๆ (Features) และสร้างตัวจำแนกประเภทโดยใช้เทคนิคการเรียนรู้ด้วยเครื่อง (Machine learning) ซึ่งคุณภาพของคุณลักษณะที่สกัดออกมาจากภาพจะกลายเป็นตัวแปรสำคัญสำหรับประสิทธิภาพของตัวจำแนกประเภท ในงานวิจัยนี้เสนอโมเดลจำแนกพระเครื่องโดยการเรียนรู้เชิงลึกซึ่งเป็นโมเดลแบบ 2 ชั้นตอน ชั้นตอนแรกเป็นการทำนายชื่อพระเครื่องโดยใช้โครงข่ายประสาทเทียมที่ประยุกต์จากโครงข่าย Xception เมื่อทราบชื่อพระเครื่องแล้วชั้นตอนที่สองจึงทำนายชื่อรุ่นย่อยของพระเครื่องนั้น โดยทำการแยกสร้างโมเดลสำหรับแต่ละชื่อพระเครื่อง ซึ่งประยุกต์จากโครงข่ายประสาทเทียม CNNs ผลการทดสอบพบว่าแบบจำลองที่นำเสนอให้ความแม่นยำสูงทั้งในการทำนายชื่อพระเครื่องและชื่อพระเครื่องรุ่นย่อย ถึง 97% และ 98% ตามลำดับ ซึ่งให้ความแม่นยำที่สูงกว่าโมเดล CNNs ที่นิยมใช้กันค่อนข้างมาก อย่างไรก็ตามโมเดลที่นำเสนอยังมีความผิดพลาดในการทำนายในกรณีพระผงซึ่งมีรอยแตกและไม่สมบูรณ์ ซึ่งทำให้ดูคล้ายคลึงกับพระเครื่องรุ่นอื่น จึงจำเป็นต้องทำการเพิ่มตัวอย่างของข้อมูลรูปภาพในลักษณะนี้เข้าไปให้โมเดลเรียนรู้เพิ่มขึ้นในอนาคต

Thesis Title	CLASSIFICATION OF BUDDHA AMULETS USING DEEP CONVOLUTIONAL NEURAL NETWORKS
Author	ATTAPOL ROUNGSOOK
Thesis Advisor	Dr.Thanapat Kangkachit
Department	Big Data Engineering
Academic Year	2021

ABSTRACT

Buddha amulets are the representative of Buddha. They remind Buddhists to live their life in the right taught. Since there are a large number of amulet editions, one person cannot recognize every single edition. In the last few years, many works related to automated Buddha amulets classification in fixed environments have been proposed with satisfactory accuracy. Mostly, they applied several image processing techniques to extract features and then built the classifier using various machine learning techniques. Indeed, the quality of extracted features becomes an essential key to the effectiveness of classifiers. In this work, we propose a deep cascade CNNs model for effectively classifying the editions of Buddhist amulets. Firstly, a deep CNN model inspired from Xception is constructed to predict the name of Buddhist amulets. Secondly, a custom CNNs model is built separately for each amulets to specify its edition. Experimental results show that our model offers satisfactory accuracy of 97% and 98% when classifying the name of amulets and their editions, respectively. Compared to several well-known deep learning models, our model has less number of parameters while providing better accuracy. Notice that our model still makes incorrect predictions in case of incomplete amulet images. To improve the robustness of our model, it is necessary to further increase the number of this kind of image in the training dataset.

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงได้โดยการให้ความช่วยเหลือของ ดร.ธนภัทร ชังคะจิตร ซึ่งเป็นอาจารย์ที่ปริกษาสารนิพนธ์ ที่ได้กรุณาให้คำแนะนำ ตรวจสอบ และแก้ไขข้อบกพร่องต่าง ๆ มาโดยตลอด เพื่อให้สารนิพนธ์ฉบับนี้สมบูรณ์ รวมถึงผู้ที่ให้ความช่วยเหลือเพื่อทางด้านเทคนิค ผู้เขียนจึงขอกราบขอบพระคุณไว้ ณ โอกาสนี้

ขอบพระคุณ ประธานกรรมการสอบ ดร.สรรพททธิ์ มฤคพิต กรรมการ ดร.เอกสิทธิ์ พัทธวงศ์ศักดิ์ และ ผศ.ดร.ดวงใจ จิตรคงชื่น และเจ้าหน้าที่หลักสูตรวิศวกรรมศาสตรมหาบัณฑิต สาขาวิศวกรรมข้อมูลขนาดใหญ่ทุกท่านที่ให้ความรู้ คำปรึกษาและประสานงานให้วิทยานิพนธ์นี้สำเร็จลุล่วงด้วยดี

สุดท้ายนี้ขอขอบคุณครอบครัวและเพื่อนๆ ที่คอยช่วยส่งเสริม สนับสนุนและให้กำลังใจ ทำให้การศึกษาวิจัยในครั้งนี้สำเร็จลุล่วงไปด้วยดี

ด้วยความรู้ที่ได้ที่รับจากการศึกษา หลักสูตรนี้ผู้เขียนได้ความรู้พัฒนาองค์กรพัฒนาระบบเฝ้าระวังความเสียหาย และความล้มเหลวของการให้บริการทางด้านธุรกรรมการเงิน โดยใช้หลักการการจัดการวิศวกรรมข้อมูลขนาดใหญ่ และให้บริการได้อย่างมีประสิทธิภาพ แสดงให้เห็นถึงคุณภาพของหลักสูตรวิศวกรรมศาสตรมหาบัณฑิต สาขาวิศวกรรมข้อมูลขนาดใหญ่นี้ สามารถนำไปปฏิบัติงานได้จริง

อรรถพล เรืองสุข

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ฉ
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญตาราง.....	ช
สารบัญภาพ.....	ฉ
บทที่	
1. บทนำ.....	1
1.1 ที่มาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์ของงานวิจัย.....	2
1.3 ขอบเขตงานวิจัย.....	2
1.4 สมมติฐานของงานวิจัย.....	2
1.5 ประโยชน์ที่คาดว่าจะได้รับ.....	2
1.6 นิยามศัพท์.....	2
2. ทฤษฎี และผลงานวิจัยที่เกี่ยวข้อง.....	4
2.1 ภาพจิตทัศน์.....	3
2.2 การเรียนรู้ของเครื่องคอมพิวเตอร์.....	5
2.3 สถาปัตยกรรมโครงข่ายประสาทเทียม.....	5
2.4 การตรวจสอบวัตถุด้วยการเรียนรู้เชิงลึก.....	20
2.5 การวัดประสิทธิภาพ (Performance Evaluation).....	21
2.6 งานวิจัยที่เกี่ยวข้อง.....	23
2.7 พระเครื่องที่เลือกทำงานวิจัย.....	23
3. ระเบียบวิธีวิจัย.....	24
3.1 ขั้นตอนการดำเนินงานวิจัย.....	24
3.2 การเก็บรวบรวมข้อมูลสำหรับการทำวิจัย.....	25
3.3 แสดงรายชื่อพระเครื่องที่ใช้งานวิจัย.....	26
3.4 การเพิ่มชุดตัวอย่างข้อมูล (Data Augmentation).....	29
3.5 ออกแบบ โมเดลที่ใช้งานการทำนายพระเครื่อง.....	32

สารบัญ (ต่อ)

บทที่	หน้า
3.6 ออกแบบโมเดลทำนายชื่อพระเครื่องรุ่นย่อย.....	36
3.7 การทดสอบประสิทธิภาพ.....	36
4. ผลการศึกษา.....	40
4.1 ผลการทดสอบทำนายชื่อพระเครื่อง.....	40
4.2 ผลการทดสอบทำนายชื่อพระเครื่องรุ่นย่อย.....	44
5. บทสรุปและข้อเสนอแนะ.....	62
5.1 สรุปผลการศึกษา.....	62
5.2 ข้อเสนอแนะ.....	62
บรรณานุกรม.....	63
ประวัติผู้เขียน.....	67

สารบัญตาราง

ตารางที่	หน้า
2.1 ตัวอย่าง คอนฟิวชันเมทริกซ์ของการจำแนกแบบ 2 คลาส.....	22
4.1 ค่าพารามิเตอร์ในแต่ละโมเดล.....	41
4.2 ผลการทดลองทำนายชื่อพระเครื่องแบบรวมโดยใช้โมเดล Xception.....	42
4.3 แสดงผลทดสอบสองรุ่น โดยโมเดล Xception.....	43
4.4 แสดงการตั้งค่าพารามิเตอร์ที่ใช้ในการทดสอบรุ่นย่อยใช้สถาปัตยกรรมเดี่ยว เดียวกันกับรุ่นใหญ่.....	44
4.5 ผลการทดสอบทำนายชื่อรุ่นพระเครื่องรุ่นย่อยแบบผง โดยให้ Custom CNN...	45
4.6 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบผง โดยใช้โมเดล Custom VGG16.....	46
4.7 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบผงโดยใช้โมเดล RESNET.....	48
4.8 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบผงโดยใช้โมเดล EfficeinNet B0	50
4.9 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบผง โดยใช้โมเดล EfficeinNet B3	51
4.10 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบผง โดยใช้โมเดล Siamese.....	53
4.11 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบเหรียญโลหะ โดยใช้โมเดล Custom CNN.....	54
4.12 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบเหรียญโลหะ โดยใช้โมเดล Custom VGG16.....	56
4.13 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบเหรียญโลหะ โดยใช้โมเดล RESNET.....	57
4.14 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบเหรียญโลหะ โดยใช้โมเดล EfficeinNet B0.....	59
4.15 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบเหรียญโลหะ โดยใช้โมเดล EfficeinNet B3.....	60
4.16 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบเหรียญโลหะ โดยใช้โมเดล Siamese.....	61

สารบัญภาพ

ภาพที่	หน้า
2.1 แสดงตารางเมทริกซ์ของพิกเซลรูปภาพ.....	4
2.2 แสดงค่าสี RGB ในแต่ละพิกเซล.....	5
2.3 แสดงลำดับชั้นของการเรียนรู้และตัดสินใจด้วยเครื่อง.....	6
2.4 แสดงการทำงานของโครงข่ายประสาทเทียม.....	7
2.5 แสดงการทำงานของ เพอร์เซปตอน.....	7
2.6 แสดงกระบวนการทำงานของ Convolution neural network.....	9
2.7 แสดงกระบวนการสกัดคุณลักษณะของรูปภาพจากพิกเซล โดย Convolution...	9
2.8 แสดงรูปภาพที่ผ่านการทำงานของ ReLu.....	10
2.9 แสดงการทำงานของ Max-pooling.....	12
2.10 ภาพผลลัพธ์หลังการทำ Pooling.....	12
2.11 Neural Network Architectures: VGG.....	13
2.12 That filter of 5x5 and 7x7 can be decomposed with multiple 3x3.....	14
2.13 The new inception module.....	15
2.14 Decomposed by flattened Convolutions.....	15
2.15 Decrease the size of the data.....	16
2.16 Feed the output of two successive convolutional layer.....	16
2.17 Residual Networks (ResNet in Short).....	17
2.18 The Xception module.....	18
2.19 The Xception Architecture.....	18
2.20 Architecure of ENet.....	19
2.21 Initial block of ENet.....	20
2.22 Bottleneck module of ENet.....	20
2.23 แสดงสถาปัตยกรรมของโมเดล Siamese.....	21
2.24 Segmentation.....	22
3.1 แสดงการดำเนินการวิจัย.....	26
3.2 ตัวอย่างรูปพระเครื่องที่ใช้ในการวิจัย.....	27

สารบัญภาพ (ต่อ)

ภาพที่	หน้า
3.3 ตัวอย่างภาพสี่ พระเครื่องรุ่นย่อยที่ใช้ในการวิจัย.....	27
3.4 แสดงรายชื่อพระเครื่องที่ใช้ในงานวิจัย.....	28
3.5 แสดงรายชื่อพระเครื่องแบบผง.....	29
3.6 แสดงจำนวนพระเครื่องแบบผง.....	29
3.7 แสดงรายชื่อพระเครื่องแบบเหรียญ.....	30
3.8 แสดงจำนวนพระเครื่องแบบเหรียญ.....	30
3.9 แสดงจำนวนพระเครื่องแบบผง และ แบบเหรียญ.....	31
3.10 แสดงการปรับรูปภาพ กลุ่มขนาดและตำแหน่ง.....	32
3.11 แสดงการปรับรูปภาพ ภาพขาวดำ.....	32
3.12 แสดงการปรับรูปภาพแบบซูม.....	33
3.13 แสดงการเพิ่มข้อมูลภาพ แบบ CLAHE.....	33
3.14 แสดงจำนวนข้อมูลหลังเพิ่มชุดข้อมูล.....	34
3.15 แสดงสถาปัตยกรรม Xception สำหรับการทำงานวิจัย.....	34
3.16 แสดงสถาปัตยกรรม CNN ที่ได้ออกแบบเพื่อใช้ในการทำนายพระเครื่อง รุ่นย่อย.....	36
3.17 กราฟแสดงจำนวนพระเครื่องแบ่งจำนวน Train 80 % : Validation:10% : Test 10%.....	38
3.18 แสดงตัวอย่าง Matrix confusion 10 Class และ 20 Class.....	39
4.1 แสดงการแบ่งข้อมูลเพื่อใช้ในการทดสอบ.....	40
4.2 แสดงตัวอย่างรูปภาพที่ใช้ในการทดสอบ.....	41
4.3 แสดงจำนวนข้อมูลที่ใช้ในการทดสอบทำนายชื่อพระเครื่อง.....	42
4.4 แสดงการสอนของสองรุ่นโดยใช้โมเดล Xception.....	43
4.5 ผลการทดสอบทำนายชื่อรุ่นพระเครื่องรุ่นย่อยแบบผงโดยให้ Custom CNN	46
4.6 แสดงภาพที่ทำนายผิด ชื่อ พระสมเด็จระฆังพิมพ์ใหญ่เศศจรดซุ้มเป็นพระ สมเด็จระฆังพิมพ์ใหญ่เศศทะลุซุ้ม.....	47

สารบัญภาพ (ต่อ)

ภาพที่	หน้า
4.7 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบผง โดยใช้โมเดล Custom VGG16.....	47
4.8 แสดงชื่อรุ่นที่ทำนายผิด ชื่อรุ่น พระสมเด็จพิมพ็อกครุฑ และพระสมเด็จเกษทะลุซุ้ม.....	47
4.9 แสดงการตั้งค่าพารามิเตอร์สำหรับโมเดล RestNet50.....	48
4.10 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบผง โดยใช้โมเดล RESNET.....	49
4.11 แสดงการตั้งค่าพารามิเตอร์สำหรับโมเดล EfficeinNet B0.....	50
4.12 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบผง โดยใช้โมเดล EfficeinNet B0.....	50
4.13 ตัวอย่างรูปที่ทำนายชื่อผิด โดยใช้โมเดล EfficeinNet B0.....	51
4.14 แสดงการตั้งค่าพารามิเตอร์สำหรับโมเดล EfficeinNet B3.....	52
4.15 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบผง โดยใช้โมเดล EfficeinNet B3.....	52
4.16 ตัวอย่างรูปที่ทำนายชื่อผิดโดยใช้โมเดล EfficeinNet B3.....	52
4.17 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบผง โดยใช้โมเดล Siamese....	53
4.18 แสดงตัวอย่างข้อมูลพระเครื่องแบบเหรียญที่ใช้ในทดลอง.....	54
4.19 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบเหรียญโลหะโดยใช้โมเดล Custom CNN.....	55
4.20 ตัวอย่างรูปที่ทำนายชื่อผิด โดยใช้โมเดล CNN.....	55
4.21 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบเหรียญโลหะโดยใช้โมเดล Custom VGG16.....	56
4.22 แสดงค่าพารามิเตอร์โมเดล RESNET.....	57
4.23 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบเหรียญโลหะโดยใช้โมเดล RESNET.....	58
4.24 แสดงค่าพารามิเตอร์โมเดล RESNET.....	59

สารบัญภาพ (ต่อ)

ภาพที่	หน้า
4.25 แสดงผลการทดสอบพระเครื่องรุ่นย่อแบบเหรียญโลหะโดยใช้โมเดล EfficeinNet B0.....	59
4.26 แสดงการตั้งค่าพารามิเตอร์สำหรับโมเดล EfficeinNet B3.....	60
4.27 แสดงผลการทดสอบพระเครื่องรุ่นย่อแบบเหรียญโลหะโดยใช้โมเดล EfficeinNet B3.....	61
4.28 แสดงผลการทดสอบพระเครื่องรุ่นย่อแบบเหรียญโลหะโดยใช้โมเดล Siamese.....	62



บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญของปัญหา

ประเทศไทยเป็นที่รู้จักในฐานะประเทศพุทธศาสนา คนไทยที่นับถือศาสนาพุทธที่มีความศรัทธา และใช้ชีวิตตามคำสอนของพระพุทธเจ้า โดยเน้นเรื่องทำความดี หลีกเลี่ยงการทำชั่ว และทำจิตใจให้บริสุทธิ์ พระเครื่องถือเป็นเครื่องรางที่ถูกสร้างขึ้นเพื่อเป็นตัวแทนของพระพุทธเจ้า หรือ พระสงฆ์ ชาวพุทธสามารถนำเครื่องรางเหล่านั้นติดตัวไปด้วยเพื่อเตือนสติในการประพฤติตนเป็นคนดี โดยทั่วไปพระเครื่องที่มีชื่อเสียง จะมีอริยาบทในท่าต่าง ๆ อย่างไรก็ตามเนื่องจากมีพระเครื่องจำนวนมาก จึงเป็นไปได้ที่บุคคลหนึ่งจะสามารถจดจำพระเครื่องได้ทั้งหมด เมื่อพิจารณาจากการจำแนกพระเครื่อง ในอดีตที่ผ่านมานักวิจัยชาวไทยได้เสนอผลงาน เพื่อจำแนกประเภทหรือระบุชื่อ รวมถึงได้มีการนำเสนอวิธีการสกัดคุณลักษณะที่มีความหมาย (Feature Extraction) โดยใช้เทคนิคการประมวลผลภาพ (Image Processing) เช่น การตรวจจับมุม, การตรวจจับลายน้ำ, การตรวจสอบขอบ, การแปลงคุณลักษณะที่ไม่แปรเปลี่ยนไปตามขนาด [3] จากนั้นในขั้นตอนการจัดหมวดหมู่ ได้สร้างเครื่องมือแยกประเภทโดยใช้เทคนิคการเรียนรู้ด้วยเครื่อง (Machine Learning) เช่น ใช้ K-Nearest Neighbors ใน และ Neuron Networks ผลงานทั้งหมดเหล่านี้มีความแม่นยำพอสมควร อย่างไรก็ตามภาพอินพุตของงานวิจัยเหล่านี้ต้องอยู่ในสภาพแวดล้อมแบบคงที่ (เช่นในสตูดิโอถ่ายภาพ) เพื่อให้ได้ภาพที่มีคุณภาพดี

เครือข่ายประสาทเทียมลึก (DCNNs) มีบทบาทสำคัญในงานวิจัยด้านคอมพิวเตอร์วิทัศน์ (Computer vision) เมื่อใช้ DCNNs ความถูกต้องที่เพิ่มขึ้นได้รับการรายงาน จากการจำแนกประเภทวัตถุ ImageNet ในรูปภาพ ImageNet-2014 โดยโมเดล VGG-19 และ GoogLeNet ได้อันดับสองอันดับแรก VGG-19 ถูกนำเสนอด้วยเครือข่ายลึกลึกหนาแน่นมากถึง 19 ชั้น นอกจากนี้ GoogLeNet ประกอบด้วย Meta-layer ที่เริ่มต้นซึ่งมีความละเอียดของตัวกรอง convolution filter หลายแบบการเลียนแบบการรับรู้ของมนุษย์ ไม่มีงานใดที่มีอยู่ที่ใช้ CNNs ในการจำแนกพระเครื่อง

พระเครื่อง อย่างไรก็ตามมีงานวิจัยในต่างประเทศที่ใช้ CNNs ในการจำแนกเหรียญโบราณซึ่ง ซึ่งมีความคล้ายคลึงกับพระเครื่อง ของศาสนาพุทธ มีงานวิจัยที่ เสนอแบบจำลองเพื่อแยกเหรียญโรมันโบราณ โมเดล CNNs นี้ถูกใช้เพื่อระบุรูปแบบใบหน้าของจักรพรรดิที่ปรากฏบนด้านของเหรียญได้เช่นเดียวกับผู้เชี่ยวชาญของมนุษย์ โมเดล CNNs นี้ยังให้ประสิทธิภาพที่น่าพึงพอใจ ดังนั้นเหรียญโบราณของโรมันมีความคล้ายคลึงกันที่รายละเอียดด้านข้างของพระเครื่องสามารถระบุความแตกต่างกันได้ เช่น พระพุทธรูปหรือพระภิกษุที่มีชื่อเสียง มีอริยาบทในท่าต่างๆ ซึ่งไม่เหมือนกับเหรียญโรมันที่มีรูปใบหน้าเพียงอย่างเดียว นี่เป็นเหตุผลว่าทำไมโมเดล CNNs ของการจำแนกเหรียญโรมัน ไม่สามารถนำมาใช้กับการจำแนกพระเครื่องได้ทันที

งานวิจัยนี้ต้องการนำเสนอ วิธีการจำแนกประเภทพระเครื่องโดยใช้ Deep learning ด้วยเทคนิค Xception , VGG , EfficeinNet, ResNet และ One-shot learning ซึ่งใช้ความสามารถของ CNNs และแยกส่วนการค้นคุณลักษณะเด่นของรูปภาพ และมีการชดเชยในส่วนที่หายไปจากการลดรูปเพื่อให้ได้ความสมบูรณ์ให้การทำนายมากที่สุด รวมถึงเสนอการออกแบบโมเดลที่ใช้จำนวนพารามิเตอร์ให้น้อยลงแต่ยังคงให้ประสิทธิภาพที่ดีในการทำนายผล นอกจากนี้ในจำนวนพระเครื่องที่มีชื่อเดียวกันประกอบไปด้วยหลายรุ่นย่อย ในการทำนายชื่อพระเครื่องรุ่นย่อยที่มีองค์ประกอบคล้ายกันจำเป็นต้องมีโมเดลเฉพาะรุ่น เพื่อให้เกิดความแม่นยำในการทำนายชื่อพระเครื่องรุ่นย่อย

โดยงานนี้จึงนำเสนอโมเดลแบบ 2 ขั้นตอนสำหรับทำนายชื่อพระเครื่องในขั้นตอนแรก หลังจากนั้นจึงทำนายชื่อพระเครื่องรุ่นย่อย โดยทำการออกแบบโมเดลที่ใช้สถาปัตยกรรม CNNs ที่มีโครงสร้างเดียวกันทั้งสองขั้นตอน ผลการทดสอบพบว่าแบบจำลองที่นำเสนอให้ความแม่นยำสูงทั้งในการทำนายชื่อพระเครื่องและชื่อพระเครื่องรุ่นย่อย ถึง 97% และ 98% ตามลำดับ อย่างไรก็ตามโมเดลที่นำเสนอมีความผิดพลาดในการทำนายในกรณีที่พระเครื่องมีลักษณะที่ไม่สมบูรณ์ซึ่งทำให้คล้ายคลึงกับพระเครื่องอีกรุ่น ดังนั้นงานนี้จึงนำเสนอโมเดลที่ทำงานร่วมกัน โดยโมเดลแรกจะทำนายชื่อพระเครื่อง และโมเดลที่สองจะทำนายชื่อรุ่นย่อย ผลการทดสอบปรากฏว่าสามารถทำนายชื่อได้อย่างมีประสิทธิภาพ

1.2 วัตถุประสงค์ของการศึกษาหรือวิจัย

1. เพื่อให้สามารถระบุชื่อพระเครื่องได้อย่างถูกต้อง
2. เพื่อให้สามารถจำแนกพระเครื่องในรุ่นย่อยได้อย่างมีประสิทธิภาพ

1.3 ขอบเขตของงานวิจัย

1. ข้อมูลรูปพระเครื่องแบบพระพิมพ์ และ พระเหรียญโลหะ จำนวน 3,456 รูป
2. ข้อมูลรูปพระเครื่องแบบพระพิมพ์ สมเด็จจิวตบางขุนพรหมลึกรุ่นย่อย จำนวน 350 รูป
3. ข้อมูลรูปพระเครื่องแบบเหรียญโลหะ หลวงพ่อคุณ จำนวนลึกรุ่นย่อย จำนวน 500 รูป

1.4 สมมติฐานของงานวิจัย

1. การเรียนรู้เชิงลึกมีความสามารถในการจำแนกรูปภาพได้ ดังนั้นจึงนำรูปพระเครื่องมาเป็นข้อมูลเพื่อให้จำแนกพระเครื่องและบ่งบอกชื่อได้ถูกต้อง
2. ใช้รูปพระเครื่องที่มีรูปจริงในเครือข่ายสาธารณะ และสภาพแวดล้อมในการถ่ายรูปที่ต่างกัน
3. บุคลากร การเรียนรู้เชิงลึกในแบบต่างๆ เพื่อให้เกิดประสิทธิภาพสูงสุด

1.5 ประโยชน์ที่คาดว่าจะได้รับ

1. โมเดล การเรียนรู้เชิงลึกสามารถนำไปใช้งาน อย่างมีประสิทธิภาพ
2. สามารถจำแนกพระเครื่องแบบพิมพ์ และ เหรียญโลหะได้
3. สามารถนำไปต่อยอด และพัฒนาเป็น โปรแกรมสำเร็จรูปและให้บริการและแก่ประชาชนทั่วไปในแบบ ออนไลน์ได้

1.6 นิยามศัพท์

1. พระเครื่องแบบพิมพ์ หรือ พระผง คือ มีส่วนผสม ปูนเปลือกหอย ขางไม้ น้ำอ้อย หรือขี้ผึ้ง ชั้นดี เป็นส่วนผสม และแกะสลักไม้เป็นแม่พิมพ์ แล้วนำมากดทับเพื่อให้เป็นรูปพระตามแบบพิมพ์

2. พระเครื่องแบบโลหะ หรือ พระเหรียญ คือ เริ่มมีครั้งแรกในประเทศไทย เมื่อรัชสมัย พระบาทสมเด็จพระจุลจอมเกล้าเจ้าอยู่หัว ซึ่งถือเป็นการจำลองสิ่งศักดิ์สิทธิ์ไม่ว่าจะเป็น สถานที่ ศักดิ์สิทธิ์ พระพุทธรูป พระคณาจารย์ตลอดจนผู้ที่ควรเคารพ นำมาแกะสลักทำแม่พิมพ์ เพื่อการ ปั้น หรือ หล่อลงในแผ่น โลหะให้ปรากฏรูปที่ต้องการ



บทที่ 2

ทฤษฎี และผลงานวิจัยที่เกี่ยวข้อง

ในการวิจัยครั้งนี้ได้ทำการศึกษาค้นคว้าข้อมูลทฤษฎีและงานวิจัยที่เกี่ยวข้องกับการจำแนกพระเครื่อง ด้วยระบบคอมพิวเตอร์โดยสามารถแบ่งเป็นหัวข้อหลัง ดังต่อไปนี้

- 2.1 ภาพดิจิทัล
- 2.2 การเรียนรู้ของเครื่องคอมพิวเตอร์
- 2.3 สถาปัตยกรรมโครงข่ายประสาทเทียม
- 2.4 การตรวจสอบวัตถุด้วยการเรียนรู้เชิงลึก
- 2.5 การวัดประสิทธิภาพ (Performance Evaluation)
- 2.6 งานวิจัยที่เกี่ยวข้อง
- 2.7 พระเครื่องที่เลือกทำงานวิจัย

2.1 ภาพดิจิทัล

ภาพดิจิทัล เป็นการแสดงผลภาพในลักษณะสองมิติในหน่วยที่เรียกว่าพิกเซล ภาพดิจิทัลสามารถนิยามเป็นฟังก์ชันสองมิติ $f(x, y)$ โดยที่ x และ y เป็นพิกัดของภาพ และแอมพลิจูดของ f ที่พิกัด (x, y) ใดๆภายในภาพคือค่าความเข้มแสงของภาพ (Intensity) ที่ตำแหน่งนั้นๆ และเมื่อ x, y และแอมพลิจูดของ f เป็นค่าจำกัด (Finite value) จึงเรียกรูปภาพนี้เป็นภาพดิจิทัล (Digital Image) และถ้ากำหนดให้ภาพ $f(x, y)$ มีขนาด M แถวและ N คอลัมน์ และพิกัดของจุดกำเนิด (Origin) ของภาพคือที่ตำแหน่ง $(x, y) = (0, 0)$ แล้ว จะสามารถเขียนสมการให้อยู่ในรูปเมทริกซ์ได้ดังนี้

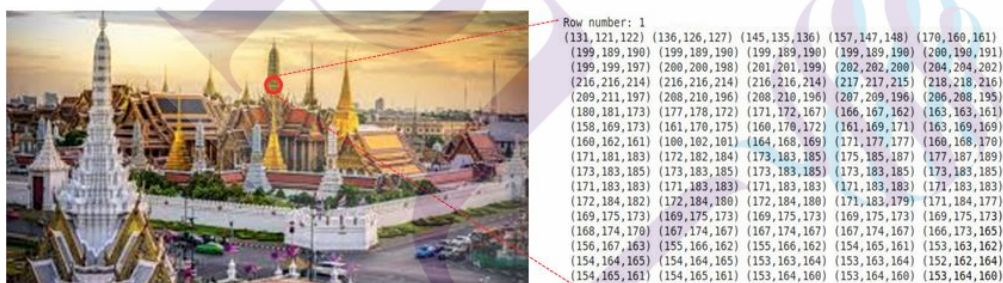
$$f(x, y) = \begin{bmatrix} f(0,0) & f(0,1) & \dots & f(0,N-1) \\ f(1,0) & f(1,1) & \dots & f(1,N-1) \\ \vdots & \vdots & & \vdots \\ f(M-1,0) & f(M-1,1) & \dots & f(M-1,N-1) \end{bmatrix}$$

ภาพที่ 2.1 แสดงตารางเมทริกซ์ของพิกเซลรูปภาพ

ตัวเลขแต่ละค่าที่อยู่ในเมทริกซ์จะเรียกว่า พิกเซล (Pixel) โดยตำแหน่ง (0,0) จะอยู่ทางด้านซ้ายมือสุดด้านบนของภาพ การจัดลำดับตำแหน่งของจุดภาพจะเรียงจากซ้ายไปขวาในแต่ละเส้นจุดและจัดลำดับของเส้นจุดจะเรียงจากบนลงล่างการเก็บค่าของความเข้มแสงของภาพ ดิจิทัลลงหน่วยความจำในลักษณะเส้นจุด(raster)นี้จะเรียกภาพบิตแมป (bit-mapped image) หรือภาพแรสเตอร์(raster image) แต่ภาพที่จัดเก็บในลักษณะนี้จะมีขนาดใหญ่จึงมีการบีบอัดภาพ(image compression) เพื่อให้ข้อมูลภาพมีขนาดเล็กลง

การสร้างภาพดิจิทัลสามารถสร้างได้จากอุปกรณ์รับภาพเช่น กล้องดิจิทัล(digital cameras) เครื่องกราดภาพ(scanners) เป็นต้น ภาพดิจิทัลยังสามารถสร้างโดยการสังเคราะห์จากสิ่งที่ไม่ใช่ข้อมูลภาพเช่น ฟังก์ชันทางคณิตศาสตร์ หรือ แบบจำลองเรขาคณิตแบบสามมิติซึ่งการสร้างภาพลักษณะนี้เป็นส่วนหนึ่งในงานด้านคอมพิวเตอร์กราฟิกส์ (computer graphics)

2.1.1 ภาพสี (Color-Image) ภาพในระบบสี RGB คือ เมทริกซ์ขนาด 2D ซ้อนกันจำนวน 3 เมทริกซ์ ซึ่งแสดงค่าความเข้มของแสงสีแดง (R) 8 บิต สีเขียว (G) 8 บิต และสีน้ำเงิน (B) 8 บิต ดังนั้นภาพสีในระบบ RGB จะมีจำนวนบิตต่อจุดภาพทั้งหมด 24 บิต ทำให้สามารถแสดงสีได้ถึง 16,777,216 สี ดังแสดงในภาพ



ภาพที่ 2.2 แสดงค่าสี RGB ในแต่ละพิกเซล

2.1.2 ภาพสีเทา (Gray-scale Image) จะอยู่ในรูปแบบของความเข้มแสงในแต่ละจุดภาพ โดยจะมีระดับความเข้มสีเทา คือ 0 – 255 (8 บิต) โดยสีค่าจะแทนด้วยค่าตัวเลข 255 สีขาวจะแทนด้วยค่าตัวเลขคือ 0 รวมทั้งสิ้น 256 ระดับสี ดังแสดงในภาพที่ 2.1.2 ถึงแม้ว่าภาพระดับสีเทาก็จะมีความซับซ้อนมากกว่าภาพขาว-ดำ แต่ภาพสีเทาก็สามารถให้ข้อมูลได้กว้างขวางมากกว่าภาพขาว-ดำ

2.2 การเรียนรู้ของเครื่องคอมพิวเตอร์


ปัจจุบันการใช้เครื่องคอมพิวเตอร์ ประมวลผล และตัดสินใจ เป็นที่นิยมอย่างแพร่หลาย เนื่องจากประสิทธิภาพของ ฮาร์ดแวร์มีความสามารถสูงขึ้น และยังมีราคาที่ถูกลงทำให้ นักวิจัย และองค์กรเอกชนสามารถเข้าถึงได้ทุกระดับทำให้การศึกษา และใช้งานการเรียนรู้ด้วยเครื่อง (Machine learning = ML) เป็นที่แพร่หลาย และทุกองค์กรมีความต้องการจะใช้ระบบ ปัญญาประดิษฐ์ (Artificial intelligence = AI) ที่มีโครงสร้างที่ใหญ่กว่ามาก เพื่อสร้างผลตอบแทนธุรกิจให้กับองค์กร อย่างไรก็ตามการที่ปัญญาประดิษฐ์จะวิเคราะห์และสามารถตัดสินใจได้นั้น ต้องผ่านการเรียนรู้เสียก่อน เช่นเดียวกับมนุษย์ นอกจากการเรียนรู้ด้วยเครื่องแล้ว ยังมีการเรียนรู้เชิงลึก (Deep learning = DL) ที่สามารถใช้ในการสอนเครื่องคอมพิวเตอร์ได้อย่างรวดเร็วอีกด้วย




ภาพที่ 2.3 แสดงลำดับขั้นของการเรียนรู้และตัดสินใจด้วยเครื่อง

2.3 สถาปัตยกรรมโครงข่ายประสาทเทียม

กล่าวถึงโครงข่ายประสาทเทียมที่กำลังได้รับความนิยมเป็นอย่างมากในวงการ การเรียนรู้เชิงลึกโดยอาศัย โครงข่ายประสาทเทียมเป็นแม่แบบในการทำงาน คือมีการเชื่อมโยงของเซลล์ประสาท มากมายเป็นจำนวนมาก และแบ่งเป็นชั้นการทำงาน โดยในแต่ละชั้นจะส่งผ่านความรู้ต่อให้ชั้นถัดไป เพื่อทำการวิเคราะห์ ข้อมูลและส่งต่อไปเป็นทอดๆ ในชั้นที่มีความซับซ้อนมากขึ้น จำนวนชั้นนั้นขึ้นอยู่กับความสามารถของเครื่องคอมพิวเตอร์ และชั้นแสดงผลจะบอกความหมายของ อินพุตว่าคืออะไร



ภาพที่ 2.4 แสดงการทำงานของโครงข่ายประสาทเทียม



ภาพที่ 2.5 แสดงการทำงานของเพอร์เซปตรอน

เป็นการคำนวณและส่งผ่านข้อมูลไปในทิศทางเดียวการคำนวณผลลัพธ์ในแต่ละโหนดได้โดยสมการต่อไปนี้

โครงข่ายประสาทเทียม เป็นกระบวนการ ทางคณิตศาสตร์ที่จำลองมาจากการทำงานของระบบสมองของมนุษย์เพื่อนำ มาใช้ประโยชน์ในการตัดสินใจ การทำ นายการจำแนก และอื่นๆ รูปแบบของโครงข่ายประสาทเทียมพื้นฐานจะประกอบด้วยเซลล์ประสาท (Neuron) เพียง1เซลล์ซึ่งเราเรียกว่าสถาปัตยกรรมเพอร์เซปตรอน (Perceptron Architecture) โดยที่อินพุตต่างๆ จะถูกส่งผ่านกลุ่มใยประสาทนำ เข้า(Dendrites) เข้าสู่เซลล์ประสาท เพื่อทำ การประมวลผลและส่งผลลัพธ์ ออกมาทางแกนประสาท (Axon) โดยการ โครงข่ายเพอร์เซปตรอนเป็นพื้นฐานและเป็นต้นแบบของ

โครงข่ายประสาทเทียมชนิดอื่นๆ อีกทั้งสถาปัตยกรรมเพอร์เซปตรอนแบบหลายชั้น (Multi-Layer Perceptron: MLP) ใช้ขั้นตอนการเรียนรู้แบบแพร่ย้อนกลับ (Back Propagation Learning Algorithm) ซึ่งวิธีการนี้สามารถแก้ปัญหาที่มีความซับซ้อนได้อย่างมีประสิทธิภาพ สถาปัตยกรรมเพอร์เซปตรอนแบบหลายชั้นจะประกอบไปด้วยชั้นอินพุต (Input Layer) ชั้นซ่อน (Hidden Layer) และชั้นเอาต์พุต (Output Layer)

2.3.1 การเรียนรู้แบบมีผู้สอน (Supervised learning)

การเรียนรู้แบบมีผู้สอนนั้นต้องการชุดข้อมูลอินพุตและเอาต์พุตเป้าหมายเป็นชุดฝึกสอนควบคู่ (training pair) โดยปกติการสอนโครงข่ายนั้นจะใช้ชุดฝึกสอนควบคู่กันหลายชุด ในระหว่างการสอนโครงข่ายจะเกิดเอาต์พุตจริงแตกต่างจากเอาต์พุตเป้าหมายทำให้ได้ค่าความคลาดเคลื่อนหรือ ค่าความผิดพลาด โดยโครงข่ายจะเรียนรู้ข้อมูลทั้งสองโดยการปรับค่าน้ำหนักเพื่อลดค่าความแตกต่างหรือ ค่าความผิดพลาดระหว่างของตัวแปรเอาต์พุตของโครงข่ายกับค่าของข้อมูลเอาต์พุตที่ต้องการให้น้อยที่สุด การปรับค่าน้ำหนักจะปรับทีละน้อยๆ โดยกระบวนการทำซ้ำกับข้อมูลที่ละชุด จนกระทั่งค่าน้ำหนักในโครงข่ายลู่เข้า ซึ่งทั้งหมดนี้เรียกว่า การเรียนรู้ จากนั้นเมื่อเราป้อนค่าข้อมูลอินพุตล่าสุดซึ่งเป็นข้อมูลชุดใหม่ก็จะค่าตัวแปรเอาต์พุตโครงข่าย เมื่อโครงข่ายทำการเรียนรู้แล้วก็จะป้อนข้อมูลอินพุตล่าสุดให้กับโครงข่าย เพื่อจะหาค่าของตัวแปรเอาต์พุตซึ่งคือค่าผลการทำนายหรือระบุค่าหรือวลีสำคัญ เป็นต้น


2.3.2 การเรียนรู้แบบไม่มีผู้สอน (Unsupervised learning)

การเรียนรู้แบบไม่มีผู้สอนนั้นได้ถูกพัฒนาเพื่อให้ใกล้เคียงกับระบบการเรียนรู้ของสมองมนุษย์มากยิ่งขึ้น โดยจะมีเพียงชุดข้อมูลอินพุตเท่านั้น จากนั้น กระบวนการเรียนรู้จะใช้หลักทางสถิติ โดยหาค่าทางสถิติของชุดฝึกสอน และทำการจัดกลุ่มข้อมูลออกเป็นระดับต่างๆ โดยโครงข่ายประสาทเทียมจะหาค่าเอาต์พุตเองจากความสัมพันธ์ระหว่างข้อมูลอินพุตและเอาต์พุต

2.3.3 การเรียนรู้เชิงบังคับ (Reinforcement learning)


การเรียนรู้เชิงบังคับนั้นเป็นการเรียนรู้แบบมีผู้สอนและไม่มีผู้สอน โดยจะใช้การเรียนรู้แบบไม่มีผู้สอนในระหว่างการสอนที่มีเพียงชุดข้อมูลอินพุต และจะใช้การเรียนรู้แบบมีผู้สอนคือเมื่อได้ค่าเอาต์พุตและจะทำการบอกว่าถูกหรือผิดแต่จะไม่บอกว่าเอาต์พุตที่ถูกคืออะไร

2.3.4 คอนโวลูชัน(Convolution)



ภาพที่ 2.6 แสดงกระบวนการทำงานของ Convolution neural network

คอนโวลูชันเป็นกระบวนการที่ทำงานเพื่อสกัดเอาลักษณะสำคัญจากภาพออกมา โดยการใช้ค่าพิกเซล โดยค่าพิกเซลได้มาจากการมองของกล้องทั่วไปนั้นมีด้วยกันสามแชนแนล (Channel) แบ่งเป็นสีได้แก่ สีแดง, น้ำเงิน และเขียว โดยแต่ละจุดสามารถแทนค่าด้วยตัวเลขเพื่อบอกความเข้มของสีนั้นได้ โดยมีค่าตั้งแต่ 0 ถึง 255 จากความเข้มน้อยไปหามาก โดยในการทำภาพขาวดำแชนแนลของภาพนั้น จะมีเพียงหนึ่งแชนแนลเท่านั้นคือแชนแนลของสีเทา ซึ่งค่าตัวเลข 0 นั้นคือสีขาวไล่ไปจนถึง 255 ซึ่งเป็นสีดำสนิทตามรูปที่ 2.3.4 ในแต่ละชุดการทำการคำนวณแล้วเก็บไว้ ตัวอย่างการทำงานของคอนโวลูชัน



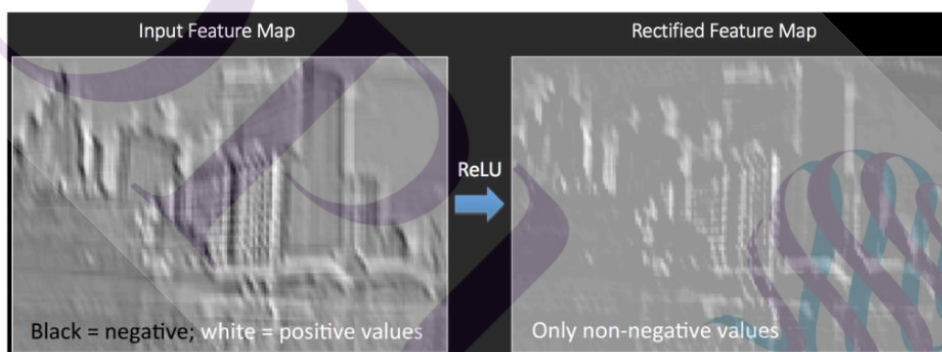
ภาพที่ 2.7 แสดงกระบวนการสกัดคุณลักษณะของรูปภาพจากพิกเซล โดย Convolution

2.3.5 การจำกัดค่าความเป็นเชิงเส้น (Activation Function)

การหาค่า เอาต์พุต ของโหนด เนื่องจาก เอาต์พุตมีค่าตั้งแต่ -1 จนถึง 1 ดังนั้นการเลือกค่าเอาต์พุต จึงมีความสำคัญ โดยมี Function ที่ทำหน้าที่เลือก โดยใช้หลักการทางคณิตศาสตร์เพื่อให้มีความถูกต้องโดยสามารถอธิบายได้ดังนี้

2.3.5.1 รีลู่ (ReLU)


หลังจากได้ทำการคอนโวลูชันรูปภาพและได้พีเจอร์แมพมาทำการปรับแต่งให้พีเจอร์แมพไม่เป็นลักษณะเชิงเส้น ด้วยวิธีการ ReLU ทำการแทนที่ผลของพิกเซลที่มีค่าเป็นเชิงลบ ในพีเจอร์แมพด้วยค่า 0 จุดประสงค์ของการทำ ReLU นั้นเพื่อให้โครงข่ายประสาทเทียมแบบสังวัตนาการ เรียนรู้ข้อมูลที่ไม่เป็นเชิงเส้นจากภาพ เมื่อนำภาพเข้าสู่กระบวนการที่เป็นพีเจอร์แมพเข้ามาทำ ReLU โดยสีดำ ในภาพเป็นค่าเชิงลบและสีขาวในภาพ เป็นค่าเชิงบวกเมื่อทำการ ReLU ค่าที่ได้ จะมีเพียงค่าที่เป็นเชิงบวก



ภาพที่ 2.8 แสดงรูปภาพที่ผ่านการทำงานของ ReLU


จากการทำงานค่าของฟังก์ชันถ้าค่านั้นน้อยกว่า 0 ผลลัพธ์จะออกมาเป็น 0 แต่ถ้ามีค่ามากกว่า 0 ผลลัพธ์ก็จะออกมาเป็นค่านั้นๆ เลย คำนวณได้จากสมการ

$$\max(0, x)$$




2.3.5.2 Sigmoid Function เป็นฟังก์ชันที่ให้ค่าอยู่ระหว่าง 0 ถึง 1 คำนวณได้จากสมการ

$$\sigma(x) = \frac{1}{1 + e^{-x}}$$




2.3.5.3 Hyperbolic Tangent (tanh) เป็นฟังก์ชันที่ให้ค่าอยู่ระหว่าง -1 ถึง 1 คำนวณได้จากสมการ

$$\tanh(x)$$



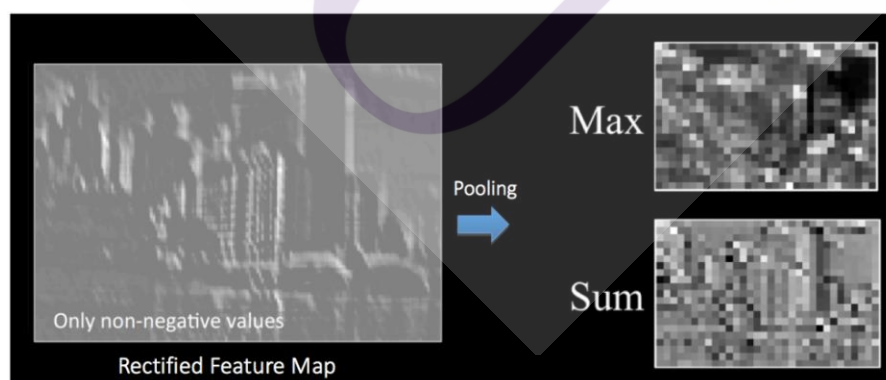
2.3.6 การพูลลิ่ง (Pooling)

การพูลลิ่ง ช่วยลดมิติของฟีเจอร์แมพลง แต่ยังคงรักษาข้อมูลสำคัญไว้ การพูลลิ่งสามารถจำแนกเป็นประเภทต่างได้เช่น พูลลิ่งด้วยค่าสูงสุด (Max Pooling), ค่าเฉลี่ย (Average Pooling), ผลรวมหรืออื่นๆการพูลลิ่ง ทำให้ผลลัพธ์ที่ได้มีขนาดเล็กและจัดการได้ง่ายขึ้น นอกจากนี้ยังลดจำนวนพารามิเตอร์และการคำนวณที่เกินจำเป็นในโครงข่าย ในกรณีที่ต้องการพูลลิ่งด้วยค่าสูงสุด จะกำหนดตัวกรองข้อมูลขึ้นมา (filter) ตัวอย่างในที่นี้สมมติให้ตัวกรองข้อมูล มีขนาด 2x2 และตัวกรองข้อมูลนี้จะทำการเคลื่อนที่ทีละ 2 พิกเซล ไปจนทั่วเมทริกซ์ของ ฟีเจอร์แมพเพื่อทำการเก็บค่าที่สูงที่สุดในทุกๆ 2 พิกเซล



ภาพที่ 2.9 แสดงการทำงานของ Max-pooling

นอกจากนี้การพูลลิ่งจะทำตามจำนวนแกนแนลของภาพซึ่งในกรณีภาพสีเราจะได้รับผลลัพธ์ออกมาถึงสามผลลัพธ์เมื่อฟีเจอร์แมพที่ผ่านการทำ ReLU เข้ามาทำการพูลลิ่งจะมีผลลัพธ์



ภาพที่ 2.10 ภาพผลลัพธ์หลังการทำ Pooling

2.3.7 สถาปัตยกรรมนิเวศวิทยาเชิงลึก CNNs Architecture

2.3.7.1 VGG เป็นสถาปัตยกรรมเครือข่ายประสาทเทียมรูปแบบหนึ่ง ซึ่ง VGG ถูกคิดค้นจาก Oxford เป็นคนแรกที่ใช้ตัวกรองขนาด 3×3 (filters) ในแต่ละชั้นของ convolutions และรวมกันเป็นลำดับของ convolutions

ConvNet Configuration					
A	A-LRN	B	C	D	E
11 weight layers	11 weight layers	13 weight layers	16 weight layers	16 weight layers	19 weight layers
input (224×224 RGB image)					
conv3-64	conv3-64 LRN	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64
maxpool					
conv3-128	conv3-128	conv3-128	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128
maxpool					
conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256 conv1-256	conv3-256 conv3-256 conv3-256	conv3-256 conv3-256 conv3-256 conv3-256
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 conv1-512	conv3-512 conv3-512 conv3-512	conv3-512 conv3-512 conv3-512 conv3-512
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 conv1-512	conv3-512 conv3-512 conv3-512	conv3-512 conv3-512 conv3-512 conv3-512
maxpool					
FC-4096					
FC-4096					
FC-1000					
soft-max					

Table 2: Number of parameters (in millions).

Network	A,A-LRN	B	C	D	E
Number of parameters	133	133	134	138	144

ภาพที่ 2.11 Neural Network Architectures: VGG


เครือข่าย VGG นี้จะใช้ multiple convolutional layers ขนาด 3×3 หลายแบบ เพื่อแสดงถึงคุณลักษณะที่ซับซ้อน สืบเนื่องจากภาพที่ 2.9 บล็อก 3, 4, 5 ของ VGG-E: 256×256 และ 512×512 ตัวกรอง 3×3 filters ถูกใช้หลายครั้งในลำดับเพื่อแยกคุณลักษณะที่ซับซ้อนและการรวมกันของคุณสมบัติดังกล่าวนี้มีประสิทธิภาพ เช่น มีขนาดใหญ่ 512×512 classifiers กับ 3 ชั้น ซึ่งเป็น convolutional สิ่งนี้เห็นได้ชัดว่ามีจำนวนพารามิเตอร์และมีความสามารถในการเรียนรู้อย่างมาก แต่การฝึกอบรมเครือข่ายเหล่านี้เป็นเรื่องยากและต้องแยกออกเป็นเครือข่ายขนาดเล็กที่มีการเพิ่มทีละชั้น ทั้งหมดนี้เนื่องจากไม่มีวิธีที่ดีในการจัดรูปแบบให้เป็นระเบียบหรือเพื่อจำกัดพื้นที่การค้นหาขนาดใหญ่ที่ได้รับการประชาสัมพันธ์โดยใช้พารามิเตอร์จำนวนมาก

สถาปัตยกรรมเครือข่ายประสาทเทียม VGG ใช้คุณลักษณะขนาดใหญ่ในหลายชั้น และต้องใช้ระยะเวลาในการทำงานค่อนข้างนาน

2.3.7.2 Inception V3, V2 จากการพัฒนาอย่างต่อเนื่องจากสถาปัตยกรรมเครือข่ายประสาทเทียม Inception ทำให้เกิด สถาปัตยกรรมเครือข่ายประสาทเทียม Inception V2 และ V3 ในปี 2015 ทำให้ Inception ได้รับการแนะนำให้เป็น Inception V2 จากการคำนวณโดยใช้ Batch-normalization ในการคำนวณค่าเฉลี่ยและส่วนเบี่ยงเบนมาตรฐาน ของคุณลักษณะทั้งหมดที่เอาต์พุตเลเยอร์หรือของชั้นถัดมา

ในปี 2015 ได้มีการเปิดตัว Inception Module ซึ่งเป็นสถาปัตยกรรมเครือข่ายประสาทเทียมรุ่นใหม่โดย GoogLeNet ได้มีการพัฒนาในการทำงานที่มีรายละเอียดมากขึ้นกว่าเดิม สามารถอธิบายได้ดังนี้


1. มีการเพิ่มประสิทธิภาพการไหลเวียนของข้อมูลเข้าสู่เครือข่ายโดยการสร้างเครือข่ายที่มีความลึกและความกว้าง ก่อนที่จะรวบรวมข้อมูลคุณสมบัติ
2. เมื่อประสิทธิภาพของเครือข่ายมีความลึกมากขึ้นเป็นการเพิ่มคุณสมบัติ หรือความกว้างของเลเยอร์จะเพิ่มขึ้นอย่างเป็นระบบ
3. ใช้การเพิ่มความกว้างในแต่ละเลเยอร์เพื่อเพิ่มการรวมกันของคุณสมบัติก่อน ในเลเยอร์ถัดไปมีการใช้ Convolution เท่านั้น



ภาพที่ 2.12 That filter of 5x5 and 7x7 can be decomposed with multiple 3x3

ที่มา: Eugenio Culurciello, (2017)

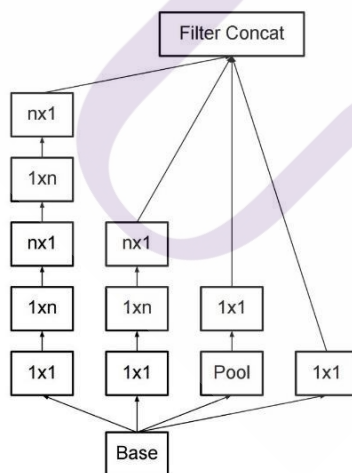
จึงทำให้สถาปัตยกรรมเครือข่ายประสาทเทียม Inception V. 2.1.7 เป็นดังภาพ



ภาพที่ 2.13 The new inception module

ที่มา: Eugenio Culureiello, (2017)


4. การใช้ตัวกรอง (filter) ยังสามารถย่อยสลายโดย Convolution) แบบเป็น โมดูลที่ซับซ้อนมากขึ้น ดังภาพที่ 2.13



ภาพที่ 2.14 Decomposed by flattened Convolutions

ที่มา: Eugenio Culureiello, (2017)


5. โมดูล Inception ยังมีความสามารถในการลดขนาดของข้อมูลโดยการ Pooling ในขณะที่การคำนวณ ซึ่งเป็นพื้นฐานเหมือนกันกับการดำเนินการ Convolution แบบคู่ขนานในการทำงาน Simple pooling layer ดังภาพที่ 2.15



ภาพที่ 2.15 Decrease the size of the data

ที่มา: Eugenio Culureiello, (2017)

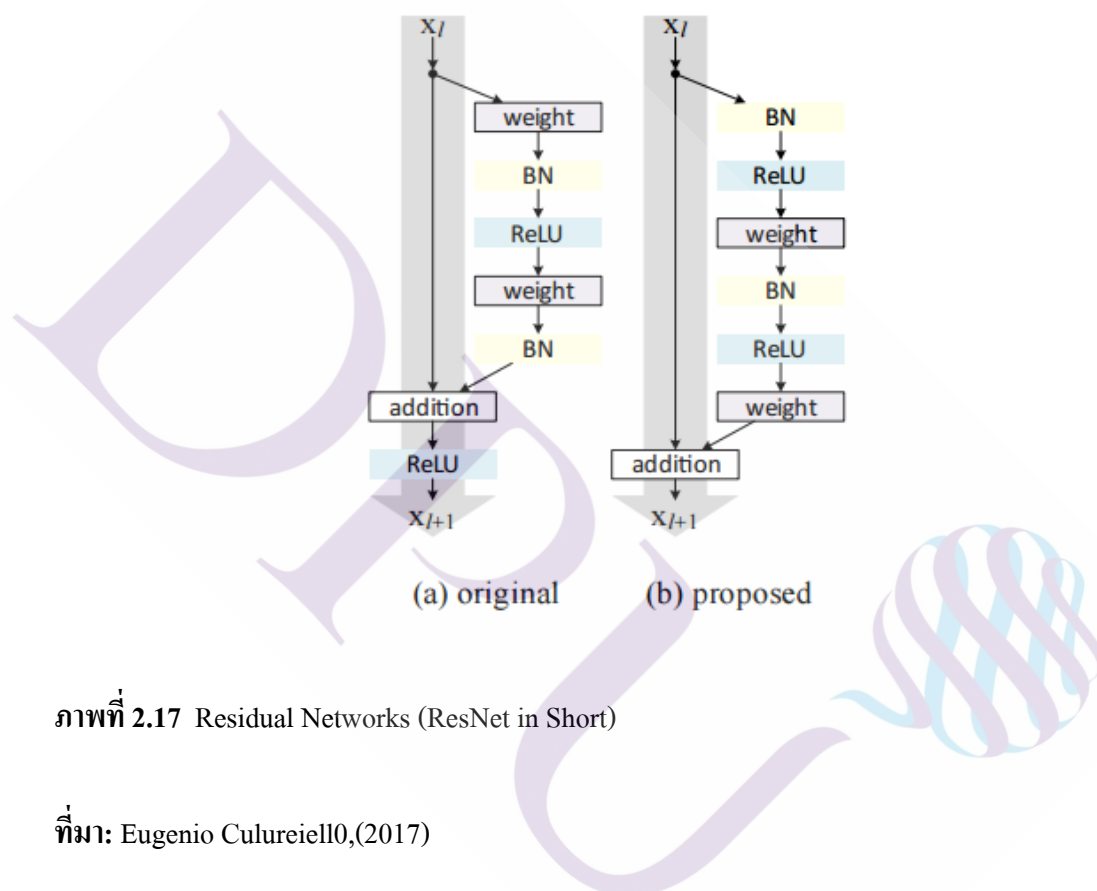
2.3.7.4 ResNet ถูกคิดค้นขึ้นมาพร้อมๆ กันกับ Inception V โดยมี การ feed ข้อมูลหรือผลลัพธ์ ของทั้งสองชั้น Convolutional อย่างต่อเนื่อง และยังหลีกเลี่ยงการป้อนข้อมูลไปยังชั้นถัดไป ดังภาพที่ 2.16



ภาพที่ 2.16 Feed the output of two successive convolutional layer

ที่มา: Eugenio Culureiello, (2017)

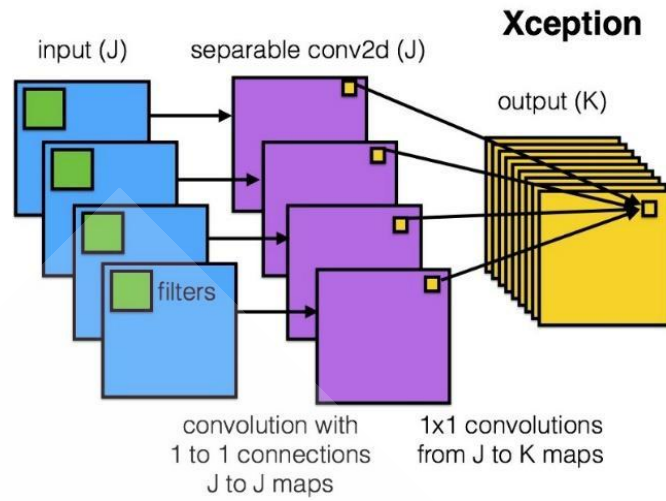
ResNet เป็นการนำ residual modules มาต่อกัน และใช้ stochastic descent gradient มาเทรน ตัว input จะถูก preprocess โดยการแบ่งเป็น patch เล็กๆ ก่อนถูกนำเข้ามาในโมเดล ResNet เป็นหนึ่งในสถาปัตยกรรม monster ซึ่งกำหนดความลึกของสถาปัตยกรรมการเรียนรู้ที่ลึกซึ่งได้ อย่างแท้จริง) Residual Networks (ResNet in sh ประกอบด้วยโมดูลที่เหลือจำนวนมากตามมาซึ่ง เป็นโครงสร้างพื้นฐานของสถาปัตยกรรม ResNet ดังภาพที่ 2.17



ภาพที่ 2.17 Residual Networks (ResNet in Short)

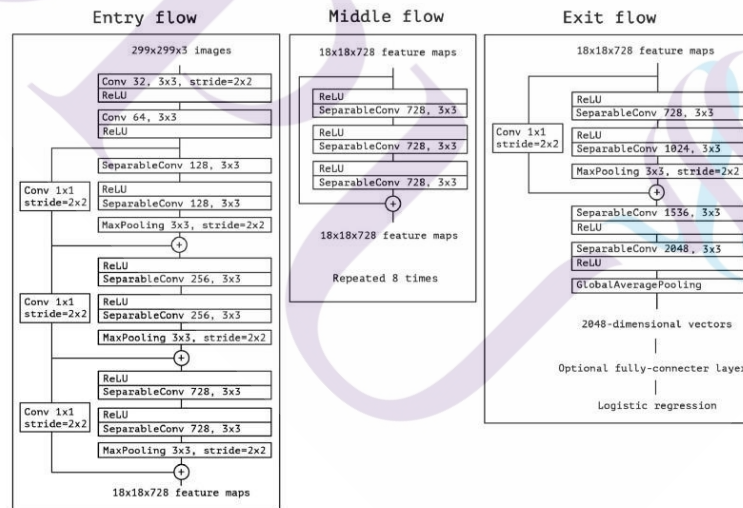
ที่มา: Eugenio Culureiello, (2017)

2.3.7.5 Xception François Chollet ได้ออกแบบโมดูล Xception ขึ้นมา แล้วพบว่ามีความสามารถช่วยปรับปรุงโมดูลและสถาปัตยกรรมการเริ่มต้นด้วยสถาปัตยกรรมที่เรียบง่ายและดีมากซึ่งมีประสิทธิภาพเท่ากับ ResNet และ Inception V4 แต่มีการทำงานที่น้อยลงมากกว่า ดังภาพที่ 2.19 และ 2.20



ภาพที่ 2.18 The Xception module

ที่มา: Eugenio Culureiello, (2017)



ภาพที่ 2.19 The Xception Architecture

ที่มา: Eugenio Culureiello, (2017)

สถาปัตยกรรมเครือข่ายประสาทเทียม Xception มีจำนวนทั้งหมด 36 convolutional ขั้นตอนการทำงานใกล้เคียงกับ ResNet-34 แต่รูปแบบและรหัสเป็นง่ายกว่า ResNet และเข้าใจได้

มากขึ้นกว่า Inception V4 จึงทำให้สถาปัตยกรรมเครือข่ายประสาทเทียม Xception เป็นที่น่าสนใจมากขึ้น

2.3.7.6 E-NET Abhishek Chaurasia, Sangpol Kim and Eugenio Culurciello (2016 เป็นเครือข่ายประสาทเทียมมีประสิทธิภาพอีกรูปแบบหนึ่ง ซึ่ง E-Net นี้มีจุดมุ่งหมายเพื่อให้สามารถใช้งานได้บนอุปกรณ์เคลื่อนที่ที่ใช้พลังงานต่ำและสามารถประมวลผลได้ที่มีความแม่นยำ สถาปัตยกรรมทั้งหมดของ E-Net ส่วนใหญ่จะมีลักษณะคล้ายกับ ResNets ที่มีโครงสร้างที่แยกออกเป็นหลายสาขาที่แยกออก แต่ยังผสานกลับผ่านการเพิ่มคุณลักษณะให้ชัดเจนมากขึ้นได้ เช่นเดียวกับโมเดลต้นแบบของ ResNet ตัวอย่างโครงสร้างดังภาพที่ 2.20


Name	Type	Output size
initial		$16 \times 256 \times 256$
bottleneck1.0	downsampling	$64 \times 128 \times 128$
4× bottleneck1.x		$64 \times 128 \times 128$
bottleneck2.0	downsampling	$128 \times 64 \times 64$
bottleneck2.1		$128 \times 64 \times 64$
bottleneck2.2	dilated 2	$128 \times 64 \times 64$
bottleneck2.3	asymmetric 5	$128 \times 64 \times 64$
bottleneck2.4	dilated 4	$128 \times 64 \times 64$
bottleneck2.5		$128 \times 64 \times 64$
bottleneck2.6	dilated 8	$128 \times 64 \times 64$
bottleneck2.7	asymmetric 5	$128 \times 64 \times 64$
bottleneck2.8	dilated 16	$128 \times 64 \times 64$
<i>Repeat section 2, without bottleneck2.0</i>		
bottleneck4.0	upsampling	$64 \times 128 \times 128$
bottleneck4.1		$64 \times 128 \times 128$
bottleneck4.2		$64 \times 128 \times 128$
bottleneck5.0	upsampling	$16 \times 256 \times 256$
bottleneck5.1		$16 \times 256 \times 256$
fullconv		$C \times 512 \times 512$

ภาพที่ 2.20 Architecture of ENet

ที่มา: ENet: A Deep Neural Network Architecture for Real Time Semantic Segmentation (2016)

ส่วนเริ่มต้นของ (E-Net) Initial block 512 คือ การนำข้อมูลหรือภาพเข้าสู่โมเดลมีความละเอียด (x16) ซึ่งส่งผลให้มีขนาดการแสดงผลของบล็อกเริ่มต้นที่ $512 \times 256 \times 256$ หลังจาก


ที่มีการรวมตัวของ Convolution 13) filters และ (MaxPooling 2 without overlap) แสดงดังภาพที่ 2.21



ภาพที่ 2.21 Initial block of ENet

ที่มา: ENet: A Deep Neural Network Architecture for Real Time Semantic Segmentation (2016)

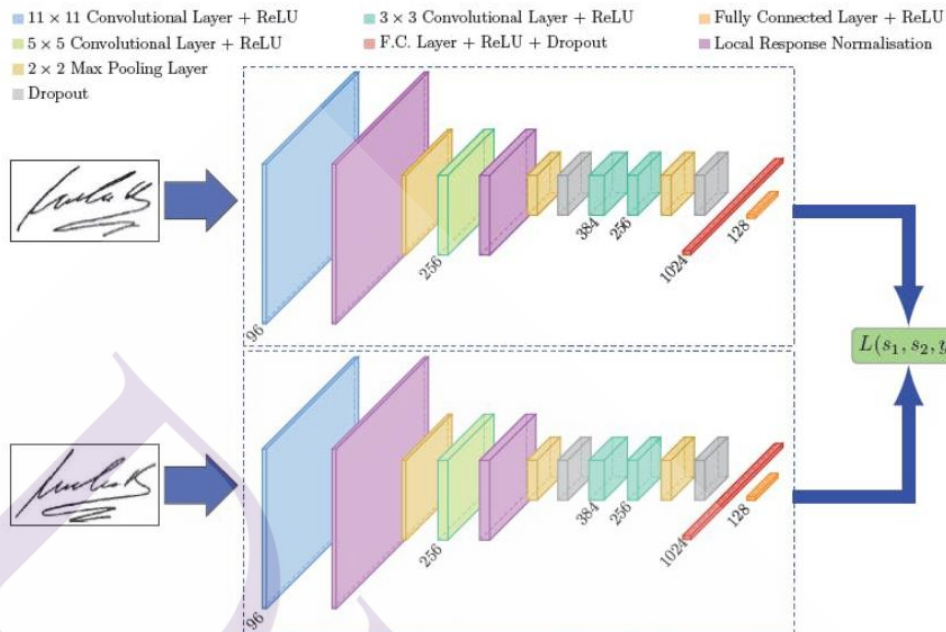
ในส่วนต่อมาเป็นโมดูล Bottleneck มีโครงสร้างเหมือนกันภาพที่ 3.2.22 แต่ละสาขาประกอบไปด้วยชั้น การทำ Convolution ครั้งแรกเพื่อลดขนาดของข้อมูลลงด้วยขนาด 1x1 ซึ่งทำให้ระหว่าง Convolution เหล่านี้ มักเกิดการขยายตัว การทำงาน Batch normalization และ ReLu จะถูกวางไว้ระหว่าง Convolution ทั้งหมดจากนั้นใช้ Dropout เชิงพื้นที่ ดังภาพที่ 2.22



ภาพที่ 2.22 Bottleneck module of ENet

ที่มา: ENet: A Deep Neural Network Architecture for Real Time Semantic Segmentation (2016)

2.3.7.7 Siamese

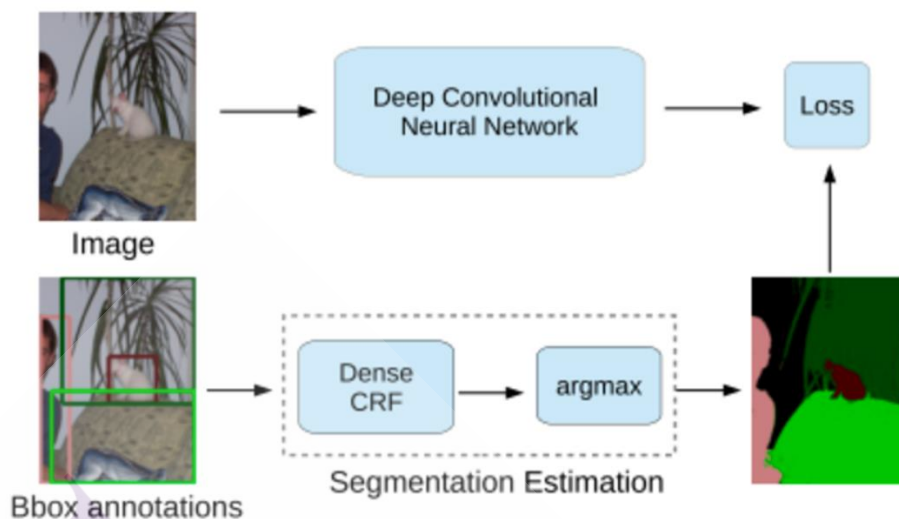


ภาพที่ 2.23 แสดงสถาปัตยกรรมของโมเดล Siamese

เป็นการนำระบบเครือข่ายประสาทการประยุกต์ใช้งาน โดยนำ สถาปัตยกรรมที่เหมือนกันมาทำการเปรียบเทียบข้อมูลเพื่อหาผลต่างของข้อมูลโดยการคำนวณระยะห่างว่ามีความใกล้เคียงกันเพียงใด โดยการนำข้อมูลที่ต้องการผลผ่านระบบเครือข่ายประสาททั้งสองและนำผลที่ได้มาหาระยะห่างของข้อมูล

2.4 การตรวจสอบวัตถุการเรียนรู้เชิงลึก

รูปภาพโดยทั่วไปจะมีองค์ประกอบต่างๆ อยู่ในรูป เช่น รูป สัตว์ ต้นไม้ ดอกไม้ ล้วนแต่เป็นองค์ประกอบของรูปภาพ ซึ่งแต่ละองค์ประกอบจะมีพื้นที่เป็นของตัวเอง จึงมีการพยายามที่จะตรวจสอบหาพื้นที่ ที่วัตถุนั้นอยู่ เพื่อระบุว่าเป็นวัตถุชนิดใด โดยการพยายามตีกรอบวัตถุ ต่างๆ ที่อยู่ในรูปภาพ



ภาพที่ 2.24 Segmentation

ที่มา: Image Segmentation Algorithms Overview (2017)

2.5 การวัดประสิทธิภาพ (Performance Evaluation)

การวัดประสิทธิภาพการจำแนกแบบสองคลาส (Binary-Class Classification) สามารถแสดงได้ดังนี้

2.5.1 คอนฟิวชันเมทริกซ์ (Confusion Matrix) คือ เมทริกซ์ที่แสดงผลของการจำแนกโดยแจกแจงจำนวนที่จำแนกได้ตามคลาส ดังตัวอย่างใน ตารางที่ 2 ซึ่งแสดงการจำแนกข้อมูลเป็น 2 คลาส โดยค่าแต่ละแถวแสดงจำนวนข้อมูลที่มีคลาสนั้นเป็นคำตอบที่ถูกต้อง ส่วน ค่าในแต่ละหลักแสดงจำนวนข้อมูลที่ทำนายได้คลาสนั้น กำหนดให้สำหรับคลาสใด ๆ

- (1) TP คือ จำนวนข้อมูลที่ทำนายได้คลาสนั้นและทำนายถูก (True Positive)
- (2) FP คือ จำนวนข้อมูลที่ทำนายได้คลาสนั้นและทำนายผิด (False Positive)
- (3) TN คือ จำนวนข้อมูลที่ทำนายได้คลาสนั้นและทำนายถูก (True Negative)
- (4) FN คือ จำนวนข้อมูลที่ทำนายได้คลาสนั้นและทำนายผิด (True Negative)

ตารางที่ 2.1 ตัวอย่าง คอนฟิวชันเมตริกซ์ของการจำแนกแบบ 2 คลาส

		คลาสที่ทำนาย	
		แนวโน้มขาขึ้น	แนวโน้มขาลง
ความจริง	แนวโน้มขาขึ้น	TP	FN
	แนวโน้มขาลง	FP	TN

2.5.2 ตัววัดประสิทธิภาพจำแนกตามคลาส

โดยทั่วไปตัววัดประสิทธิภาพที่นิยมใช้กันในงานวิจัยมีอยู่ 4 ค่า ดังนี้ค่าความเที่ยง (Precision) เป็นการวัดความแม่นยำของแบบจำลองโดยการพิจารณาแยกทีละคลาส ตัวอย่างเช่น การวัดว่าแบบจำลองทำนายว่าคำตอบที่เป็นบวกถูกต้องเท่าไรจากผลการทำนายคลาสบวกทั้งหมดเท่าไร

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

ค่าความระลึก (Recall) เป็นการวัดความถูกต้องของแบบจำลองโดยการพิจารณาแยกทีละคลาส ตัวอย่างเช่น การวัดว่าผลการทำนายคลาสบวกความถูกต้องเท่าไรเมื่อเทียบกับคลาสบวกจริงทั้งหมด

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

ค่าเอฟวัน (F1) เป็นการวัดความเที่ยงและความระลึกของแบบจำลองไปพร้อม ๆ กัน โดยคำนวณได้จาก สมการดังต่อไปนี้

$$2 \times \text{Precision} \times \text{Recall} \text{ F1} = \text{Precision} + \text{Recall}$$

ค่าความแม่นยำ (Accuracy) เป็นการวัดความแม่นยำของแบบจำลองโดยรวม กล่าวคือแบบจำลอง ทำนายถูกต้องกี่ครั้งจากจำนวนการทำนายทั้งหมด

$$TP \text{ TN Accuracy} = TP \text{ FP TN FN}$$

2.6 งานวิจัยที่เกี่ยวข้อง

2.6.1 Imanol Schlag : Ancient Roman Coin Recognition in the Wild using Deep Learning Based Recognition of Artistically Depicted Face Profiles (2017) ได้ศึกษาวิจัยการตรวจสอบเหรียญ โรมัน โดยใช้เทคนิค การตรวจสอบใบหน้าของกษัตริย์ โรมันแต่ละสมัย โดยจำแนกตามลักษณะใบหน้าของกษัตริย์

2.6.2 Patompon Fugthong : Buddha Amulet Information Retrieval using Digital Images Combined with Feature Extraction and K-nearest Neighbor Techniques (2012) ได้ศึกษาวิจัยการจำแนกพระเครื่องโดยใช้ ภาพถ่าย โดยใช้เทคนิค การสกัดคุณลักษณะพิเศษ ร่วมกับวิธีการใกล้เคียงเพื่อนบ้าน

2.6.3 Surayut Panchavinin : A Development of Buddha Amulet Pattern Recognition System using Back Propagation Artificial Neural Network (2011) ได้ศึกษาวิจัยการจำแนกพระเครื่องโดยใช้วิธีการ การเรียนรู้เชิงลึกแบบย้อนกลับ ANN

2.6.4 Chomtip Pornpanomchai : Thai Buddhist Sculpture Recognition System (TBuSRS) (2011) ได้ศึกษาวิจัยจำแนกพระประธานในโบสถ์โดยใช้วิธีการ จับคู่

2.6.5 Chomtip Pornpanomchai : Buddhist Amulet Recognition System (BARS) (2010) ได้ศึกษาจำแนกพระเครื่องแบบเหรียญ โดยใช้วิธีการจับคู่

2.7 พระเครื่องที่เลือกทำงานวิจัย

2.7.1 พระเบญจภาคี

1. พระสมเด็จวัดระฆัง พระสมเด็จวัดระฆัง คือพระเครื่องรางรูปสมมติพระพุทธเจ้าสร้างโดยสมเด็จพระพุฒาจารย์ (โต) พรหมรังสี วัดระฆังโฆสิตาราม ลักษณะเป็นรูปสี่เหลี่ยมผืนผ้าขนาดกว้างประมาณ 2.5 เซนติเมตร สูงประมาณ 4 เซนติเมตร สีขาว ส่วนประกอบสำคัญในการสร้าง ปูนเปลือกหอย ขาวก้นบาตร ผงวิเศษ 5 ชนิดและน้ำมันตังอิ้ว
2. พระนางพญา พุทธคุณเด่นทางเมตตามหานิยมอยู่ยงคงกระพันชาตรี เป็นองค์แทนพระเครื่องที่สร้างในสมัยอยุธยา
3. พระกำแพงซุ้มกอ พุทธคุณเด่นทางด้านโชคลาภ โภคทรัพย์ เป็นองค์แทนพระเครื่องที่สร้างในสมัยสุโขทัย
4. พระรอด พุทธคุณเด่นทางด้านแคล้วคลาดนิรันตราย เป็นองค์แทนพระเครื่องที่สร้างในสมัยทราวดีตอนปลาย (หริภุญชัย)

5. พระผงสุพรรณ นั้นพุทธคุณเด่นทางด้าน โภคทรัพย์ แคล้วคลาด อยู่ยง เป็นองค์แทนพระเครื่องที่สร้างในสมัยอุทอง

2.7.2 หลวงปู่ทวด พระหลวงพ่อทวด วัดช้างให้ จ.ปัตตานี มีตั้งเนื้อว่าน รุ่นแรก ปี 2497, พระหล่อโบราณหลังเตารีด ปี 2505, พระปี่มหลังตัวหนังสือ ปี 2505 และเหรียญรุ่นต่างๆ อีกมากมาย ทุกวันนี้ทุกรุ่นทุกพิมพ์ล้วนเป็นที่นิยมกันอย่างกว้างขวาง

2.7.3 พระขุนแผนผงพรายกุมาร หลวงปู่ทิม เริ่มทำ ‘ผงพรายกุมาร’ มาตั้งแต่กลางปี พ.ศ. 2515 โดยค้นพบจากคัมภีร์เก่าของหลวงปู่สังข์เต่า เพื่อเก็บไว้ผสมสร้างพระเครื่องแจกผู้มีจิตศรัทธาที่มาทำบุญที่วัดในงานผูกพัทธสีมาที่จะจัดขึ้น หลวงปู่ได้กล่าวว่า ‘หากได้ผงพรายกุมารมหาภูติผสมใส่ลงไปด้วย พระเครื่องที่สร้างขึ้นนี้จะมีความศักดิ์สิทธิ์มากขึ้น เพราะมีอานุภาพแห่งพรายกุมารมหาภูติแฝงอยู่ คอยช่วยเหลือเอื้ออำนวยพร’ นายกุหลาบ จ้อยเจริญ หรือ ‘หมอลาบ’ ผู้มีวิชาคาถาอาคมเข้มขลัง จึงรับอาสาไปนำกะโหลกพรายมาเป็นส่วนผสมสำคัญ เมื่อหลวงปู่ทิมปลุกเสก ‘ผงพรายกุมารมหาภูติ’ เสร็จ จึงนำมาผสมผงวิเศษอื่นๆ และผงว่าน 108 เพื่อกดพิมพ์พระตามต้องการ

2.7.4. หลวงปู่ศุข พระครูวิมลคุณากร คนทั่วไปอาจจะยังไม่คุ้นหูเท่าใดนัก แต่ถ้าเอ่ยชื่อ หลวงปู่ศุข วัดปากคลองมะขามเต่าแล้วละก็ไม่มีใครปฏิเสธได้ว่าไม่รู้จัก โดยเฉพาะนักนิยมพระเครื่องแล้ว แทบทุกคนต่างใฝ่หาพระเครื่องของหลวงปู่ศุข มาใช้เพราะเชื่อกันว่า พระหลวงปู่ศุขนั้นให้พุทธคุณ ทั้งด้านเมตตามหานิยม และ ด้านแคล้วคลาด คงกระพัน

2.7.5. หลวงปู่ทิม พระครูภาวนาภริณี หรือ หลวงปู่ทิม อิสริโก อดีตเจ้าอาวาสวัดละหารไร่ จ.ระยอง ผู้มีวิชาอาคมแก่กล้าและเป็นพระนักพัฒนา เป็นที่เคารพศรัทธาของชาวยะยองและจังหวัดใกล้เคียง โดยเฉพาะในแวดวงนักนิยมสะสมพระเครื่องและเหรียญคณาจารย์ ด้วยพุทธคุณของวัตถุมงคลของท่านนั้นเป็นที่ปรากฏประจักษ์จนเป็นที่กล่าวขานต่อกันมา ทั้งด้านอยู่ยงคงกระพันและเมตตามหานิยมเรียกว่าสมบุรณ์แบบ

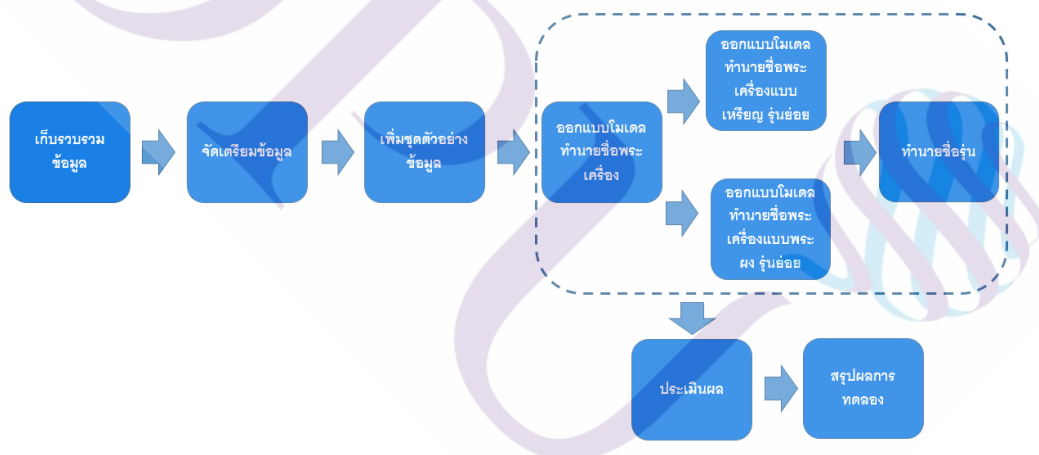
2.7.6. หลวงพ่อคุณ เหรียญหลวงพ่อคุณแต่ละรุ่นเป็นที่นิยมของนักสะสมพระเครื่อง โด่งดังมีชื่อเสียงไปถึงระดับต่างประเทศ จนกลายเป็นที่ต้องการของลูกศิษย์ลูกหาอย่างมาก ซึ่งบางรุ่นก็มีราคาสูงเหยียบ 8 หลัก

บทที่ 3

ระเบียบวิธีวิจัย

3.1 ขั้นตอนการดำเนินงานวิจัย

งานวิจัยนี้มีจุดประสงค์ เพื่อศึกษาการทำนายชื่อ พระเครื่องแต่ละชนิดจากรูปภาพ ที่มีสภาพแวดล้อมที่แตกต่างกัน โดยใช้ภาพถ่ายจาก Internet คัดเลือกรูปพระเครื่องที่ได้รับความนิยม และมีมูลค่าสูง เป็นข้อมูลรูปภาพ 20 ประเภท ประกอบไปด้วย พระเครื่อง แบบ พระผง และ แบบ เหรียญ โลหะ จากการศึกษาวิธีการวิจัยที่เกี่ยวข้อง สามารถจัดเป็น ขั้นตอนการวิจัย ได้ดังนี้



ภาพที่ 3.1 แสดงการดำเนินการวิจัย

3.2 การเก็บรวบรวมข้อมูลสำหรับการทำวิจัย



ภาพที่ 3.2 ตัวอย่างรูปพระเครื่องที่ใช้ในการวิจัย



ภาพที่ 3.3 ตัวอย่างภาพสี พระเครื่องรุ่นย่อยที่ใช้ในการวิจัย

ที่มาของรูปภาพ โดยเลือกจากเว็บไซต์แสดงภาพสะสม เว็บไซต์ซื้อขาย เว็บไซต์งานประกวดพระเครื่อง โดยใช้วิธีการ Download ทำการ Download ครั้งละประเภท โดยเลือกภาพด้านหน้าองค์พระเครื่อง ซึ่งประกอบไปด้วย พระเครื่องแบบผง และ พระเครื่องแบบเหรียญโลหะ ดังรูปที่ 1 และสามารถแสดงชื่อรุ่นได้ตาม ตารางที่ 1

3.3 แสดงรายชื่อ พระเครื่องที่ใช้งานวิจัย

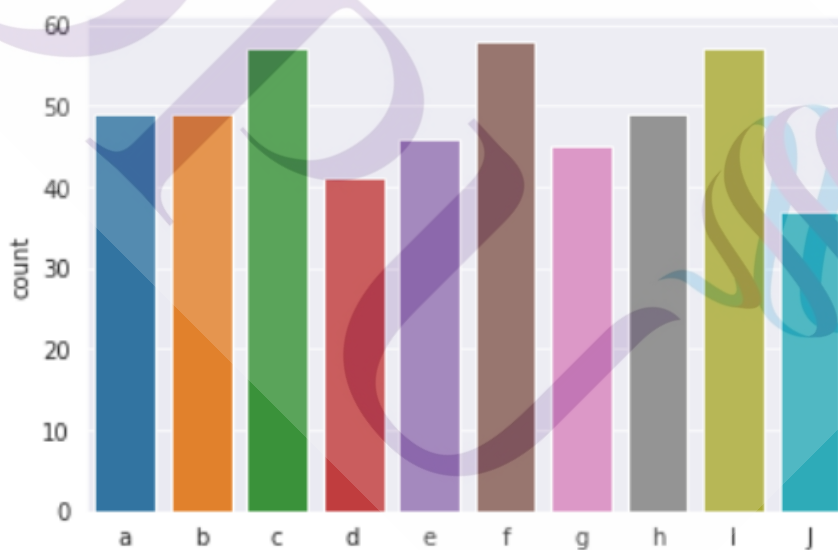
Class	Class Name	Class	Class Name
a	สมเด็จพระบางขุนพรหมพิมพ์เส้นด้าย	n	เหรียญ มหาโภคทรัพย์ รุ่น เศรษฐี คุณ เจ้าสัว หลวงพ่อคุณ
b	สมเด็จพระบางขุนพรหม พิมพ์ปรกโพธิ์	o	เหรียญเจริญพรด่าง หลวงพ่อคุณ วัดบ้านไร่ ปี 2536
c	สมเด็จพระวัดระฆังพิมพ์ฐานแซม	p	เหรียญหลวงพ่อกุณ ปี 2517
e	สมเด็จพระบางขุนพรหมเกตุบัวตูม	q	เหรียญหลวงพ่อกุณรุ่นแรก ปี 2512
f	พระสมเด็จพระวัดระฆังพิมพ์ใหญ่	r	เหรียญหลวงพ่อกุณ รุ่นเจริญพรบน ปี 2536
d	สมเด็จพระวัดระฆังพิมพ์ใหญ่เศียรคชชุ้ม	s	เหรียญหลวงพ่อกุณ รุ่นเพชรน้ำเอก ปี 2536
g	พระสมเด็จพระเกษไชโย	t	เหรียญหลวงพ่อกุณ รุ่นคุณพระเทพประทานพร ปี 2536
h	พระสมเด็จพระวัดระฆังพิมพ์ใหญ่เศียรคชชุ้ม	u	เหรียญหลวงพ่อกุณ รุ่นธนาคารศรีนคร ปี 2521
l	พระสมเด็จ ออกครุฑเศียรบาตร บางขุนพรหม	v	เหรียญหลวงพ่อกุณ รุ่นนั่งพานขณะมาร ปี 2537
j	สมเด็จพระวัดบางขุนพรหมพิมพ์เกษบัวตูม	w	เหรียญหลวงพ่อกุณ รุ่นสร้างบารมี ปี 2519

ภาพที่ 3.4 แสดงรายชื่อพระเครื่องที่ใช้ในงานวิจัย

เพื่อเพิ่มความสามารถในการจำแนก พระเครื่องให้สามารถทำนายได้แม่นยำยิ่งขึ้น จึงทำการแบ่งชุดข้อมูล พระเครื่องแบบผง, พระเครื่องแบบเหรียญโลหะ โดยทำการรวบรวมข้อมูลจาก สังคมออนไลน์ เว็บไซต์ประกวดพระเครื่อง รุ่นต่าง ๆ และ เว็บไซต์สำหรับการซื้อขาย สามารถแสดงได้ดังตาราง ด้านล่างนี้ ชุดข้อมูล พระเครื่องแบบผง พระเครื่องแบบผง ทำการรวบรวมข้อมูล จาก สังคมออนไลน์ เว็บไซต์ประกวดพระเครื่อง รุ่นต่าง ๆ และ เว็บไซต์สำหรับการซื้อขาย สามารถแสดงได้ดังตาราง ด้านล่างนี้

Class Name	Description
a	สมเด็จพระนางพรมหมพิมพ์เส้นด้าย
b	สมเด็จพระนางพรมหมพิมพ์ปรกโพธิ์
c	สมเด็จพระวัดระฆังพิมพ์ฐานแซม
e	สมเด็จพระนางพรมหมพิมพ์บัวตูม
f	พระสมเด็จพระวัดระฆังพิมพ์ใหญ่
d	สมเด็จพระวัดระฆังพิมพ์ใหญ่เศษจรดซุ้ม
g	พระสมเด็จพระเกษไชโย
h	พระสมเด็จพระวัดระฆังพิมพ์ใหญ่เศษทะเลซุ้ม
l	พระสมเด็จพระ อัครราชเสวยราตร บางพรม
j	สมเด็จพระวัดบางพรมหมพิมพ์เกษบัวตูม

ภาพที่ 3.5 แสดงรายชื่อพระเครื่องแบบพง



ภาพที่ 3.6 แสดงจำนวนพระเครื่องแบบพง

ชุดข้อมูล พระเครื่องแบบเหรียญโลหะ


Class Name	Description
n	เหรียญ มหาโภคทรัพย์ รุ่น เศรษฐี คุณ เจ้าสัว หลวงพ่อคุณ
o	เหรียญเจริญพรล่าง หลวงพ่อคุณ วัดบ้านไร่ ปี 2536
p	เหรียญหลวงพ่อคุณ ปี 2517
q	เหรียญหลวงพ่อคุณรุ่นแรก ปี 2512
r	เหรียญหลวงพ่อคุณ รุ่นเจริญพรบน ปี 2536
s	เหรียญหลวงพ่อคุณ รุ่นเพชรน้ำเอก ปี 2536
t	เหรียญหลวงพ่อคุณ รุ่นคุณพระเทพประทานพร ปี 2536
u	เหรียญหลวงพ่อคุณ รุ่นธนาคารศรีนคร ปี 2521
v	เหรียญหลวงพ่อคุณ รุ่นนั่งพานชนะมาร ปี 2537
w	เหรียญหลวงพ่อคุณ รุ่นสร้างบารมี ปี 2519

ภาพที่ 3.7 แสดงรายชื่อพระเครื่องแบบเหรียญ



ภาพที่ 3.8 แสดงจำนวนพระเครื่องแบบเหรียญ

ชุดข้อมูล พระเครื่องแบบ พระ ผง และ พระเครื่องแบบเหรียญ ดังแสดงได้ในตารางที่ 1



ภาพที่ 3.9 แสดงจำนวนพระเครื่องแบบผง และ แบบเหรียญ

การปรับชุดข้อมูลสำหรับการวิจัย จากชุดข้อมูลเป็น ภาพสี ทั้งหมด ทำให้การพิจารณาข้อมูลมีความหลากหลายมากขึ้นไป ทำให้เกิดความยากลำบากในการพิจารณา จึงควรปรับให้อยู่ในกลุ่มเงื่อนไขเดียวกัน คือ ปรับสีภาพให้เป็นขาวดำ หรือ Gray Scale โดยใช้ไลบรารี Python PIL อีกทั้ง ชุดข้อมูลมีขนาดของ รูปภาพแตกต่างกันจำเป็นต้องปรับขนาด ให้เท่ากัน เพื่อความสะดวกในการวิจัย โดยใช้ขนาดภาพ 300×300 พิกเซล

3.4 การเพิ่มชุดตัวอย่างข้อมูล (Data Augmentation)


การเพิ่มชุดตัวอย่างข้อมูลเป็นการเพิ่มรูปภาพในคุณลักษณะต่างๆเพื่อใช้ในการฝึกสอนโมเดล โดยการเพิ่มชุดตัวอย่างข้อมูลนี้จะใช้ไลบรารี Augmentor ในภาษาไพธอนโดยตั้งค่าต่างๆ ดังนี้

3.4.1 การตั้งค่าในกลุ่มขนาดและตำแหน่ง

Flip_left_right กำหนดค่า 0.1

Skew กำหนดค่า 0.2 – 0.5

Rotate กำหนดค่า 0.3




ภาพที่ 3.10 แสดงการปรับรูปภาพ กลุ่มขนาดและตำแหน่ง

3.4.2 การตั้งกลุ่มความเข้มภาพ

Black_and_white 0.1

3.4.3 ภาพขาวดำ กำหนดค่า alpha 0.0 ถึง 1.0



ภาพที่ 3.11 แสดงการปรับรูปภาพ ภาพขาวดำ

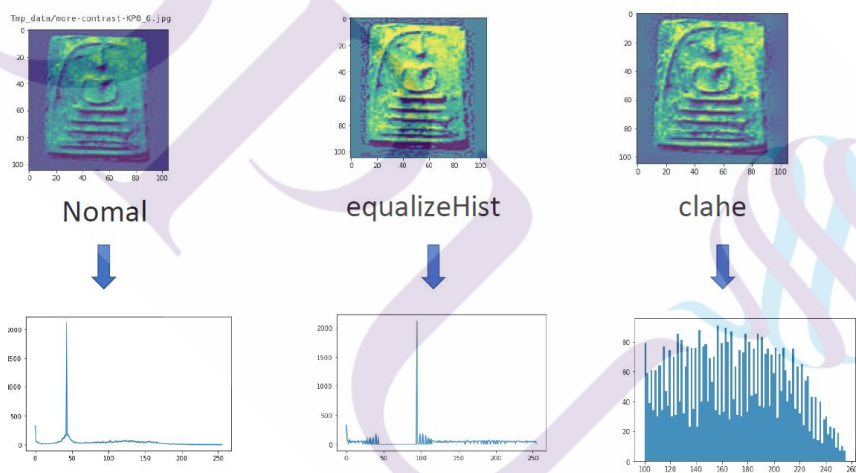
3.4.4 การขยายภาพ

Zoom กำหนดค่า 0.1




ภาพที่ 3.12 แสดงการปรับรูปภาพแบบซูม

3.4.4 การทำ CLAHE



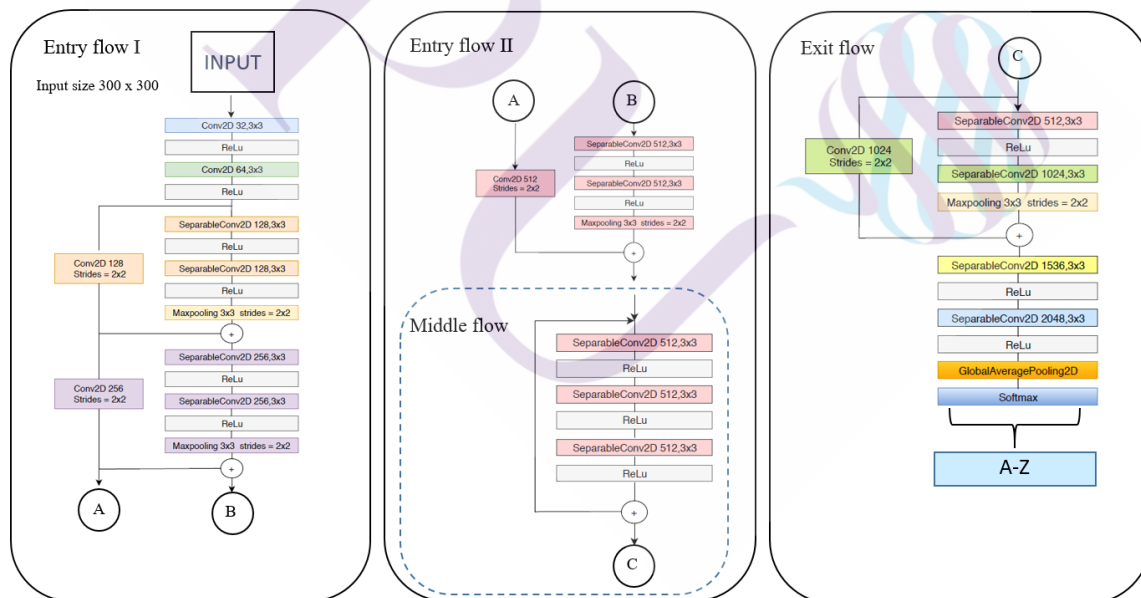
ภาพที่ 3.13 แสดงการเพิ่มข้อมูลภาพ แบบ CLAHE

จากการเพิ่มชุดข้อมูลทำให้ ได้ข้อมูลเพิ่มมา แต่ในชุดข้อมูลแต่ละคลาสมีจำนวนไม่เท่ากัน ตั้งแต่ต้น ทำให้จำนวนภาพในแต่ละคลาสไม่เท่ากัน จึงทำภาคัดภาพที่ขาดความคมชัดออกบางคลาส เพื่อให้ภาพในแต่ละคลาสมีจำนวนที่ใกล้เคียงกัน สามารถแสดงจำนวนภาพหลังการเพิ่มชุดข้อมูล ได้ดังนี้



ภาพที่ 3.14 แสดงจำนวนข้อมูลหลังเพิ่มชุดข้อมูล

3.5 ออกแบบโมเดลที่ใช้ในการทำนายพระเครื่อง



ภาพที่ 3.15 แสดงสถาปัตยกรรม Xception สำหรับการทำงานวิจัย

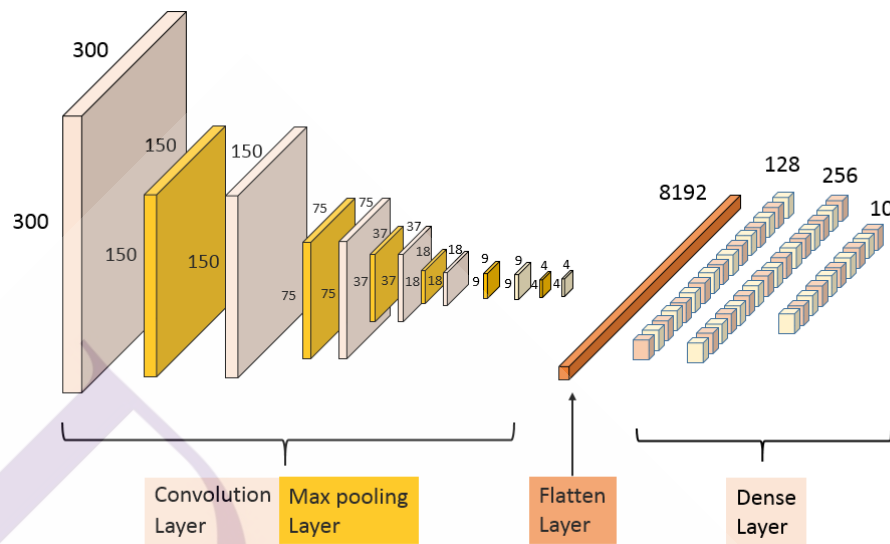
ในปัจจุบันนี้ ได้มีการวิจัยมากมายเกี่ยวกับ Image Classification ทำให้มีหลายโมเดล สามารถทำนายรูปภาพได้อย่างมีประสิทธิภาพ รองรับข้อมูลได้หลากหลาย สามารถรองรับการปรับแต่งได้อย่างมีประสิทธิภาพ หรือความไม่สมบูรณ์ของภาพ เช่น Vgg16 , Vgg19 , ResNet , EfficinNet , Xception , Inception

ในงานวิจัย เลือกใช้งาน โมเดล Xception เนื่องจากมีความสามารถในการทำนายรูปภาพ และสามารถทำงานได้อย่างมีประสิทธิภาพ เนื่องจากการทำงานของ โมเดล สามารถ สกัดหาคุณนะสมบัติในแต่ละรูป และชดเชยความสูญเสียรายละเอียดของภาพ เพื่อให้สามารถระบุชนิดของรูป หรือ ชนิดของวัตถุในรูป ดังนั้น จึงสามารถออกแบบโมเดลได้เอง และปรับแต่ง แก้ไข เพื่อทดสอบหา ประสิทธิภาพ และ ค่าตัวแปรเพื่อให้สามารถใช้งานร่วมกันข้อมูลได้ดี

จากรูปที่ 3.15 สามารถแบ่งอธิบายการทำงานได้ดังนี้

1. Entry flow I คือส่วนที่รับข้อมูลรูปภาพและทำการ สกัดข้อมูลเป็นชั้น แบบหยาบ โดยจะมีการนำค่าที่ได้ใช้ชั้นแรก ไปชดเชยให้ชั้นถัดไป เพื่อป้องกันการสูญเสียคุณลักษณะ และชะลอการลดข้อมูลในชั้นถัดไป
2. Entry flow II สามารถแบ่งได้เป็นสองส่วนย่อย คือ ส่วนที่สกัดข้อมูลเป็นชั้น ที่มีความละเอียดกว่า Entry flow และนำข้อมูลจากชั้นก่อนหน้ามาชดเชย และส่วนที่เป็น Middle Flow จะทำการส่งข้อมูลกลับไปทำซ้ำอีกครั้ง ดังที่แสดงในรูปที่ 7
3. Exit flow จะทำหน้าที่สกัดข้อมูลเป็นชั้น ที่มีความละเอียดสูงเพื่อหาคุณลักษณะเด่น เพื่อทำนายชื่อพระเครื่อง

3.6 ออกแบบโมเดลทำนายชื่อพระเครื่องรุ่นย่อย



ภาพที่ 3.16 แสดงสถาปัตยกรรม CNN ที่ได้ออกแบบเพื่อใช้ในการทำนายชื่อพระเครื่องรุ่นย่อย

เนื่องจากในจำนวนพระเครื่องที่ทำนายชื่อนั้น ประกอบไปด้วยหลายรุ่นย่อยซึ่งมีองค์ประกอบคล้ายกัน ดังนั้นในการทำนายชื่อพระเครื่องในรุ่นย่อย ไม่สามารถใช้โมเดลในรุ่นใหญ่ได้อย่างมีประสิทธิภาพ เพราะมีองค์ประกอบเฉพาะที่ต่างออกไปจำเป็นต้องใช้งาน โมเดลเฉพาะรุ่น เพื่อให้เกิดประสิทธิภาพในการทำนายชื่อพระเครื่องในรุ่นย่อยนั่นเอง จากรูปที่ 8 แสดงสถาปัตยกรรม CNN ที่ได้ออกแบบเพื่อใช้ในการทำนายชื่อพระเครื่องรุ่นย่อย ที่ใช้ทำนายพระเครื่องแบบเหรียญโลหะ จะนำมาทดสอบในพระเครื่องรุ่นย่อยแบบพระผงด้วย เพื่อพิสูจน์ความสามารถของโมเดลว่าสามารถทำนายได้หรือไม่ ทั้งนี้เนื่องจาก CNN มีความสามารถในการสกัดหาคุณลักษณะของรูปได้อย่างดี จึงเหมาะสมที่จะนำมาใช้งาน

3.6.1 โมเดลทำนายชื่อพระเครื่อง รุ่นย่อย เหรียญโลหะ

การทำนายชื่อพระเครื่องแบบรุ่นย่อยแบบเหรียญโลหะ มีรูปทรงที่แตกต่างกัน และมีใบหน้าพระสงฆ์ที่มีลักษณะคล้ายกันทำกับการตรวจสอบวัตถุ ได้จากรูปทรง หรือ ลักษณะท่าทางของพระสงฆ์ในเหรียญ จึงนำโมเดล CNN มาใช้ในการทดสอบ


3.6.2 โมเดลทำนายชื่อพระเครื่องรุ่นย่อยแบบพระผง

การทำนายชื่อพระเครื่องแบบพระรุ่นย่อยนี้ ส่วนใหญ่มีลักษณะประจำรุ่นที่เหมือนกันคือ เป็น สีเหลืองพื้นผ้า มีลักษณะทรงสูงทำให้ยากต่อการแยกประเภท และมีรายละเอียดในองค์พระที่แตกต่างกันเช่นจำนวนชั้นของฐานพระและลักษณะขององค์พระ จึงใช้โมเดล CNN ในการสกัดหาคุณลักษณะนี้

3.6.3 โมเดลที่ใช้ประกอบการวิจัย

- | | |
|-----------------|--|
| 1. Xecption | ฝึกสอนโดยใช้ชุดข้อมูลพระเครื่องแบบผง |
| 2. Xecption | ฝึกสอนโดยใช้ชุดข้อมูลพระเครื่องแบบเหรียญ |
| 3. Xecption | ฝึกสอนโดยใช้ชุดข้อมูลพระเครื่องแบบผสม |
| 4. CNN | ฝึกสอนโดยใช้ชุดข้อมูลพระเครื่องแบบผง |
| 5. CNN | ฝึกสอนโดยใช้ชุดข้อมูลพระเครื่องแบบเหรียญ |
| 6. CNN | ฝึกสอนโดยใช้ชุดข้อมูลพระเครื่องแบบผสม |
| 7. ResNet | ฝึกสอนโดยใช้ชุดข้อมูลพระเครื่องแบบผง |
| 8. ResNet | ฝึกสอนโดยใช้ชุดข้อมูลพระเครื่องแบบเหรียญ |
| 9. ResNet | ฝึกสอนโดยใช้ชุดข้อมูลพระเครื่องแบบผสม |
| 10. EfficeinNet | ฝึกสอนโดยใช้ชุดข้อมูลพระเครื่องแบบผง |
| 11. EfficeinNet | ฝึกสอนโดยใช้ชุดข้อมูลพระเครื่องแบบเหรียญ |
| 12. EfficeinNet | ฝึกสอนโดยใช้ชุดข้อมูลพระเครื่องแบบผสม |
| 13. Siames | ฝึกสอนโดยใช้ชุดข้อมูล พระเครื่องแบบผง |
| 14. Siames | ฝึกสอนโดยใช้ชุดข้อมูลพระเครื่องแบบเหรียญ |
| 15. Siames | ฝึกสอนโดยใช้ชุดข้อมูลพระเครื่องแบบเหรียญ |

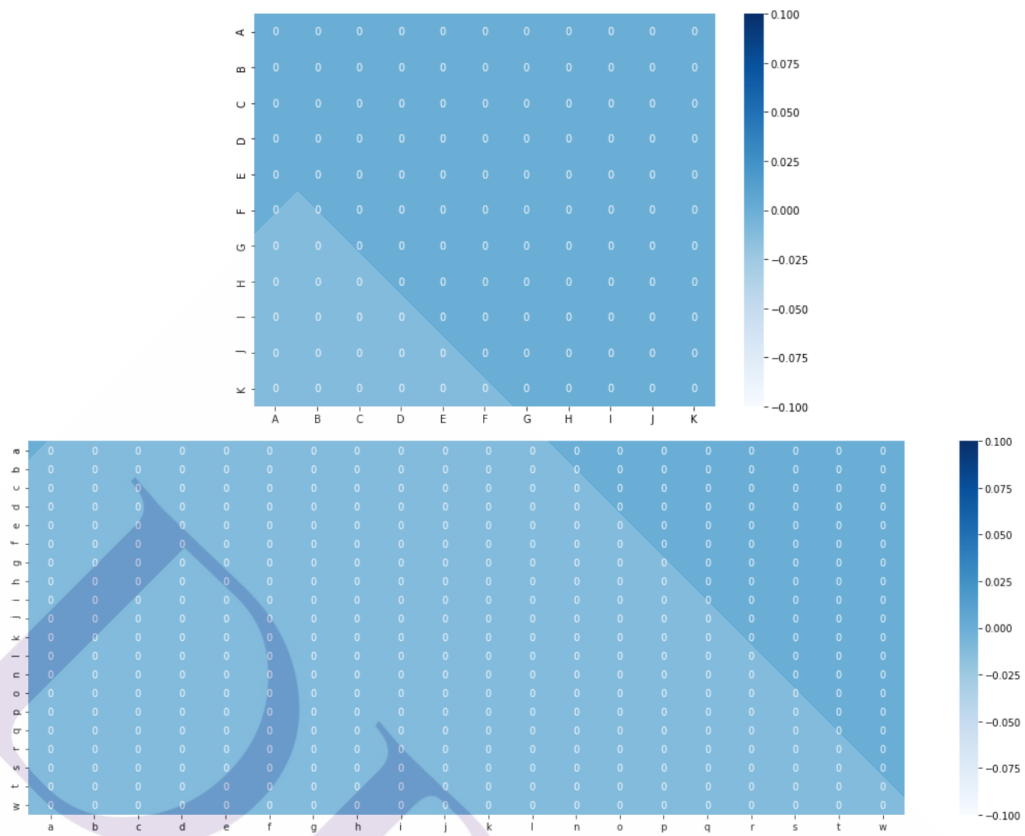
3.6.4 การแบ่งชุดข้อมูล เพื่อทำการวิจัย



ภาพที่ 3.17 กราฟแสดงจำนวนพระเครื่องแบ่งจำนวน Train 80 % : Validation:10% : Test 10%

3.7 การทดสอบประสิทธิภาพ

การวัดผลการทดสอบ คือการนับจำนวนที่ทำนายรูปภาพถูกในแต่ละคลาส และนับจำนวน โดยใช้ Matrix confusion เพื่อคำนวณค่า Precision , Recall , Accuracy ซึ่งเป็นการวัดประสิทธิภาพโมเดล



ภาพที่ 3.18 แสดงตัวอย่าง Matrix confusion 10 Class และ 20 Class


บทที่ 4

ผลการศึกษา

ในบทนี้จะทำการรายงานผลการทดลองในการทำนายพระเครื่อง โดยแยกแต่ละโมเดล และชุดข้อมูลที่ใช้ทำการทดสอบเพื่อเปรียบเทียบพารามิเตอร์ และประสิทธิภาพของแต่ละโมเดลซึ่งชุดข้อมูลได้แก่ ผลการทดสอบทำนายชื่อพระเครื่อง, ผลการทดสอบทำนายชื่อพระเครื่อง แบบพวง รุ่งย่อย และ ผลการทดสอบทำนายชื่อพระเครื่อง แบบเหรียญ รุ่งย่อย

4.1 ผลการทดสอบทำนายชื่อพระเครื่อง

4.1.1. ชุดข้อมูลชื่อพระเครื่อง



ภาพที่ 4.1 แสดงการแบ่งข้อมูลเพื่อใช้ในการทดสอบ



ภาพที่ 4.2 แสดงตัวอย่างรูปภาพที่ใช้ในการทดสอบ


4.1.2. กำหนดค่าพารามิเตอร์ของโมเดล

ตารางที่ 4.1 ค่าพารามิเตอร์ในแต่ละโมเดล

Model	Parameter	Epoch	Learning rate	Loss functions	Optimizer	Transfer learning//Train from scratch
Custom CNN	2,662,122	100	0.001	SparseCategoricalCrossentropy	Adam	None
Custom VGG16	9,291,850	100	0.001	SparseCategoricalCrossentropy	Adam	None
ResNet50	23,564,800	100	0.001	CategoricalCrossentropy	Adam	imagenet
EfficenNetB0	5,730,169	100	0.001	CategoricalCrossentropy	Adam	imagenet
EfficenNetB3	10,783,535	100	0.001	CategoricalCrossentropy	Adam	imagenet
Siamese	13,875,668	100	0.001	Margin	RMSprop	None
Custom Xception	4,220,906	500	0.001	CategoricalCrossentropy	Adam	None

แสดงค่าพารามิเตอร์ที่ใช้ในการทดสอบแต่ละโมเดล

4.1.3. ผลการทดสอบทำนายชื่อพระเครื่อง



ภาพที่ 4.3 แสดงจำนวนข้อมูลที่ใช้ในการทดสอบทำนายชื่อพระเครื่อง

ตารางที่ 4.2 ผลการทดลองทำนายชื่อพระเครื่องแบบรวมโดยใช้โมเดล Xception


Xception x4 Predict	Actual											Total	Precision for each class	Recall for each class
	LPK	LPS	LPT	LPU	PKP	PNP	PRW	PSK	PSP	PSW				
LPK	49	1	0	0	0	0	0	0	0	0	0	50	0.9800	0.9423
LPS	1	79	0	1	1	0	0	0	0	0	0	82	0.9634	0.9294
LPT	0	2	42	0	0	0	0	0	0	0	0	44	0.9545	0.9767
LPU	1	1	0	50	0	0	0	0	0	0	0	52	0.9615	0.9259
PKP	0	0	0	2	58	0	0	0	0	0	0	60	0.9667	0.9667
PNP	0	0	0	1	0	43	0	0	0	0	0	44	0.9773	0.9556
PRW	1	0	1	0	0	1	49	1	1	1	1	55	0.8909	1.0000
PSK	0	1	0	0	1	1	0	61	0	1	65	0.9385	0.9531	
PSP	0	1	0	0	0	0	0	1	46	1	49	0.9388	0.9787	
PSW	0	0	0	0	1	1	0	1	0	70	73	0.9589	0.9589	
Total	52	85	43	54	60	45	49	64	47	73	572			
Weighted class	0.091	0.149	0.075	0.094	0.105	0.079	0.086	0.112	0.082	0.128	1.000	0.9563		
Weighted Precision	0.089	0.143	0.072	0.091	0.101	0.077	0.076	0.105	0.077	0.122	0.954			
Weighted Recall	0.086	0.138	0.070	0.087	0.101	0.075	0.086	0.107	0.080	0.122	0.953			

จากตารางที่ 4.2 นี้ แสดงผลการทำนายชื่อพระเครื่องได้ถูกต้อง 95.63 % แต่ยังคงมีทำนายผิดอยู่บ้าง เนื่องจากความคล้ายคลึงกันของรูปภาพ ภาพที่ทำนายผิดจะมีความไม่สมบูรณ์ เช่น มีแสงที่ไม่ดี มีด หรือ มีความแตกหัก และมีลักษณะที่เสื่อมโทรมขององค์พระ

เมื่อใช้งานโมเดล Xception ทำนายชื่อพระเครื่องสองรุ่นย่อย โดยนำรุ่นย่อยมารวมกัน โดยแบ่งกลุ่มตามชื่อพระเครื่องได้แก่ พระเครื่อง แบบผง คือ พระสมเด็จจางขุนพรหม (KP) และ หลวงพ่อคุณ สามารถจำแนกได้ทั้งหมด เนื่องจาก ลักษณะที่แตกต่างกันชัดเจน เช่น รูปทรงของภาพ และลักษณะลายภาพ

ตารางที่ 4.3 แสดงผลทดสอบสองรุ่น โดยโมเดล Xception

Class	KP	LP
KP	100	0
LP	0	100



ภาพที่ 4.4 แสดงการสอนของสองรุ่นโดยใช้โมเดล Xception

จากทดสอบทำนายชื่อพระเครื่องโดยใช้ โมเดล Xception พบว่าสามารถทำงานได้ดี ให้เปอร์เซ็นต์ที่ 95 % นอกจากนี้ เพื่อจากยืนยันผลการทดสอบก โดยใช้โมเดล Custom CNN เข้ามาทดสอบด้วยผลที่ได้คือ โมเดล CNN สามารถทำงานได้ถูกต้องจาก กราฟการ Train จะเห็นว่าโมเดล Xception มีจะที่ไม่เป็นระนาบมีการแกว่งไปมาแต่ยังให้ผลการทดสอบที่ดี

แต่โมเดล Custom CNN กราฟแสดงค่าสอดคล้องกัน ทั้งค่า Training , Validate, Accuracy ,Loss และยังได้ผลการทดสอบที่ดี อีกด้วย

4.2 ผลการทดสอบทำนายชื่อพระเครื่องรุ่นย่อย

4.2.1 กำหนดค่าพารามิเตอร์

ตารางที่ 4.4 แสดงการตั้งค่าพารามิเตอร์ที่ใช้ในการทดสอบรุ่นย่อยใช้สถาปัตยกรรมเดียวกันกับรุ่นใหญ่

Model	Parameter	Epoch	Learning rate	Loss functions	Optimizer	Transfer learning/Train from scratch
Custom CNN	2,662,122	100	0.001	SparseCategoricalCrossentropy	Adam	None
Custom VGG16	9,291,850	100	0.001	SparseCategoricalCrossentropy	Adam	None
ResNet50	23,564,800	100	0.001	CategoricalCrossentropy	Adam	imagenet
EfficeinNetB0	5,730,169	100	0.001	CategoricalCrossentropy	Adam	imagenet
EfficeinNetB3	10,783,535	100	0.001	CategoricalCrossentropy	Adam	imagenet
Siamess	13,875,668	100	0.001	Margin	RMSprop	None
Custom Xception	4,220,906	500	0.001	CategoricalCrossentropy	Adam	None


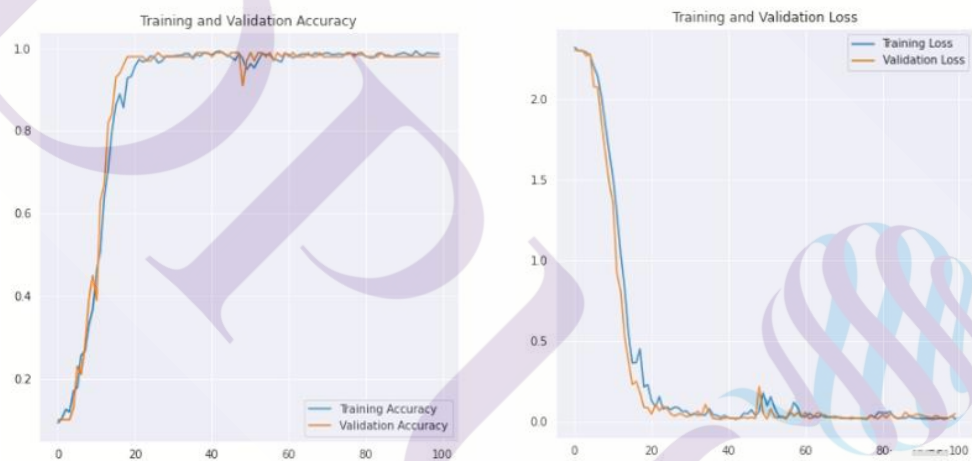
4.2.2 ผลการทดสอบทำนายคลาสพระเครื่องแบบผง รุ่นย่อย

4.2.2.1 โมเดล Custom CNN


จากการทดสอบพระเครื่องรุ่นย่อยแบบพระผง โดยกำหนดชื่อ คลาสเป็น KP0 ถึง KP9 ผลการทดสอบได้ 98% โดยทำนายผิดไป หนึ่งคลาสจำนวนสองรูป โดยชื่อที่ทำนายผิด ชื่อ พระสมเด็จพระนั่งพิมพ์ใหญ่เกษตรชุม เป็น พระสมเด็จพระนั่งพิมพ์ใหญ่เกษตรชุม เนื่องจากรูปทั้งสองมีความคล้ายคลึงกัน

ตารางที่ 4.5 ผลการทดสอบทำนายชื่อรุ่นพระเครื่องรุ่นย่อยแบบผงโดยให้ Custom CNN

Class	precision	recall	f1-score	support
KP0 (Class 0)	1.00	1.00	1.00	10.00
KP1 (Class 1)	1.00	1.00	1.00	10.00
KP2 (Class 2)	1.00	1.00	1.00	10.00
KP3 (Class 3)	1.00	1.00	1.00	10.00
KP4 (Class 4)	1.00	1.00	1.00	10.00
KP5 (Class 5)	1.00	0.80	0.89	10.00
KP6 (Class 6)	1.00	1.00	1.00	10.00
KP7 (Class 7)	0.83	1.00	0.91	10.00
KP8 (Class 8)	1.00	1.00	1.00	10.00
KP9 (Class 9)	1.00	1.00	1.00	10.00
accuracy			0.98	100.00
macro avg	0.98	0.98	0.98	100.00
weighted avg	0.98	0.98	0.98	100.00



ภาพที่ 4.5 ผลการทดสอบทำนายชื่อรุ่นพระเครื่องรุ่นย่อยแบบผงโดยให้ Custom CNN


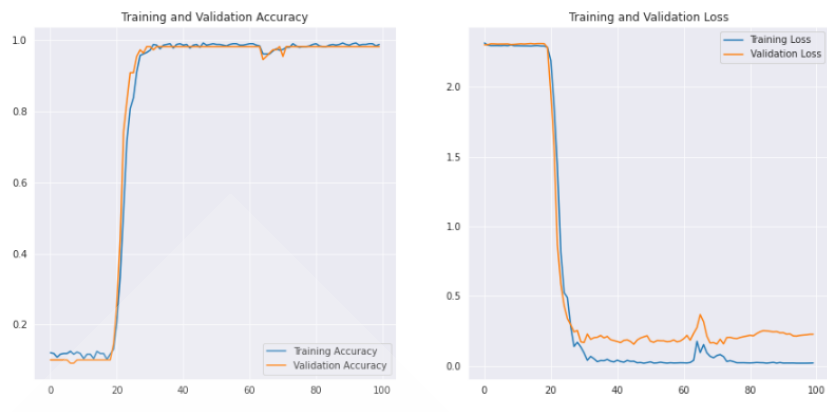


ภาพที่ 4.6 แสดงภาพที่ทำนายผิด ชื่อ พระสมเด็จระฆังพิมพ์ใหญ่เกศจรดซุ้มเป็นพระสมเด็จระฆังพิมพ์ใหญ่เกศทะลุซุ้ม

4.2.2.2 โมเดล Custom VGG16

ตารางที่ 4.6 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบผง โดยใช้โมเดล Custom VGG16

Class	precision	recall	f1-score	support
KP0 (Class 0)	1.00	1.00	1.00	10.00
KP1 (Class 1)	1.00	1.00	1.00	10.00
KP2 (Class 2)	1.00	1.00	1.00	10.00
KP3 (Class 3)	1.00	1.00	1.00	10.00
KP4 (Class 4)	1.00	1.00	1.00	10.00
KP5 (Class 5)	1.00	0.80	0.89	10.00
KP6 (Class 6)	1.00	1.00	1.00	10.00
KP7 (Class 7)	0.83	1.00	0.91	10.00
KP8 (Class 8)	1.00	1.00	1.00	10.00
KP9 (Class 9)	1.00	1.00	1.00	10.00
accuracy			0.98	100.00
macro avg	0.98	0.98	0.98	100.00
weighted avg	0.98	0.98	0.98	100.00



ภาพที่ 4.7 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบผง โดยใช้โมเดล Custom VGG16



ภาพที่ 4.8 แสดงชื่อรุ่นที่ทำนายผิด ชื่อรุ่น พระสมเด็จพิมพ์อักษรรุท และพระสมเด็จเกศทะเลลูฮุ่ม

4.2.2.3 โมเดล RESNET


ผลการทดสอบจาก การใช้งาน โมเดล RESNET ไม่สามารถทำงานชื่อพระเครื่องรุ่นย่อยแบบผงได้ทำนายผิด แบบกระจายตัวทำให้เมื่อคิดเป็น เปอร์เซ็นแล้วมีคะแนนที่ต่ำ

ตารางที่ 4.7 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบผง โดยใช้โมเดล RESNET

Class	precision	recall	f1-score	support
KP0 (Class 0)	0.14	0.20	0.17	10.00
KP1 (Class 1)	0.33	0.30	0.32	10.00
KP2 (Class 2)	0.10	0.10	0.10	10.00
KP3 (Class 3)	0.11	0.10	0.11	10.00
KP4 (Class 4)	0.12	0.10	0.11	10.00
KP5 (Class 5)	0.20	0.10	0.13	10.00
KP6 (Class 6)	0.00	0.00	0.00	10.00
KP7 (Class 7)	0.13	0.20	0.16	10.00
KP8 (Class 8)	0.00	0.00	0.00	10.00
KP9 (Class 9)	0.09	0.10	0.10	10.00
accuracy			0.12	100.00
macro avg	0.12	0.12	0.12	100.00
weighted avg	0.12	0.12	0.12	100.00

```
[12] resnet_model = ResNet50V2(include_top=False, weights='imagenet', input_shape=IMAGE_SIZE + [3])
[7] for layer in resnet_model.layers:
    layer.trainable = False
[8] resnet_model = Sequential()
    pretrained_model= tf.keras.applications.ResNet50(include_top=False,
        input_shape=(300,300,3),
        pooling='avg',classes=10,
        weights='imagenet')
    for layer in pretrained_model.layers:
        layer.trainable=False
    resnet_model.add(pretrained_model)
[13] resnet_model.add(Flatten())
    resnet_model.add(Dense(512, activation='relu'))
    resnet_model.add(Dense(10, activation='softmax'))
resnet_model.summary()
```

ภาพที่ 4.9 แสดงการตั้งค่าพารามิเตอร์สำหรับโมเดล RestNet50




```
[46] resnet_model.summary()
```

```
Model: "sequential_1"
```

Layer (type)	Output Shape	Param #
resnet50 (Functional)	(None, 2048)	23587712
flatten_4 (Flatten)	(None, 2048)	0
dense_5 (Dense)	(None, 512)	1049088
dense_6 (Dense)	(None, 5)	2565

=====
 Total params: 24,639,365
 Trainable params: 1,051,653
 Non-trainable params: 23,587,712
 =====



ภาพที่ 4.10 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบผง โดยใช้โมเดล RESNET

4.2.2.4 โมเดล EfficcinNet B0

ผลการทดสอบจาก การใช้งาน โมเดล EfficcinNet B0 ไม่สามารถทำงานชื่อพระเครื่องรุ่นย่อยแบบผงได้ทำนายผิด แบบกระจายตัวทำให้เมื่อคิดเป็น เปอร์เซ็นแล้วมีคะแนนที่ต่ำ

ตารางที่ 4.8 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบผง โดยใช้โมเดล EfficientNet B0

Class	precision	recall	f1-score	support
KP0 (Class 0)	0.00	0.00	0.00	10.00
KP1 (Class 1)	0.00	0.00	0.00	10.00
KP2 (Class 2)	0.00	0.00	0.00	10.00
KP3 (Class 3)	0.00	0.00	0.00	10.00
KP4 (Class 4)	0.00	0.00	0.00	10.00
KP5 (Class 5)	10.00	1.00	18.00	10.00
KP6 (Class 6)	0.00	0.00	0.00	10.00
KP7 (Class 7)	0.00	0.00	0.00	10.00
KP8 (Class 8)	0.00	0.00	0.00	10.00
KP9 (Class 9)	0.00	0.00	0.00	10.00
accuracy			0.10	100.00
macro avg	0.10	0.10	0.02	100.00
weighted avg	0.10	0.10	0.02	100.00


```
[ ] resnet_model = EfficientNetB0(include_top=False,weights='imagenet',input_shape=IMAGE_SIZE + [3])
[ ] for layer in resnet_model.layers:
    layer.trainable = False
[ ] resnet_model.summary()

[ ] x = Flatten()
x = Dense(100,activation='relu')
x = Dense(10,activation='softmax')

model = Model(inputs=resnet_model.input, outputs=x)

[ ] model.summary()
```

ภาพที่ 4.11 แสดงการตั้งค่าพารามิเตอร์สำหรับโมเดล EfficientNet B0



ภาพที่ 4.12 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบผง โดยใช้โมเดล EfficientNet B0



ภาพที่ 4.13 ตัวอย่างรูปที่ทำนายชื่อผิด โดยใช้โมเดล EfficeinNet B0

4.2.2.5 โมเดล EfficeinNet B3

ผลการทดสอบจากการใช้งาน โมเดล EfficeinNet B0 ไม่สามารถทำงานชื่อพระเครื่อง
รุ่นย่อยแบบผงได้ทำนายผิด แบบกระจายตัวทำให้เมื่อคิดเป็น เปอร์เซ็นแล้วมีคะแนนที่ต่ำ

ตารางที่ 4.9 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบผง โดยใช้โมเดล EfficeinNet B3

Class	precision	recall	f1-score	support
KP0 (Class 0)	0.00	0.00	0.00	10.00
KP1 (Class 1)	0.00	0.00	0.00	10.00
KP2 (Class 2)	0.00	0.00	0.00	10.00
KP3 (Class 3)	0.00	0.00	0.00	10.00
KP4 (Class 4)	0.00	0.00	0.00	10.00
KP5 (Class 5)	10.00	1.00	18.00	10.00
KP6 (Class 6)	0.00	0.00	0.00	10.00
KP7 (Class 7)	0.00	0.00	0.00	10.00
KP8 (Class 8)	0.00	0.00	0.00	10.00
KP9 (Class 9)	0.00	0.00	0.00	10.00
accuracy			0.10	100.00
macro avg	0.10	0.10	0.02	100.00
weighted avg	0.10	0.10	0.02	100.00

```
[ ] resnet_model = EfficientNetB3(include_top=False,weights='imagenet',input_shape=IMAGE_SIZE + [3])

[ ] for layer in resnet_model.layers:
    layer.trainable = False

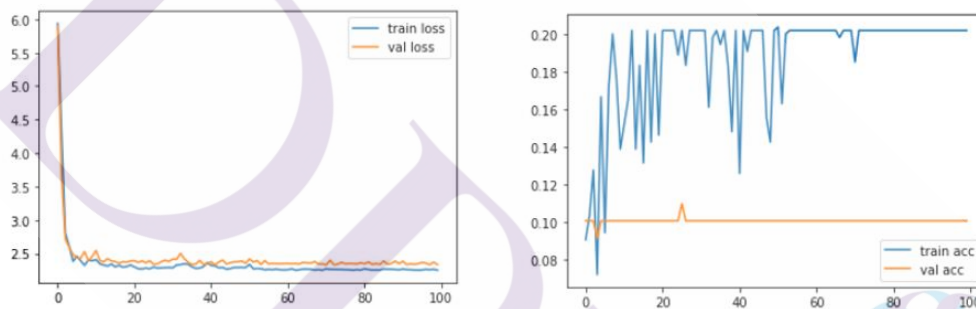
[ ] resnet_model.summary()

[ ] x = Conv2D(128, (3, 3), activation='relu')(resnet_model.output)
x = MaxPooling2D(pool_size=(2, 2))(x)
x = Flatten()(x)
x = Dense(100,activation='relu')(x)
x = Dense(10,activation='softmax')(x)

model = Model(inputs=resnet_model.input, outputs=x)

[ ] model.summary()
```

ภาพที่ 4.14 แสดงการตั้งค่าพารามิเตอร์สำหรับโมเดล EfficientNet B3



ภาพที่ 4.15 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบผง โดยใช้โมเดล EfficientNet B3



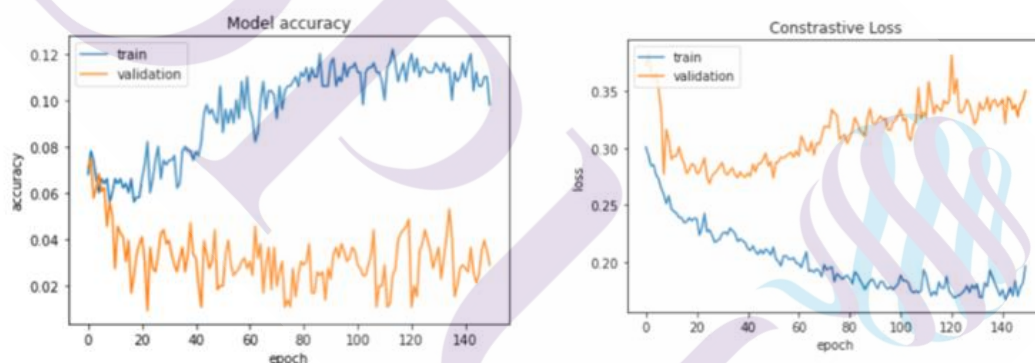
ภาพที่ 4.16 ตัวอย่างรูปที่ทำนายชื่อผิดโดยใช้โมเดล EfficientNet B3

4.2.2.6 โมเดล Siamese

ผลการทดสอบจาก การใช้งาน โมเดล Siamese ไม่สามารถทำงานชื่อพระเครื่องรุ่นย่อยแบบผงได้ทำนายผิด แบบกระจายตัวทำให้เมื่อคิดเป็น เปอร์เซ็นแล้วมีคะแนนที่ต่ำ

ตารางที่ 4.10 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบผง โดยใช้โมเดล Siamese

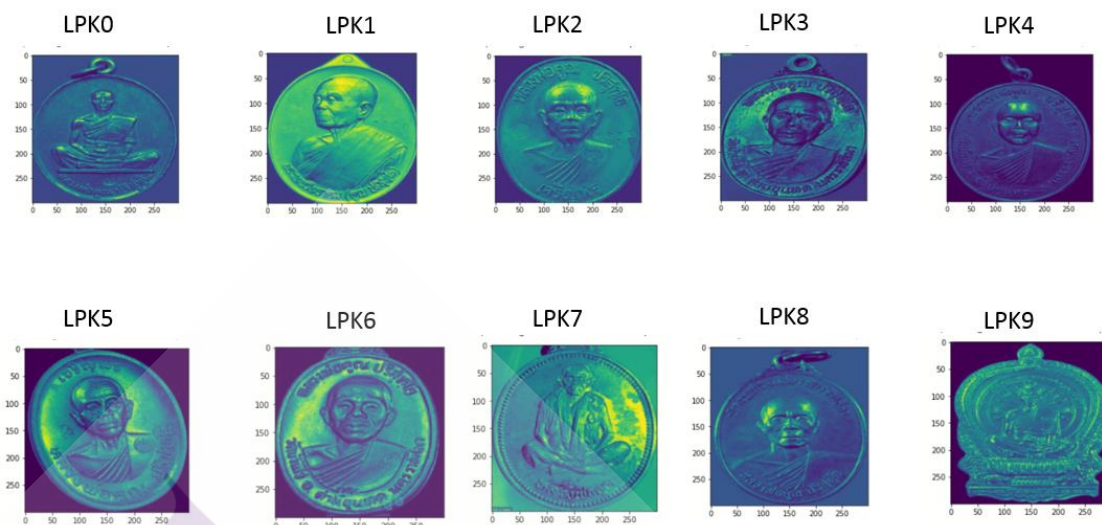
	KP0	KP1	KP2	KP3	KP4	KP5	KP6	KP7	KP8	KP9	Total	Percent
KP0	2	1	0	0	0	6	0	0	1	0	10	0.2
KP1	4	3	0	0	0	0	0	0	3	0	10	0.3
KP2	4	1	2	1	2	0	0	0	0	0	10	0.2
KP3	1	0	0	0	0	4	0	0	5	0	10	0
KP4	0	0	0	0	0	0	6	0	4	0	10	0
KP5	4	0	0	0	0	6	0	0	0	0	10	0.6
KP6	0	0	0	0	0	0	10	0	0	0	10	100
KP7	3	1	0	0	0	2	0	1	3	0	10	0.1
KP8	2	0	0	2	0	1	0	0	5	0	10	0.5
KP9	5	0	0	2	0	0	0	0	3	0	10	0
Total	25	6	2	5	2	19	16	1	24	0		10.19



ภาพที่ 4.17 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบผง โดยใช้โมเดล Siamese

4.2.3 ผลการทดสอบทำนายชื่อพระเครื่อง แบบเหรียญ รุ่นย่อย

ในหัวข้อนี้จะทำการอภิปรายการทดสอบโมเดลแต่ละแบบ โดยใช้ข้อมูลแบบเหรียญโลหะ โดยแสดงตัวอย่างข้อมูลดังรูปด้านล่างนี้ โดยการทดสอบจะดำเนินการตามลำดับ





ภาพที่ 4.18 แสดงตัวอย่างข้อมูลพระเครื่องแบบเหรียญที่ใช้ในทดลอง

4.2.3.1 โมเดล Custom CNN


การทดสอบการทำนายชื่อพระเครื่องแบบเหรียญ โดยใช้โมเดล Custom CNN สามารถทำนายชื่อได้ถูกต้อง 99 เปอร์เซ็นต์

ตารางที่ 4.11 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบเหรียญโลหะโดยใช้โมเดล Custom CNN

Class	precision	recall	f1-score	support
LPK0 (Class 0)	1	1	1	10
LPK1 (Class 1)	1	1	1	10
LPK2 (Class 2)	1	1	1	10
LPK3 (Class 3)	1	1	1	10
LPK4 (Class 4)	1	1	1	10
LPK5 (Class 5)	1	0.9	0.95	10
LPK6 (Class 6)	0.91	1	0.95	10
LPK7 (Class 7)	1	1	1	10
LPK8 (Class 8)	1	1	1	10
LPK9 (Class 9)	1	1	1	10
accuracy			0.99	100.00
macro avg	0.99	0.99	0.99	100.00
weighted avg	0.99	0.99	0.99	100.00



ภาพที่ 4.19 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบเหรียญโลหะ โดยใช้โมเดล Custom CNN



LP5



LP6



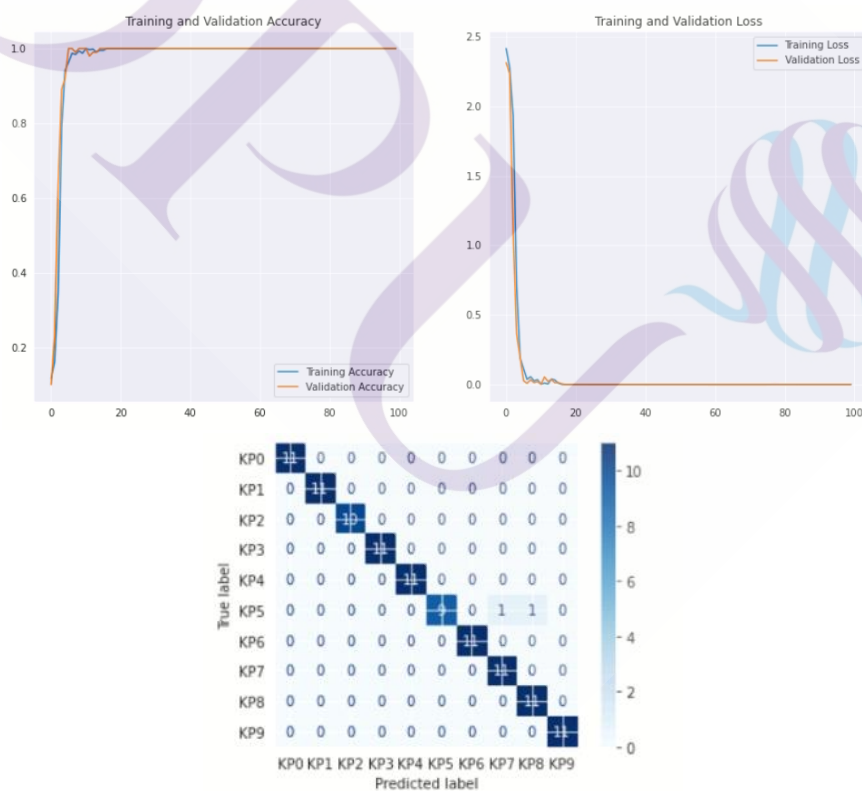
ภาพที่ 4.20 ตัวอย่างรูปที่ทำนายชื่อผิด โดยใช้โมเดล CNN

4.2.3.2 โมเดล Custom VGG16

การทดสอบการทำนายชื่อพระเครื่องแบบเหรียญ โดยใช้โมเดล Custom VGG16 สามารถทำนายชื่อได้ถูกต้อง 100 เปอร์เซ็นต์

ตารางที่ 4.12 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบเหรียญโลหะโดยใช้โมเดล Custom VGG16

Class	precision	recall	f1-score	support
LPK0 (Class 0)	1	1	1	10
LPK1 (Class 1)	1	1	1	10
LPK2 (Class 2)	1	1	1	10
LPK3 (Class 3)	1	1	1	10
LPK4 (Class 4)	1	1	1	10
LPK5 (Class 5)	1	1	1	10
LPK6 (Class 6)	1	1	1	10
LPK7 (Class 7)	1	1	1	10
LPK8 (Class 8)	1	1	1	10
LPK9 (Class 9)	1	1	1	10
accuracy			1.00	100.00
macro avg	1.00	1.00	1.00	100.00
weighted avg	1.00	1.00	1.00	100.00



ภาพที่ 4.21 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบเหรียญโลหะโดยใช้โมเดล Custom VGG16

4.2.3.3 โมเดล RESNET

การทดสอบการทำนายชื่อพระเครื่องแบบเหรียญ โดยใช้โมเดล RESNET สามารถทำนายชื่อผิดเป็นจำนวนมาก การทำนายชื่อมีการกระจายตัวการทำนายออกไปในทุกๆ ชื่อไม่สามารถระบุชื่อได้ถูกต้อง

ตารางที่ 4.13 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบเหรียญโลหะ โดยใช้โมเดล RESNET

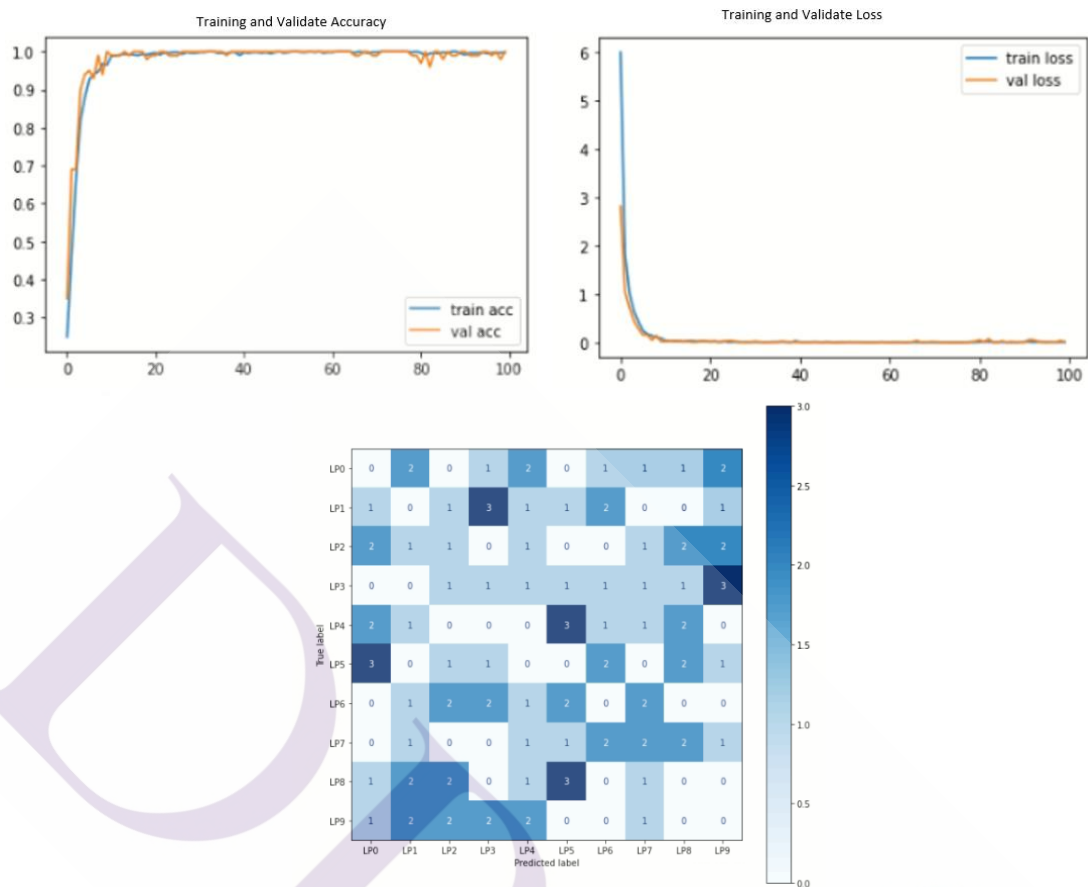
Class	precision	recall	f1-score	support
LPK0 (Class 0)	0	0	0	10
LPK1 (Class 1)	0	0	0	10
LPK2 (Class 2)	0.1	0.1	0.1	10
LPK3 (Class 3)	0.1	0.1	0.1	10
LPK4 (Class 4)	0	0	0	10
LPK5 (Class 5)	0	0	0	10
LPK6 (Class 6)	0	0	0	10
LPK7 (Class 7)	0.2	0.2	1	10
LPK8 (Class 8)	0	0	0	10
LPK9 (Class 9)	0	0	0	10
accuracy			0.40	100.00
macro avg	0.40	0.40	0.40	100.00
weighted avg	0.40	0.40	0.40	100.00

```

✓ [12] resnet_model = ResNet50V2(include_top=False, weights='imagenet', input_shape=IMAGE_SIZE + [3])
✓ [7] for layer in resnet_model.layers:
      layer.trainable = False
✓ [8] resnet_model = Sequential()
      pretrained_model= tf.keras.applications.ResNet50(include_top=False,
        input_shape=(300,300,3),
        pooling='avg',classes=10,
        weights='imagenet')
      for layer in pretrained_model.layers:
        layer.trainable=False
      resnet_model.add(pretrained_model)
✓ [13] resnet_model.add(Flatten())
      resnet_model.add(Dense(512, activation='relu'))
      resnet_model.add(Dense(10, activation='softmax'))
✓ [14] resnet_model.summary()

```

ภาพที่ 4.22 แสดงค่าพารามิเตอร์โมเดล RESNET



ภาพที่ 4.23 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบเหรียญโลหะโดยใช้โมเดล RESNET

4.2.3.4 โมเดล EfficeinNet B0

การทดสอบการทำนายชื่อพระเครื่องแบบเหรียญ โดยใช้โมเดล EfficeinNet B0 สามารถทำนายชื่อผิดเป็นจำนวนมาก การทำนายชื่อไม่มีการกระจายตัวการทำนายออกไปในทุกๆ ชื่อ แต่ไม่สามารถระบุชื่อได้ถูกต้อง


ตารางที่ 4.14 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบเหรียญโลหะโดยใช้โมเดล

EfficeinNet B0

Class	precision	recall	f1-score	support
LP0 (Class 0)	0.00	0.00	0.00	10.00
LP1 (Class 1)	0.10	0.10	0.18	10.00
LP2 (Class 2)	0.00	0.00	0.00	10.00
LP3 (Class 3)	0.00	0.00	0.00	10.00
LP4 (Class 4)	0.00	0.00	0.00	10.00
LP5 (Class 5)	0.00	0.00	0.00	10.00
LP6 (Class 6)	0.00	0.00	0.00	10.00
LP7 (Class 7)	0.00	0.00	0.00	10.00
LP8 (Class 8)	0.00	0.00	0.00	10.00
LP9 (Class 9)	0.00	0.00	0.00	10.00
accuracy			0.10	100.00
macro avg	0.01	0.10	0.02	100.00
weighted avg	0.10	0.10	0.02	100.00

```
[ ] resnet_model = EfficientNetB0(include_top=False,weights='imagenet',input_shape=IMAGE_SIZE + [3])
[ ] for layer in resnet_model.layers:
    layer.trainable = False
[ ] resnet_model.summary()
[ ] x = Flatten()
    x = Dense(100,activation='relu')
    x = Dense(10,activation='softmax')
    model = Model(inputs=resnet_model.input, outputs=x)
[ ] model.summary()
```

ภาพที่ 4.24 แสดงค่าพารามิเตอร์โมเดล RESNET



ภาพที่ 4.25 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบเหรียญโลหะ โดยใช้โมเดล EfficeinNet B0

4.2.3.5 โมเดล EfficeinNet B3

การทดสอบการทำนายชื่อพระเครื่องแบบเหรียญ โดยใช้โมเดล EfficeinNet B0 สามารถทำนายชื่อผิดเป็นจำนวนมาก การทำนายชื่อไม่มีการกระจายตัวการทำนายออกไปในทุกๆ ชื่อ แต่ไม่สามารถระบุชื่อได้ถูกต้อง

ตารางที่ 4.15 แสดงผลการทดสอบพระเครื่องรุ่นย่อยแบบเหรียญโลหะ โดยใช้โมเดล

EfficeinNet B3

Class	precision	recall	f1-score	support
LP0 (Class 0)	0.00	0.00	0.00	10.00
LP1 (Class 1)	0.10	0.10	0.19	10.00
LP2 (Class 2)	0.00	0.00	0.00	10.00
LP3 (Class 3)	0.00	0.00	0.00	10.00
LP4 (Class 4)	0.00	0.00	0.00	10.00
LP5 (Class 5)	0.00	0.00	0.00	10.00
LP6 (Class 6)	0.00	0.00	0.00	10.00
LP7 (Class 7)	0.00	0.00	0.00	10.00
LP8 (Class 8)	0.00	0.00	0.00	10.00
LP9 (Class 9)	0.00	0.00	0.00	10.00
accuracy			0.10	100.00
macro avg	0.01	0.10	0.02	100.00
weighted avg	0.10	0.10	0.02	100.00

```
[ ] resent_model = EfficientNetB3(include_top=False,weights='imagenet',input_shape=IMAGE_SIZE + [3])

[ ] for layer in resent_model.layers:
    layer.trainable = False


[ ] resent_model.summary()

[ ] x = Conv2D(128, (3, 3), activation='relu')(resent_model.output)
    x = MaxPooling2D(pool_size=(2, 2))(x)
    x = Flatten()(x)
    x = Dense(100,activation='relu')(x)
    x = Dense(10,activation='softmax')(x)

    model = Model(inputs=resent_model.input, outputs=x)

[ ] model.summary()
```

ภาพที่ 4.26 แสดงการตั้งค่าพารามิเตอร์สำหรับโมเดล EfficeinNet B3




ภาพที่ 4.27 แสดงผลการทดสอบพระเครื่องรุ่นย่อแบบเหรียญโลหะ โดยใช้โมเดล EfficientNet B3

4.2.3.6 โมเดล Siamese

การทดสอบการทำนายชื่อพระเครื่องแบบเหรียญ โดยใช้โมเดล Siamese สามารถทำนายชื่อผิดเป็นจำนวนมาก การทำนายชื่อ ไม่ถูกชื่อ แต่ไม่สามารถระบุชื่อได้ถูกต้อง

ตารางที่ 4.16 แสดงผลการทดสอบพระเครื่องรุ่นย่อแบบเหรียญโลหะ โดยใช้โมเดล Siamese

	LP0	LP1	LP2	LP3	LP4	LP5	LP6	LP7	LP8	LP9		
LP0	0	0	0	0	0	0	2	0	2	6	10	0
LP1	0	0	0	0	0	0	0	0	7	3	10	0
LP2	0	0	0	0	0	0	0	0	1	9	10	0
LP3	0	0	0	0	0	0	0	0	7	3	10	0
LP4	0	0	0	0	0	0	0	0	5	5	10	0
LP5	1	0	2	0	0	0	0	0	4	3	10	0
LP6	0	0	0	0	0	0	0	0	5	5	10	0
LP7	0	0	1	0	0	0	0	0	9	0	10	0
LP8	0	0	0	0	0	0	0	0	0	10	10	0
LP9	0	0	0	0	0	0	0	0	10	0	10	0
	1	0	3	0	0	0	2	0	50	44		0



ภาพที่ 4.28 แสดงผลการทดสอบพระเครื่องรุ่นย่อแบบเหรียญโลหะ โดยใช้โมเดล Siamese

บทที่ 5

บทสรุปและข้อเสนอแนะ

จากการดำเนินการทดลองทำนายชื่อพระเครื่อง โดยใช้วิธีการเรียนรู้เชิงลึกของเครื่อง โดยใช้โมเดลต่างๆ เพื่อเปรียบเทียบผล โดยเลือกโมเดลที่เป็นมาตรฐาน และ ใช้โมเดลที่ทำการดัดแปลง เพื่อให้สามารถทำนายชื่อพระเครื่องได้

5.1 สรุปผลการทดลอง

จากผลการทดสอบแสดงให้เห็นว่าพระเครื่องรุ่นใหญ่สามารถทำนายได้ดี 95.63 % โดย ใช้โมเดล Xception แต่เมื่อให้ทำนายผลรุ่นย่อยแล้วไม่สามารถทำนายได้ แต่เมื่อแยกรุ่นย่อยไปสอน โมเดล ต่างๆจะพบว่าโมเดล CNN ที่ใช้ในการดัดแปลงนั้นให้ผลที่ดี 98% เมื่อเปรียบเทียบกับ โมเดลที่เป็นมาตรฐานที่เมื่อทำนายไม่ถูกต้อง

5.1.1 ปัญหาที่พบในการวิจัย

1. การเก็บรวบรวมข้อมูล เนื่องจากรูปพระเครื่อง รุ่นเก่าหาข้อมูลได้ยาก
2. ความไม่สมบูรณ์ของรูปภาพ เนื่องจากมีอายุมาก หรือ ผ่านการใช้งานมา หรือมีสภาพแสงไม่เหมาะสม
3. ขนาดของรูปที่ไม่เท่ากัน เนื่องจากเป็นพฤติกรรมของผู้ใช้งานไม่สามารถควบคุมได้
4. การปะปนกันของข้อมูล มีชื่อที่คล้ายกัน ทำให้การค้นหาต้องคัดกรอง
5. จำนวนข้อมูลมีน้อย ทำให้การทำให้ต้องเพิ่มชุดข้อมูลด้วยวิธีการต่างๆ

5.2 ข้อเสนอแนะ

เนื่องจากปัจจุบันมีพระเครื่องออกมาใหม่เป็นจำนวนมากมีเครื่องถ่ายภาพที่สามารถพกพาได้สะดวก และสามารถนำเข้าระบบสารสนเทศได้สะดวก ควรมีหน่วยงานกำกับดูแลจัดทำประวัติ เพื่อเป็นการรวบรวมข้อมูลและขึ้นทะเบียนยืนยันอัตลักษณ์ และผู้ครอบครองพระเครื่อง เช่น เทคโนโลยีบล็อกเชน



บรรณานุกรม

บรรณานุกรม

- Adam Paszke Faculty of Mathematics, Informatics and Mechanics University of Warsaw, Poland
 “ENet: A Deep Neural Network Architecture for Real-Time Semantic Segmentation”
 arxiv. 1606.02147, 7 Jul ,2016
- Alex Krizhevsky, “ImageNet Classification with Deep Convolutional Neural Networks”,
 University of Toronto,2015
- Anthony Sutardja, “Andrew Fang,Coin Detection”, Report
 ,<https://andrewbfang.com/resources/coin.pdf>
- Chatree Korbuakaew:”Identification of amulets with special feature matching”, Department of
 Computing :SILPAKORN UNIVERSITY, 2007
- Chomtip Pornpanomchai, “Buddhist Amulet Recognition System”,Faculty of Information and
 Communication Technology,Mahidol University,2010
- Chomtip Pornpanomchai, ”Thai Buddhist Sculpture Recognition System”,Faculty of Information
 and Communication Technology,Mahidol University,2011
- Christian Szegedy, “Going Deeper with Convolutions”,CVPR2015,2015
- François Chollet, "Xception: Deep Learning with Depthwise Separable Convolutions", Computer
 Vision and Pattern Recognition (cs.CV),arXiv:1610.02357, 4 apr ,2017
- Ioannis Kypraios, “Advances in Object Recognition Systems”,ISBN 978-953-51-0598-5,2012
- Imanol Schlag,Ognjen Arandjelovic,School of Computer Science University of St Andrews
 Scotland,United Kingdom,ICCV2017,2017
- JINHO KIM,Comparing ,“Image Classification Methods:K-Nearest-Neighbor and Support-
 Vector-Machines”, AMERICAN-MATH'12/CEA'12 Proceedings of the 6th WSEAS
 international conference on Computer Engineering and Applications, and Proceedings
 of the 2012 American conference on Applied Mathematics,2012
- JINHO KIM , “Annotating Object Instances with a Polygon-RNN”:arXiv:1704.005548v1,19 Apr,
 2017
- Karen Simonyan, “Andrew Zisserman, Very Deep Convolutional Networks for Large-Scale
 Image Recognition”, Computer Vision and Pattern Recognition
 ,(cs.CV),arXiv:1409.1556,2014

Patompon Fugthong and Phayung Meesad,"**Buddha Amulet Information Retrieval using Digital Images Combined with Feature Extraction and K-nearest Neighbor**",Department Information Technology, Kmitnb , 2013

Pierre Sermanet, "OverFeat: Integrated Recognition, Localization and Detection using Convolutional Neural Networks",arXiv:1212.6229v4 ,24 Feb 2014

Shatrughan Modi," Image Processing Based Systems and Techniques for the Recognition of Ancient and Modern Coins", Computer Vision and Pattern Recognition (cs.CV); Artificial Intelligence (cs.AI),2013



ประวัติผู้เขียน

ชื่อ-นามสกุล

อรรถพล เรืองสุข

ประวัติการศึกษา

ครุศาสตร์อุตสาหกรรมบัณฑิต

สาขา อิเล็กทรอนิกส์ และ คอมพิวเตอร์

คณะครุศาสตร์อุตสาหกรรม

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหาร

ลาดกระบัง

ปีการศึกษา 2548

ตำแหน่งและสถานที่ทำงานปัจจุบัน

Machine learning and Ai Specialist

National ITMX.co.th

