



การขยายข้อมูลภาพสี่ด้วยการประมาณพารามิเตอร์ความเชื่อมโยงสี่ระหว่างกล้องหลายตัว



โดย
นายชนะชัย พุทธิรักษา

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรวิทยาศาสตรมหาบัณฑิต

สาขาวิชาเทคโนโลยีสารสนเทศ แผน ก แบบ ก 2 ระดับปริญญาโทมหาบัณฑิต

ภาควิชาคอมพิวเตอร์

บัณฑิตวิทยาลัย มหาวิทยาลัยศิลปากร

ปีการศึกษา 2561

ลิขสิทธิ์ของบัณฑิตวิทยาลัย มหาวิทยาลัยศิลปากร

การขยายข้อมูลภาพสี่ด้วยการประมาณพารามิเตอร์ความเชื่อมโยงสี่ระหว่างกล้องหลายตัว



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรวิทยาศาสตรมหาบัณฑิต
สาขาวิชาเทคโนโลยีสารสนเทศ แผน ก แบบ ก 2 ระดับปริญญาโทมหาบัณฑิต
ภาควิชาคอมพิวเตอร์
บัณฑิตวิทยาลัย มหาวิทยาลัยศิลปากร
ปีการศึกษา 2561
ลิขสิทธิ์ของบัณฑิตวิทยาลัย มหาวิทยาลัยศิลปากร

COLOR DATA AUGMENTATION THROUGH LEARNING COLOR-MAPPING
PARAMETERS BETWEEN CAMERAS



By

MR. Chanachai PUTTARUKSA

A Thesis Submitted in Partial Fulfillment of the Requirements
for Master of Science (INFORMATION TECHNOLOGY)

Department of COMPUTER SCIENCE

Graduate School, Silpakorn University

Academic Year 2018

Copyright of Graduate School, Silpakorn University

59309203 : เทคโนโลยีสารสนเทศ แผน ก แบบ ก 2 ระดับปริญญาโท

คำสำคัญ : การเรียนรู้เชิงลึก, การขยายข้อมูล, การปรับเทียบสี

นาย ชนะไชย พุทธิรักษา: การขยายข้อมูลภาพสีด้วยการประมาณพารามิเตอร์ความเชื่อมโยงสีระหว่างกล้องหลายตัว อาจารย์ที่ปรึกษาวิทยานิพนธ์ : ผู้ช่วยศาสตราจารย์ ดร. ภิญโญ แท้ประสาทสิทธิ์

เพื่อที่จะได้ตัวแบบโครงข่ายประสาทเทียมที่มีความแม่นยำเราจำเป็นต้องใช้ข้อมูลสำหรับฝึกสอนตัวแบบเป็นจำนวนมาก โดยเฉพาะอย่างยิ่งในงานที่เกี่ยวข้องกับรูปภาพซึ่งมักจะต้องการขยายข้อมูลเข้าช่วยเพื่อให้ได้ข้อมูลเพียงพอต่อความต้องการ เทคนิคการขยายข้อมูลเทคนิคหนึ่งที่เป็นที่นิยมคือ Color jittering ซึ่งเป็นการขยายข้อมูลโดยปรับค่าสีจากภาพต้นฉบับเล็กน้อย อย่างไรก็ตามในสถานะการจริงนั้นความแตกต่างของสีระหว่างอุปกรณ์ถ่ายภาพสองอุปกรณ์อาจมีความแตกต่างกันเป็นอย่างมาก ส่งผลให้วิธีการขยายข้อมูลดังกล่าวไม่มีประสิทธิภาพ วิทยานิพนธ์นี้จึงเสนอวิธีการจับคู่สีระหว่างอุปกรณ์ถ่ายภาพโดยใช้เทคนิคการเรียนรู้เชิงลึก ในการเรียนรู้พารามิเตอร์สำหรับจับคู่สีวิธีการที่นำเสนอนี้จะทำให้สามารถขยายข้อมูลภาพสีโดยใช้การแปลงภาพจากกล้องต้นฉบับเป็นภาพที่มีสีเหมือนกับภาพที่ถ่ายโดยกล้องเป้าหมาย วิธีการที่นำเสนอนี้จะช่วยให้สามารถสร้างตัวแบบการเรียนรู้ที่มีความชาญฉลาดในการจัดการกับภาพที่ได้จากหลายอุปกรณ์ถ่ายภาพ โดยไม่จำเป็นต้องนำภาพจริงจากอุปกรณ์เหล่านั้นมาใช้ในการฝึกสอนตัวแบบ นอกจากนี้วิธีที่นำเสนอสามารถนำไปใช้ในงานปรับเทียบสีเพื่อให้ภาพที่ได้จากกล้องหลายตัวมีสีในโทนเดียวกัน โครงข่ายประสาทเทียมสำหรับเรียนรู้พารามิเตอร์จับคู่สีที่นำเสนอในวิทยานิพนธ์นี้สามารถนำไปประยุกต์ใช้กับอุปกรณ์ถ่ายภาพอื่นๆ ได้อย่างเป็นระบบ เพื่อขยายขอบเขตการใช้งานเทคนิคที่นำเสนอในสถานะการอื่นๆ

59309203 : Major (INFORMATION TECHNOLOGY)

Keyword : deep learning, data augmentation, color calibration

MR. CHANACHAI PUTTARUKSA : COLOR DATA AUGMENTATION THROUGH
LEARNING COLOR-MAPPING PARAMETERS BETWEEN CAMERAS THESIS ADVISOR :
ASSISTANT PROFESSOR DOCTOR PINYO TAEPRASARTSIIT

In order to achieve a more accurate deep learning model, we need large amount of data. For imaging application, color data augmentation is usually required. Color jittering is a common current practice for such augmentation where color values in image are slightly adjusted. Unfortunately, color values between two cameras may be significantly different. This makes the current practice ineffective. This work proposes to map color values among cameras by using deep learning to learn color-mapping parameters. In this way, we can augment color data by converting an image from one camera to another image whose colors seemingly are taken from another camera. This allows a machine to learn a model that can deal with input images from multiple cameras without actually using training data from multiple cameras. These parameters can also be employed to calibrate colors in order that all cameras produce the same color tone. The proposed neural network architecture which employs fully connected layers and batch normalization outperforms an existing method and can be systematically performed for any camera pairs to extend its applications in other scenarios.

กิตติกรรมประกาศ

วิทยานิพนธ์เล่มนี้สำเร็จสมบูรณ์ได้ด้วยดีเพราะได้รับความกรุณาชี้แนะและช่วยเหลืออย่างดียิ่งจาก อาจารย์ที่ปรึกษาวิทยานิพนธ์ อ.ดร.ภิญโญ แพ้วประสาทสิทธิ์ ที่ให้คำแนะนำและตรวจแก้ไขข้อบกพร่องมาโดยตลอด ตั้งแต่เริ่มต้นจนสำเร็จเรียบร้อย ผู้วิจัยขอกราบขอบพระคุณด้วยความเคารพอย่างสูงไว้ ณ โอกาสนี้

ขอขอบคุณสำนักงานพัฒนาวิทยาศาสตร์และเทคโนโลยีแห่งชาติ (สวทช.) โครงการพัฒนาศักยภาพบุคลากร STEM (Science, Technology, Engineering, Mathematics) เพื่อการวิจัยและพัฒนาสำหรับภาคอุตสาหกรรม : STEM Workforce สำหรับเงินทุนในการซื้ออุปกรณ์ทำงานวิจัย

ขอขอบคุณบริษัท มูฟพลัส จำกัด สำหรับการสนับสนุนคลาวด์เซอร์วิสสมรรถนะสูง ซึ่งเป็นสิ่งจำเป็นอย่างยิ่งสำหรับการทำงานวิจัยให้สำเร็จลุล่วงไปได้ด้วยดี

ขอขอบคุณภาควิชาคอมพิวเตอร์ คณะวิทยาศาสตร์ มหาวิทยาลัยศิลปากรที่ให้โอกาสในการศึกษาต่อระดับปริญญาโทและสนับสนุนทุนการศึกษา

ชนะชัย พุทธรักษา



สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ง
บทคัดย่อภาษาอังกฤษ.....	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ.....	ช
สารบัญตาราง.....	ญ
สารบัญภาพ.....	ฎ
บทที่ 1 บทนำ.....	1
1.1 ความเป็นมาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์ของงานวิจัย.....	5
1.3 ประโยชน์ที่คาดว่าจะได้รับ.....	6
1.4 โครงร่างหัวข้อวิทยานิพนธ์.....	6
บทที่ 2 งานวิจัยที่เกี่ยวข้อง.....	7
2.1 Data augmentation for face recognition.....	7
2.2 Research on data augmentation for image classification based on convolution neural networks (Jia Shijie, 2017).....	10
2.3 Ensuring color consistency across multiple cameras.....	13
บทที่ 3 ทฤษฎีที่เกี่ยวข้อง.....	15
3.1 ระบบสีอาร์จีบี (RGB Color Model).....	15
3.2 การขยายข้อมูล (Data Augmentation).....	16
3.3 การเรียนรู้เชิงลึก (Deep Learning).....	17
3.4 การวิเคราะห์การถดถอย (Regression Analysis).....	20

บทที่ 4 วิธีการดำเนินงานวิจัย	22
4.1 การเลือกอุปกรณ์ถ่ายภาพ.....	22
4.2 การเก็บข้อมูลสำหรับฝึกสอนตัวแบบการเรียนรู้เชิงลึก	23
4.3 การออกแบบโครงข่ายประสาทเทียมสำหรับแปลงค่าสี	30
4.4 กลไกการฝึกและทดสอบตัวแบบการเรียนรู้เชิงลึกอย่างเป็นระบบ	31
4.5 การนำตัวแบบการเรียนรู้ที่ผ่านการฝึกมาใช้ในการขยายข้อมูลภาพ.....	34
บทที่ 5 ผลการดำเนินงานวิจัย.....	35
5.1 การศึกษาความคงที่ของสีจากภาพของอุปกรณ์ที่ใช้ในการทดลอง.....	35
5.2 ตัวแบบแปลงค่าสีระหว่างอุปกรณ์.....	37
5.2.1 ตัวแบบแปลงค่าสีจาก iPad Mini 4 เป็น MotoC.....	37
5.2.2 ตัวแบบแปลงค่าสีจาก MotoC เป็น iPad Mini 4.....	39
5.2.3 ตัวแบบแปลงค่าสีจาก iPad Mini 4 เป็น Galaxy S8.....	40
5.2.4 ตัวแบบแปลงค่าสีจาก Galaxy S8 เป็น iPad Mini 4.....	42
5.2.5 ตัวแบบแปลงค่าสีจาก Galaxy S8 เป็น MotoC.....	43
5.2.6 ตัวแบบแปลงค่าสีจาก MotoC เป็น Galaxy S8.....	45
5.2.7 เปรียบเทียบประสิทธิภาพของตัวแบบแปลงค่าสี.....	46
ตัวแบบแปลงค่าสีจาก iPad Mini 4 เป็น MotoC	48
ตัวแบบแปลงค่าสีจาก MotoC เป็น iPad Mini 4	50
ตัวแบบแปลงค่าสีจาก iPad Mini 4 เป็น Galaxy S8.....	51
ตัวแบบแปลงค่าสีจาก Galaxy S8 เป็น iPad Mini 4.....	53
ตัวแบบแปลงค่าสีจาก Galaxy S8 เป็น MotoC.....	54
ตัวแบบแปลงค่าสีจาก MotoC เป็น Galaxy S8.....	56
5.3 การนำตัวแบบแปลงค่าสีมาใช้ในการขยายข้อมูลภาพจากฐานข้อมูล	58
5.3.1 ฐานข้อมูล CIFAR-10.....	58

การทดลองครั้งที่ 1.....	59
การทดลองครั้งที่ 2.....	61
การทดลองครั้งที่ 3.....	63
5.3.2 ฐานข้อมูล CIFAR-100	67
การทดลองครั้งที่ 1.....	68
การทดลองครั้งที่ 2.....	69
การทดลองครั้งที่ 3.....	72
5.3.3 ฐานข้อมูล Pascal VOC.....	76
5.3.4 ฐานข้อมูลภาพบาดแผล Medetec.....	81
5.4 การทดสอบด้วยภาพจริงจากอุปกรณ์ถ่ายภาพที่ใช้ในการทดลอง.....	84
การฝึกสอนโดยใช้ข้อมูลพื้นฐานจาก CIFAR-10.....	85
การฝึกสอนด้วยข้อมูลจากตัวแบบแปลงค่าสีเป็น MotoC.....	86
การฝึกสอนด้วยข้อมูลจากตัวแบบแปลงค่าสีเป็น Galaxy S8	87
การฝึกสอนด้วยข้อมูลจากตัวแบบแปลงค่าสีเป็น iPad Mini 4.....	88
บทที่ 6 สรุปผลการดำเนินงานวิจัยและข้อเสนอแนะ	90
รายการอ้างอิง	91
ประวัติผู้เขียน.....	93

สารบัญตาราง

หน้า

ตารางที่ 1 อุปกรณ์ถ่ายภาพและเหตุผลที่เลือกใช้ในการทดลอง	22
ตารางที่ 2 รายละเอียดผลการทดสอบตัวแบบการแปลงค่าสีจากกลุ่มพารามิเตอร์ที่ 10 ซึ่งเป็นตัวแบบที่ดีที่สุดที่ได้จากการทดลองแปลงค่าสีจาก iPad Mini 4 ไปเป็น MotoC	38
ตารางที่ 3 รายละเอียดผลการทดสอบตัวแบบการแปลงค่าสีจากกลุ่มพารามิเตอร์ที่ 10 ซึ่งเป็นตัวแบบที่ดีที่สุดที่ได้จากการทดลองแปลงค่าสีจาก MotoC ไปเป็น iPad Mini 4	39
ตารางที่ 4 รายละเอียดผลการทดสอบตัวแบบการแปลงค่าสีจากกลุ่มพารามิเตอร์ที่ 10 ซึ่งเป็นตัวแบบที่ดีที่สุดที่ได้จากการทดลองแปลงค่าสีจาก iPad Mini 4 ไปเป็น Galaxy S8.....	41
ตารางที่ 5 รายละเอียดผลการทดสอบตัวแบบการแปลงค่าสีจากกลุ่มพารามิเตอร์ที่ 10 ซึ่งเป็นตัวแบบที่ดีที่สุดที่ได้จากการทดลองแปลงค่าสีจาก Galaxy S8 ไปเป็น iPad Mini 4.....	42
ตารางที่ 6 รายละเอียดผลการทดสอบตัวแบบการแปลงค่าสีจากกลุ่มพารามิเตอร์ที่ 10 ซึ่งเป็นตัวแบบที่ดีที่สุดที่ได้จากการทดลองแปลงค่าสีจาก Galaxy S8 ไปเป็น MotoC.....	44
ตารางที่ 7 รายละเอียดผลการทดสอบตัวแบบการแปลงค่าสีจากกลุ่มพารามิเตอร์ที่ 10 ซึ่งเป็นตัวแบบที่ดีที่สุดที่ได้จากการทดลองแปลงค่าสีจาก MotoC ไปเป็น Galaxy S8.....	45
ตารางที่ 8 สรุปผลการเปรียบเทียบประสิทธิภาพในการแปลงสีภาพระหว่างตัวแบบแปลงค่าสีทั้งหกตัวกับวิธี Poly Fit	57
ตารางที่ 9 พารามิเตอร์สำหรับการทดลองแบ่งประเภทภาพในการทดลองที่ 1 ของฐานข้อมูล CIFAR-10.....	59
ตารางที่ 10 ผลการทดลองแบ่งประเภทภาพการทดลองที่ 1 ในฐานข้อมูล CIFAR-10.....	60
ตารางที่ 11 พารามิเตอร์สำหรับการทดลองแบ่งประเภทภาพในการทดลองที่ 2 ของฐานข้อมูล CIFAR-10.....	62
ตารางที่ 12 ผลการทดลองแบ่งประเภทภาพการทดลองที่ 2 ในฐานข้อมูล CIFAR-10.....	62
ตารางที่ 13 พารามิเตอร์สำหรับการทดลองแบ่งประเภทภาพในการทดลองที่ 3 ของฐานข้อมูล CIFAR-10.....	64

ตารางที่ 14 ผลการทดลองแบ่งประเภทภาพการทดลองที่ 3 ในฐานข้อมูล CIFAR-10.....	65
ตารางที่ 15 สรุปผลการทดลองแบ่งประเภทภาพจากฐานข้อมูล CIFAR-10 ด้วยตัวแบบการเรียนรู้เชิงลึก ResNet20 ที่ฝึกสอนโดยข้อมูลต่างๆ กันสี่แบบ	66
ตารางที่ 16 พารามิเตอร์สำหรับการทดลองแบ่งประเภทภาพในการทดลองที่ 1 ของฐานข้อมูล CIFAR-100.....	68
ตารางที่ 17 ผลการทดลองแบ่งประเภทภาพการทดลองที่ 1 ในฐานข้อมูล CIFAR-100	69
ตารางที่ 18 พารามิเตอร์สำหรับการทดลองแบ่งประเภทภาพในการทดลองที่ 2 ของฐานข้อมูล CIFAR-100.....	70
ตารางที่ 19 ผลการทดลองแบ่งประเภทภาพการทดลองที่ 2 ในฐานข้อมูล CIFAR-100	71
ตารางที่ 20 พารามิเตอร์สำหรับการทดลองแบ่งประเภทภาพในการทดลองที่ 3 ของฐานข้อมูล CIFAR-100.....	73
ตารางที่ 21 ผลการทดลองแบ่งประเภทภาพการทดลองที่ 3 ในฐานข้อมูล CIFAR-100	74
ตารางที่ 22 สรุปผลการทดลองแบ่งประเภทภาพจากฐานข้อมูล CIFAR-100 ด้วยตัวแบบการเรียนรู้เชิงลึก ResNet32 ที่ฝึกสอนโดยข้อมูลต่างๆ กันสี่แบบ.....	75
ตารางที่ 23 พารามิเตอร์สำหรับการทดลองจำแนกวัตถุในภาพของฐานข้อมูล PascalVOC	78
ตารางที่ 24 ผลการทดลองจำแนกวัตถุในภาพจากฐานข้อมูล PascalVOC.....	78
ตารางที่ 25 ผลการทดสอบตัวแบบที่ฝึกโดยใช้ข้อมูลเฉพาะในส่วน A (ข้อมูลต้นฉบับจากฐานข้อมูล) หน่วยทั้งหมดอยู่ในรูปแบบเปอร์เซ็นต์	83
ตารางที่ 26 ผลการทดสอบของตัวแบบที่ได้รับการฝึกฝนโดยข้อมูลทั้งสามส่วน (รวมข้อมูลที่สร้างโดยการขยายข้อมูลด้วยตัวแบบแปลงค่าสี) ตัวเลขในวงเล็บแสดงว่ามีการเปลี่ยนแปลงประสิทธิภาพการทำงานอย่างไร หน่วยทั้งหมดเป็นเปอร์เซ็นต์.....	83
ตารางที่ 27 พารามิเตอร์สำหรับการทดลองด้วยภาพจริงจากอุปกรณ์ถ่ายภาพ.....	85

สารบัญภาพ

	หน้า
รูปที่ 1 ความแตกต่างระหว่างรูปที่ถ่ายจากอุปกรณ์ที่ต่างกันแม้จะถ่ายในสภาพแสงเดียวกัน	2
รูปที่ 2 การขยายข้อมูลภาพด้วยวิธี Color Jittering	2
รูปที่ 3 การเรียนรู้พารามิเตอร์ของกล้องกับการเสริมข้อมูลในฐานข้อมูลที่เกี่ยวข้อง	4
รูปที่ 4 ขั้นตอนการสังเคราะห์รูปภาพใหม่ด้วยการก่อกวนจุดสำคัญในใบหน้า	7
รูปที่ 5 ขั้นตอนการสังเคราะห์รูปภาพใหม่ด้วยการเปลี่ยนทรงผม	8
รูปที่ 6 ขั้นตอนการสังเคราะห์รูปภาพใหม่ด้วยการสวมแว่น	8
รูปที่ 7 ขั้นตอนการสังเคราะห์รูปภาพใหม่ด้วยการจำลองการเปลี่ยนท่าทางการถ่าย	9
รูปที่ 8 ขั้นตอนการสังเคราะห์รูปภาพใหม่ด้วยการเปลี่ยนสภาพแสง	9
รูปที่ 9 ความแม่นยำของตัวแบบการรู้จำใบหน้าที่ฝึกโดยข้อมูลในแบบต่างๆ ทั้งข้อมูลต้นฉบับและที่สังเคราะห์ขึ้น	10
รูปที่ 10 การขยายข้อมูลแบบ Unsupervised (a) ภาพต้นฉบับ (b) การกลับภาพ (c) การหมุนภาพ (d) การครอบตัด (e) การครอบตัดแบบสุ่ม (f) การเลื่อนวัตถุในภาพ (g) การใส่สัญญาณรบกวนลงในภาพ (h) color jittering (i) PCA-jittering	11
รูปที่ 11 การขยายข้อมูลภาพแบบ Supervised	11
รูปที่ 12 ความแม่นยำของตัวแบบการรู้จำวัตถุที่ฝึกด้วยข้อมูลที่ผ่านการขยายด้วยเทคนิคต่างๆ	12
รูปที่ 13 ความแตกต่างของค่าสี RGB จากภาพของกล้องแต่ละตัวก่อนการปรับเทียบในระดับฮาร์ดแวร์	13
รูปที่ 14 ความแตกต่างของค่าสี RGB จากภาพของกล้องแต่ละตัวหลังการปรับเทียบในระดับฮาร์ดแวร์	13
รูปที่ 15 ความแตกต่างของค่าสี RGB หลังการปรับเทียบด้วยซอฟต์แวร์ทั้งสามวิธี ได้แก่ least-square, 3x3 RGB to RGB linear transform และ general polynomial transform ตามลำดับ	14
รูปที่ 16 ตัวอย่างการผสมสีในระบบสี RGB การรวมกันของทั้งสามสี แดง เขียวและน้ำเงินในความเข้มเท่ากันทำให้เกิดสีขาวในบริเวณกลางภาพ	15

รูปที่ 17 ความสัมพันธ์ระหว่างปริมาณของข้อมูลในการฝึกสอนและความแม่นยำของตัวแบบการเรียนรู้เชิงลึก (ที่มา <https://hackernoon.com/%EF%B8%8F-big-challenge-in-deep-learning-training-data-31a88b97b282>) 16

รูปที่ 18 ตัวอย่างการขยายข้อมูลรูปภาพด้วยเทคนิคต่างๆ 17

รูปที่ 19 โครงข่ายประสาทเทียมแบบปรกติและโครงข่ายประสาทเทียมในตัวแบบการเรียนรู้แบบลึก 19

รูปที่ 20 จัดแบ่งการวิเคราะห์การถดถอยตามชนิดของข้อมูลที่ต้องการจะวิเคราะห์ 21

รูปที่ 21 ราคาของอุปกรณ์ถ่ายภาพที่ใช้ในการทดลอง..... 23

รูปที่ 22 คุณสมบัติของกล้องในอุปกรณ์ถ่ายภาพที่ใช้ในการทดลอง..... 23

รูปที่ 23 วิธีการสร้างข้อมูลสำหรับฝึกสอนตัวแบบแปลงค่าสี..... 24

รูปที่ 24 เฉดสีทั้งหมดที่ใช้เป็นข้อมูลฝึกสอนตัวแบบแปลงค่าสี จำนวน 32,768 สี..... 25

รูปที่ 25 ภาพหมายเลขหนึ่งสำหรับใช้เป็นข้อมูลฝึกสอนตัวแบบแปลงค่าสี ประกอบด้วยเฉดสีทั้งหมด 1,120 สี ภายในตารางขนาด 40 * 28..... 25

รูปที่ 26 การทำ Perspective Transform และการครอบตัดเพื่อแก้ไขความลาดเอียงของภาพ 26

รูปที่ 27 การแบ่งภาพออกเป็นสี่ส่วนแล้วจึงทำ Perspective Transform และครอบตัดภาพเพื่อให้เก็บข้อมูลที่มีความแม่นยำมากขึ้น..... 27

รูปที่ 28 การเก็บข้อมูลสำหรับฝึกสอนตัวแบบแปลงค่าสีจากรูปที่ถ่ายโดยอุปกรณ์ที่ใช้ในการทดลอง 28

รูปที่ 29 การจับคู่ข้อมูลสำหรับสร้างเป็นข้อมูลฝึกสอนตัวแบบแปลงค่าสีระหว่างอุปกรณ์ 29

รูปที่ 30 สรุปขั้นตอนการเก็บข้อมูลสำหรับฝึกสอนตัวแบบการเรียนรู้เชิงลึกสำหรับการแปลงค่าสีระหว่างอุปกรณ์..... 29

รูปที่ 31 สถาปัตยกรรมโครงข่ายประสาทเทียมของตัวแบบการเรียนรู้เชิงลึกทั้งสามแบบที่ใช้ในการทดลอง 30

รูปที่ 32 ตัวอย่างไฟล์พารามิเตอร์เซตในการทดลองครั้งที่ 60 ซึ่งเป็นการทดลองสร้างตัวแบบแปลงค่าสีจาก iPad Mini 4 เป็น MotoC โดยมีกลุ่มพารามิเตอร์ทั้งหมด 10 กลุ่ม (Combination) และใช้สถาปัตยกรรมโครงข่ายประสาทเทียมแบบ 3 เลเยอร์ 32

รูปที่ 33 ตัวอย่างผลลัพธ์ที่ได้จากการฝึกโดยกลุ่มพารามิเตอร์หนึ่งกลุ่ม	33
รูปที่ 34 กลไกการฝึกสอนตัวแบบการเรียนรู้เชิงลึกสำหรับแปลงค่าสีระหว่างอุปกรณ์อย่างเป็นระบบ	33
รูปที่ 35 กลไกการใช้ตัวแบบที่ผ่านการฝึกสอนแปลงค่าสีจากภาพต้นฉบับให้เป็นสีจากภาพเป้าหมาย	34
รูปที่ 36 Color Palette สำหรับใช้ทดสอบความคงที่ของสีจากภาพที่ถ่ายโดยอุปกรณ์ที่ใช้ในการทดลอง	35
รูปที่ 37 ความคงที่ของสีจากภาพของ MotoC เมื่อมองจากมุมมองตามแกน R แกน G และแกน B ตามลำดับ	36
รูปที่ 38 ความคงที่ของสีจากภาพของ iPad Mini 4 เมื่อมองจากมุมมองตามแกน R แกน G และแกน B ตามลำดับ	36
รูปที่ 39 ความคงที่ของสีจากภาพของ Galaxy S8 เมื่อมองจากมุมมองตามแกน R แกน G และแกน B ตามลำดับ	36
รูปที่ 40 ประสิทธิภาพของตัวแบบแปลงค่าสีจาก iPad Mini 4 ไปเป็น MotoC แห่งสีแดงเขียวและน้ำเงินแสดงค่าเฉลี่ยของการแมพสีที่ผิดพลาดของตัวแบบแต่ละตัว แห่งสีดำแสดงผลรวมของการแมพสีที่ผิดพลาดจากทั้งสามแกนแลสี	38
รูปที่ 41 ประสิทธิภาพของตัวแบบแปลงค่าสีจาก MotoC ไปเป็น iPad Mini 4 แห่งสีแดงเขียวและน้ำเงินแสดงค่าเฉลี่ยของการแมพสีที่ผิดพลาดของตัวแบบแต่ละตัว แห่งสีดำแสดงผลรวมของการแมพสีที่ผิดพลาดจากทั้งสามแกนแลสี	39
รูปที่ 42 ประสิทธิภาพของตัวแบบแปลงค่าสีจาก iPad Mini 4 ไปเป็น Galaxy S8 แห่งสีแดงเขียวและน้ำเงินแสดงค่าเฉลี่ยของการแมพสีที่ผิดพลาดของตัวแบบแต่ละตัว แห่งสีดำแสดงผลรวมของการแมพสีที่ผิดพลาดจากทั้งสามแกนแลสี	41
รูปที่ 43 ประสิทธิภาพของตัวแบบแปลงค่าสีจาก Galaxy S8 ไปเป็น iPad Mini 4 แห่งสีแดงเขียวและน้ำเงินแสดงค่าเฉลี่ยของการแมพสีที่ผิดพลาดของตัวแบบแต่ละตัว แห่งสีดำแสดงผลรวมของการแมพสีที่ผิดพลาดจากทั้งสามแกนแลสี	42

รูปที่ 44 ประสิทธิภาพของตัวแบบแปลงค่าสีจาก Galaxy S8 ไปเป็น MotoC แห่งสีแดงเขียวและน้ำเงินแสดงค่าเฉลี่ยของการแมพสีที่ผิดพลาดของตัวแบบแต่ละตัว แห่งสีดำแสดงผลรวมของการแมพสีที่ผิดพลาดจากทั้งสามแกนแนลสี.....	44
รูปที่ 45 ประสิทธิภาพของตัวแบบแปลงค่าสีจาก MotoC ไปเป็น Galaxy S8 แห่งสีแดงเขียวและน้ำเงินแสดงค่าเฉลี่ยของการแมพสีที่ผิดพลาดของตัวแบบแต่ละตัว แห่งสีดำแสดงผลรวมของการแมพสีที่ผิดพลาดจากทั้งสามแกนแนลสี.....	45
รูปที่ 46 ภาพสำหรับเก็บข้อมูลเพื่อสร้างข้อมูลชุด Random Set แต่ละภาพประกอบด้วยสีที่ถูกสุ่มขึ้นมาจำนวน 1,120 สี	47
รูปที่ 47 การเปรียบเทียบประสิทธิภาพของตัวแบบแปลงค่าสีจาก iPad Mini 4 เป็น MotoC กราฟด้านซ้ายทดสอบโดย Generate Set และกราฟด้านขวาทดสอบโดย Random Set.....	48
รูปที่ 48 เปรียบเทียบภาพที่ขยายข้อมูลโดยตัวแบบแปลงค่าสี iPadtoMotoC (A) ภาพต้นฉบับจาก iPad Mini 4 (B) ภาพเป้าหมายจาก MotoC (C) ภาพต้นฉบับที่แปลงค่าสีด้วยวิธี Poly Fit (D) ภาพต้นฉบับที่แปลงค่าสีด้วยตัวแบบแปลงค่าสี iPadtoMotoC	49
รูปที่ 49 เปรียบเทียบ Histogram จากภาพที่ขยายข้อมูลโดยตัวแบบแปลงค่าสี iPadtoMotoC (A) ภาพต้นฉบับจาก iPad Mini 4 (B) ภาพเป้าหมายจาก MotoC (C) ภาพต้นฉบับที่แปลงค่าสีด้วยวิธี Poly Fit (D) ภาพต้นฉบับที่แปลงค่าสีด้วยตัวแบบแปลงค่าสี iPadtoMotoC.....	49
รูปที่ 50 การเปรียบเทียบประสิทธิภาพของตัวแบบแปลงค่าสีจาก MotoC เป็น iPad Mini 4 กราฟด้านซ้ายทดสอบโดย Generate Set และกราฟด้านขวาทดสอบโดย Random Set.....	50
รูปที่ 51 เปรียบเทียบภาพที่ขยายข้อมูลโดยตัวแบบแปลงค่าสี MotoCtoiPad (A) ภาพต้นฉบับจาก MotoC (B) ภาพเป้าหมายจาก iPad Mini 4 (C) ภาพต้นฉบับที่แปลงค่าสีด้วยวิธี Poly Fit (D) ภาพต้นฉบับที่แปลงค่าสีด้วยตัวแบบแปลงค่าสี MotoCtoiPad	50
รูปที่ 52 เปรียบเทียบ Histogram จากภาพที่ขยายข้อมูลโดยตัวแบบแปลงค่าสี MotoCtoiPad (A) ภาพต้นฉบับจาก MotoC (B) ภาพเป้าหมายจาก iPad Mini 4 (C) ภาพต้นฉบับที่แปลงค่าสีด้วยวิธี Poly Fit (D) ภาพต้นฉบับที่แปลงค่าสีด้วยตัวแบบแปลงค่าสี MotoCtoiPad.....	51
รูปที่ 53 การเปรียบเทียบประสิทธิภาพของตัวแบบแปลงค่าสีจาก iPad Mini 4 เป็น Galaxy S8 กราฟด้านซ้ายทดสอบโดย Generate Set และกราฟด้านขวาทดสอบโดย Random Set.....	51

รูปที่ 54 เปรียบเทียบภาพที่ขยายข้อมูลโดยตัวแบบแปลงค่าสี iPadtoS8 (A) ภาพต้นฉบับจาก iPad Mini 4 (B) ภาพเป้าหมายจาก Galaxy S8 (C) ภาพต้นฉบับที่แปลงค่าสีด้วยวิธี Poly Fit (D) ภาพต้นฉบับที่แปลงค่าสีด้วยตัวแบบแปลงค่าสี iPadtoS8..... 52

รูปที่ 55 เปรียบเทียบ Histogram จากภาพที่ขยายข้อมูลโดยตัวแบบแปลงค่าสี iPadtoS8 (A) ภาพต้นฉบับจาก iPad Mini 4 (B) ภาพเป้าหมายจาก Galaxy S8 (C) ภาพต้นฉบับที่แปลงค่าสีด้วยวิธี Poly Fit (D) ภาพต้นฉบับที่แปลงค่าสีด้วยตัวแบบแปลงค่าสี iPadtoS8 52

รูปที่ 56 การเปรียบเทียบประสิทธิภาพของตัวแบบแปลงค่าสีจาก Galaxy S8 เป็น iPad Mini 4 กราฟด้านซ้ายทดสอบโดย Generate Set และกราฟด้านขวาทดสอบโดย Random Set..... 53

รูปที่ 57 เปรียบเทียบภาพที่ขยายข้อมูลโดยตัวแบบแปลงค่าสี S8toiPad (A) ภาพต้นฉบับจาก Galaxy S8 (B) ภาพเป้าหมายจาก iPad Mini 4 (C) ภาพต้นฉบับที่แปลงค่าสีด้วยวิธี Poly Fit (D) ภาพต้นฉบับที่แปลงค่าสีด้วยตัวแบบแปลงค่าสี S8toiPad..... 53

รูปที่ 58 เปรียบเทียบ Histogram จากภาพที่ขยายข้อมูลโดยตัวแบบแปลงค่าสี S8toiPad (A) ภาพต้นฉบับจาก Galaxy S8 (B) ภาพเป้าหมายจาก iPad Mini 4 (C) ภาพต้นฉบับที่แปลงค่าสีด้วยวิธี Poly Fit (D) ภาพต้นฉบับที่แปลงค่าสีด้วยตัวแบบแปลงค่าสี S8toiPad 54

รูปที่ 59 การเปรียบเทียบประสิทธิภาพของตัวแบบแปลงค่าสีจาก Galaxy S8 เป็น MotoC กราฟด้านซ้ายทดสอบโดย Generate Set และกราฟด้านขวาทดสอบโดย Random Set..... 54

รูปที่ 60 เปรียบเทียบภาพที่ขยายข้อมูลโดยตัวแบบแปลงค่าสี S8toMotoC (A) ภาพต้นฉบับจาก Galaxy S8 (B) ภาพเป้าหมายจาก MotoC (C) ภาพต้นฉบับที่แปลงค่าสีด้วยวิธี Poly Fit (D) ภาพต้นฉบับที่แปลงค่าสีด้วยตัวแบบแปลงค่าสี S8toMotoC 55

รูปที่ 61 เปรียบเทียบ Histogram จากภาพที่ขยายข้อมูลโดยตัวแบบแปลงค่าสี S8toMotoC (A) ภาพต้นฉบับจาก Galaxy S8 (B) ภาพเป้าหมายจาก MotoC (C) ภาพต้นฉบับที่แปลงค่าสีด้วยวิธี Poly Fit (D) ภาพต้นฉบับที่แปลงค่าสีด้วยตัวแบบแปลงค่าสี S8toMotoC..... 55

รูปที่ 62 การเปรียบเทียบประสิทธิภาพของตัวแบบแปลงค่าสีจาก Galaxy S8 เป็น MotoC กราฟด้านซ้ายทดสอบโดย Generate Set และกราฟด้านขวาทดสอบโดย Random Set..... 56

รูปที่ 63 เปรียบเทียบภาพที่ขยายข้อมูลโดยตัวแบบแปลงค่าสี MotoCtoS8 (A) ภาพต้นฉบับจาก MotoC (B) ภาพเป้าหมายจาก Galaxy S8 (C) ภาพต้นฉบับที่แปลงค่าสีด้วยวิธี Poly Fit (D) ภาพต้นฉบับที่แปลงค่าสีด้วยตัวแบบแปลงค่าสี MotoCtoS8 56

รูปที่ 64 เปรียบเทียบ Histogram จากภาพที่ขยายข้อมูลโดยตัวแบบแปลงค่าสี MotoCtoS8 (A) ภาพต้นฉบับจาก MotoC (B) ภาพเป้าหมายจาก Galaxy S8 (C) ภาพต้นฉบับที่แปลงค่าสีด้วยวิธี Poly Fit (D) ภาพต้นฉบับที่แปลงค่าสีด้วยตัวแบบแปลงค่าสี MotoCtoS8.....	57
รูปที่ 65 ตัวอย่างภาพทั้ง 10 หมวดหมู่จากฐานข้อมูล CIFAR-10	58
รูปที่ 66 กราฟเปรียบเทียบความแม่นยำของตัวแบบแบ่งประเภทภาพในการทดลองที่ 3 โดยชุดข้อมูลทดสอบจากฐานข้อมูล CIFAR-10 แกนนอนแสดงจำนวน Epoch และแกนตั้งแสดงค่าความแม่นยำ (Accuracy).....	60
รูปที่ 67 กราฟเปรียบเทียบความแม่นยำของตัวแบบแบ่งประเภทภาพในการทดลองที่ 2 โดยชุดข้อมูลทดสอบจากฐานข้อมูล CIFAR-10 แกนนอนแสดงจำนวน Epoch และแกนตั้งแสดงค่าความแม่นยำ (Accuracy).....	62
รูปที่ 68 ตัวอย่างภาพจากฐานข้อมูล CIFAR-10 ที่ผ่านการขยายข้อมูล คอลัมน์ 1 แสดงภาพจากฐานข้อมูลที่ไม่ได้ผ่านการแปลงสี คอลัมน์ 2 ถึง 7 แสดงภาพที่แปลงสีโดยตัวแบบแปลงสีทั้งหกตัว คอลัมน์ 8 ถึง 13 แสดงภาพที่ผ่านการแปลงสีโดยใช้ตัวแบบแปลงสีสองตัว และคอลัมน์ที่สิบสี่แสดงภาพที่แปลงสีโดยวิธี PCA-jittering	65
รูปที่ 69 กราฟเปรียบเทียบความแม่นยำของตัวแบบแบ่งประเภทภาพในการทดลองที่ 3 โดยชุดข้อมูลทดสอบจากฐานข้อมูล CIFAR-10 แกนนอนแสดงจำนวน Epoch และแกนตั้งแสดงค่าความแม่นยำ (Accuracy).....	66
รูปที่ 70 ตัวอย่างหมวดหมู่ภาพจากฐานข้อมูล CIFAR-100 ซึ่งมีหมวดหมู่ภาพกว่า 100 หมวดหมู่..	67
รูปที่ 71 กราฟเปรียบเทียบความแม่นยำของตัวแบบแบ่งประเภทภาพในการทดลองที่ 1 โดยชุดข้อมูลทดสอบจากฐานข้อมูล CIFAR-100 แกนนอนแสดงจำนวน Epoch และแกนตั้งแสดงค่าความแม่นยำ (Accuracy).....	69
รูปที่ 72 กราฟเปรียบเทียบความแม่นยำของตัวแบบแบ่งประเภทภาพในการทดลองที่ 2 โดยชุดข้อมูลทดสอบจากฐานข้อมูล CIFAR-100 แกนนอนแสดงจำนวน Epoch และแกนตั้งแสดงค่าความแม่นยำ (Accuracy).....	71
รูปที่ 73 ตัวอย่างภาพจากฐานข้อมูล CIFAR-100 ที่ผ่านการขยายข้อมูล คอลัมน์ 1 แสดงภาพจากฐานข้อมูลที่ไม่ได้ผ่านการแปลงสี คอลัมน์ 2 ถึง 7 แสดงภาพที่แปลงสีโดยตัวแบบแปลงสีทั้งหกตัว คอลัมน์ 8 ถึง 13 แสดงภาพที่ผ่านการแปลงสีโดยใช้ตัวแบบแปลงสีสองตัว	74

รูปที่ 74 กราฟเปรียบเทียบความแม่นยำของตัวแบบแบ่งประเภทภาพในการทดลองที่ 3 โดยชุดข้อมูลทดสอบจากฐานข้อมูล CIFAR-100 แขนอนแสดงจำนวน Epoch และแกนตั้งแสดงค่าความแม่นยำ (Accuracy)..... 75

รูปที่ 75 ตัวอย่างการ Segmentation ภาพจากฐานข้อมูล PascalVOC โดยโมเดลจำแนกวัตถุ..... 76

รูปที่ 76 ตัวอย่างการคำนวณค่า IoU 77

รูปที่ 77 กราฟเปรียบเทียบความแม่นยำของตัวแบบจำแนกวัตถุ โดยชุดข้อมูลทดสอบจากฐานข้อมูล PascalVOC แขนอนแสดงจำนวน Steps และแกนตั้งแสดงค่าเฉลี่ยของ IoU..... 79

รูปที่ 78 เปรียบเทียบการจำแนกวัตถุโดยตัวแบบทั้งสี่ตัวจากการทดลองในรูปแบบตัวอย่างจากฐานข้อมูล PascalVOC 80

รูปที่ 79 เปรียบเทียบภาพบาดแผลจากฐานข้อมูล Medetec กับภาพที่ผ่านการขยายข้อมูลด้วยตัวแบบ S8toiPad และ MotoCtoS8 82

รูปที่ 80 ความแม่นยำในการจำแนกประเภทภาพของตัวแบบที่ฝึกสอนโดยข้อมูลจากฐานข้อมูล CIFAR-10..... 85

รูปที่ 81 ความแม่นยำในการจำแนกประเภทภาพของตัวแบบที่ฝึกสอนโดยข้อมูลจาก CIFAR-10 รวมกับภาพที่ผ่านการขยายข้อมูลด้วยตัวแบบแปลงค่าสี S8toMotoC และ iPadtoMotoC 86

รูปที่ 82 ความแม่นยำในการจำแนกประเภทภาพของตัวแบบที่ฝึกสอนโดยข้อมูลจาก CIFAR-10 รวมกับภาพที่ผ่านการขยายข้อมูลด้วยตัวแบบแปลงค่าสี iPadtoS8 และ MotoCtoS8..... 87

รูปที่ 83 ความแม่นยำในการจำแนกประเภทภาพของตัวแบบที่ฝึกสอนโดยข้อมูลจาก CIFAR-10 รวมกับภาพที่ผ่านการขยายข้อมูลด้วยตัวแบบแปลงค่าสี MotoCtoiPad และ S8toiPad..... 88

บทที่ 1


บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

เพื่อที่จะได้ตัวแบบโครงข่ายประสาทเทียมที่มีความแม่นยำในการจำแนกวัตถุในรูปภาพสีนั้น ข้อมูลที่ใช้ในการฝึกสอนโครงข่ายประสาทเทียมเป็นปัจจัยสำคัญที่ส่งผลต่อความแม่นยำ ถ้าข้อมูลสำหรับฝึกสอนไม่เพียงพอหรือมีคุณภาพที่ต่ำ ย่อมส่งผลให้ได้ตัวแบบโครงข่ายประสาทเทียมที่ไม่มีประสิทธิภาพและขาดความแม่นยำในการจำแนกวัตถุไปด้วย


สำหรับงานที่เกี่ยวข้องกับรูปภาพ เทคนิคที่นิยมใช้อย่างแพร่หลายเพื่อให้ได้ข้อมูลที่เพียงพอต่อความต้องการสำหรับฝึกสอนโครงข่ายประสาทเทียม ได้แก่ การกลับด้านรูปภาพ การหมุนภาพ การปรับขนาด การครอบตัดและการใส่สัญญาณรบกวนในภาพ นอกจากนี้ยังมีเทคนิคที่เกี่ยวข้องกับการปรับค่าสีในภาพ เทคนิคดังกล่าวเรียกว่า “color jittering” ซึ่งเป็นการสร้างรูปภาพใหม่โดยใช้การปรับสีจากรูปภาพที่มีอยู่เดิมเล็กน้อย อย่างไรก็ตามวิธีดังกล่าวนำไปสู่ความไม่มีประสิทธิภาพหลายประการด้วยกัน เนื่องจากความไม่แน่นอนของช่วงสีที่ต้องปรับ และจำนวนของสีที่ต้องปรับ แม้ว่าในบางกรณีความไม่แน่นอนนี้อาจเป็นที่ต้องการ แต่ในบางกรณีความไม่แน่นอนดังกล่าวกลับกลายเป็นจุดเสียเปรียบ

ยกตัวอย่างเช่นในรูปที่ 1 ภาพทางด้านซ้ายและขวามีความคล้ายคลึงกันและถ่ายในสภาพแสงเดียวกัน แต่ภาพทั้งสองกลับมีความแตกต่างกันอย่างมากในแง่ของค่าสี RGB ซึ่งเป็นผลมาจากอุปกรณ์ที่ใช้ถ่ายภาพทั้งสอง ดังนั้นการปรับค่าสีเพียงเล็กน้อยด้วยวิธี color jittering นั้นจึงไม่สามารถสร้างรูปภาพใหม่ให้มีโทนสีเดียวกับภาพจากอีกอุปกรณ์ได้



รูปที่ 1 ความแตกต่างระหว่างรูปที่ถ่ายจากอุปกรณ์ที่ต่างกันแม้จะถ่ายในสภาพแสงเดียวกัน

สิ่งนี้อาจเป็นสาเหตุที่ทำให้ตัวแบบที่ผ่านการฝึกมีประสิทธิภาพด้อยกว่าที่ควรจะเป็นในกรณีที่ตัวแบบต้องทำงานกับภาพที่ถ่ายจากอุปกรณ์อื่นๆ ที่ไม่ได้มาจากภาพที่ใช้ฝึกสอน อย่างไรก็ตามเราอาจจะแก้ปัญหาแบบชั่วคราวด้วยการเพิ่มความกว้างช่วงสีที่ต้องปรับในช่วงที่ทำให้ color jittering แต่การทำเช่นนี้จะนำไปสู่ปัญหาของการมีข้อมูลสำหรับฝึกสอนมากเกินไป และภาพที่ได้จากการทำ color jittering นั้นจะดูไม่เป็นธรรมชาติซึ่งจะส่งผลเสียต่อตัวแบบการเรียนรู้



รูปที่ 2 การขยายข้อมูลภาพด้วยวิธี Color Jittering

เพื่อที่จะแก้ไขปัญหาดังกล่าว จึงควรใช้การหาพารามิเตอร์สำหรับการจับคู่สีระหว่างกล้องสองตัวโดยใช้ตัวแบบการเรียนรู้เชิงลึกที่รับข้อมูลเข้าเป็นค่า RGB จากภาพที่ถ่ายโดยกล้องหนึ่งและให้ผลลัพธ์ออกเป็นค่า RGB ที่ถ่ายได้จากอีกกล้องหนึ่ง ซึ่งจะทำให้เราสามารถสร้างรูปภาพใหม่โดยอาศัยพารามิเตอร์เหล่านั้น ในทางเทคนิคแล้ว ภาพที่สร้างขึ้นจะมีโทนสีที่เหมือนกับภาพจากกล้องอีกตัว

ด้วยวิธีนี้เองเราจึงสามารถปรับค่า RGB ของภาพอย่างมากโดยไม่ต้องอาศัยวิธีการปรับค่าสีแบบสุ่มและทำให้ได้ข้อมูลสำหรับฝึกสอนโครงข่ายประสาทเทียมที่มีความสมจริงและทำให้โครงข่ายประสาทเทียมสามารถทำงานกับภาพจากอุปกรณ์ที่ไม่รู้จักได้ดีกว่า นอกจากนี้วิธีดังกล่าวยังสามารถนำไปใช้ในการปรับค่าสีเมื่อมีเราต้องการปรับสีของภาพจากอุปกรณ์หนึ่งสู่อีกอุปกรณ์หนึ่ง

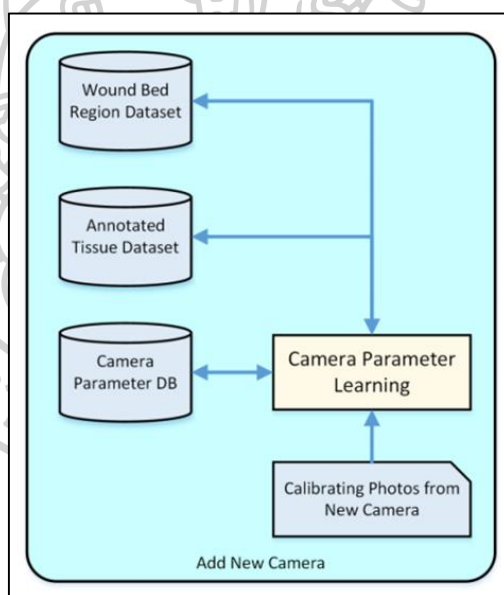
ในปัจจุบันเทคนิคการขยายข้อมูลที่เรานำเสนอนั้นมีความจำเป็นมากขึ้นเนื่องจากโปรแกรมประยุกต์ทางด้าน Computer Vision ในอุปกรณ์เคลื่อนที่เช่น โทรศัพท์มือถือ และแท็บเล็ตนั้นเป็นที่แพร่หลาย อย่างไรก็ตาม กล้องที่อยู่ในอุปกรณ์เหล่านี้มีความแตกต่างกันอย่างมหาศาลทั้งในแง่ของความคมชัดและในแง่ความแม่นยำของสี ปัจจัยเหล่านี้เองส่งผลให้ตัวแบบทางด้าน Computer Vision ที่ผ่านการฝึกมีความแม่นยำน้อยลงนอกจากว่าตัวแบบดังกล่าวจะถูกฝึกด้วยข้อมูลที่มีความหลากหลายและถูกใช้งานจริงในท้องตลาด กระนั้น การเก็บข้อมูลภาพถ่ายจากอุปกรณ์เหล่านี้จำเป็นต้องใช้งบประมาณจำนวนมาก ดังนั้นวิธีในการปรับสีภาพโดยใช้การจับคู่พารามิเตอร์สีระหว่างกล้องอย่างเป็นระบบ จึงเป็นสิ่งที่ดีกว่าวิธีการปรับสีแบบสุ่มเช่นในเทคนิค color jittering

การสร้างระบบการแพทย์ทางไกลที่สามารถจำแนกชนิดเนื้อเยื่อในบาดแผล (Tissue Classification) และวัดขนาดบาดแผล (Wound-Bed Segmentation) โดยใช้การเรียนรู้เชิงลึก (Deep Learning) ได้นั้นจำเป็นต้องใช้ข้อมูลรูปภาพบาดแผลปริมาณมาก สำหรับใช้ในการเรียนรู้ทั้งสองส่วน นอกจากนี้ยังต้องการข้อมูลจากกล้องหลายตัว ซึ่งกล้องบางตัวอาจจะไม่เคยถ่ายภาพบาดแผลจริง จึงจำเป็นที่จะต้องใช้วิธีการประมวลผลภาพเพื่อจำลองภาพบาดแผลที่ถ่ายมาจากกล้องเหล่านั้นให้ได้

สืบเนื่องจากความหลากหลายของอุปกรณ์มือถือที่ได้กล่าวไปข้างต้น ทำให้ไม่สามารถเก็บภาพบาดแผลจากกล้องได้อย่างครบถ้วน หากไม่ได้รับการแก้ไข การฝึกเครื่องจะดำเนินไปบนภาพที่ได้มาจากสถานพยาบาลที่ร่วมทำงานวิจัยเท่านั้น ทำให้มีความเสี่ยงสูงที่เครื่องจะทำงานได้ไม่ดีนักในภาพที่ได้มาจากกล้องหรือสภาพแวดล้อมอื่น

เรามีความคาดหวังที่จะทำให้ระบบนี้ได้รับการยอมรับจากผู้ใช้ในวงกว้าง โดยเฉพาะผู้ที่อยู่ในพื้นที่ห่างไกล ทำให้เราจำเป็นต้องจำลองภาพถ่ายขึ้นมา โดยอาศัยการประมาณค่าสีในภาพที่ได้จากกล้องตัวอื่น ซึ่งทำได้ผ่านการเทียบสีจากกล้องอ้างอิงและกล้องที่ต้องการให้เครื่องเรียนรู้พารามิเตอร์การเชื่อมโยงสี (color-mapping parameters) ในสภาพแสงที่กำหนด

ซึ่งวิธีการที่จะใช้คือการทำการปรับสีผ่านการเรียนรู้พารามิเตอร์ของกล้องต่าง ๆ เช่น ถ้าเรามีภาพบาดแผลจากกล้อง A ซึ่งให้สีแบบหนึ่ง เราจะเรียนรู้ว่าถ้าถ่ายภาพในลักษณะเดียวกันด้วยกล้อง B ภาพที่ได้จะเป็นอย่างไร จากนั้นเราจะนำภาพที่จำลองขึ้นจากการเรียนรู้การปรับสีนี้ ไปใช้ในการเรียนรู้โมดูล Tissue Classification และ Wound-Bed Segmentation หรือกล่าวอีกนัยหนึ่งก็คือเป็นการเรียนรู้พารามิเตอร์ของกล้องและสภาพทางแสงเพื่อสร้างภาพจำลอง รูปที่ 3 แสดงการทำงานในส่วนของการเสริมภาพจำลองลงในฐานข้อมูลผ่านการเรียนรู้พารามิเตอร์ของกล้อง



รูปที่ 3 การเรียนรู้พารามิเตอร์ของกล้องกับการเสริมข้อมูลในฐานข้อมูลที่เกี่ยวข้อง

งานการสร้างภาพจำลองนี้ จะทำให้การเรียนรู้โมดูลอีกสองตัวไม่ overfit ไปกับภาพจากกล้องหลักที่ใช้ในงานวิจัย กล่าวคือ ปัญหาที่ตัวแบบโมดูลทำการเทียบสีได้แม่นยำมากกับข้อมูลรูปภาพที่ใช้ในการฝึก แต่ทำงานได้ไม่แม่นยำในข้อมูลจริงซึ่งเป็นข้อมูลที่ตัวแบบไม่เคยเรียนรู้มาก่อน ส่งผลให้ระบบมีความพร้อมที่จะจัดการกับภาพจากกล้องที่อาจจะยังไม่มีจำหน่ายในปัจจุบันนี้ ซึ่งภาพ

ที่จำลองขึ้นมาเพิ่มเติมในภาพหลังเมื่อได้ข้อมูลจากกล้องใหม่ จะถูกนำไปเสริมกับภาพในฐานข้อมูลเดิมเพื่อใช้ในการเรียนรู้เพิ่มเติม เพื่อให้ผลลัพธ์ที่ได้จากโมเดลอีกสองตัวมีความแม่นยำมากยิ่งขึ้น

1.2 วัตถุประสงค์ของงานวิจัย

สืบเนื่องจากความหลากหลายของอุปกรณ์มือถือ ทำให้ไม่สามารถเก็บภาพบาดแผลจากกล้องได้อย่างครบถ้วน หากไม่ได้รับการแก้ไข การฝึกตัวแบบการเรียนรู้เชิงลึกจะดำเนินไปบนภาพที่ได้มาจากสถานพยาบาลที่ร่วมทำงานวิจัยเท่านั้น ทำให้มีความเสี่ยงสูงที่ตัวแบบจะทำงานได้ไม่ดีนักในภาพที่ได้มาจากกล้องหรือสภาพแวดล้อมอื่นนอกเหนือไปจากที่ได้ใช้ในระหว่างการฝึกสอน

อย่างไรก็ตาม เรามีความคาดหวังที่จะทำให้ระบบนี้ได้รับการยอมรับจากผู้ใช้ในวงกว้าง โดยเฉพาะผู้ที่อยู่ในพื้นที่ห่างไกล ทำให้เราจำเป็นต้องจำลองภาพถ่ายขึ้นมา โดยอาศัยการประมาณค่าสีในภาพที่ได้จากกล้องตัวอื่น ซึ่งทำได้ผ่านการเทียบสีจากกล้องอ้างอิงและกล้องที่ต้องการให้เครื่องเรียนรู้พารามิเตอร์การเชื่อมโยงสี (color-mapping parameters) ในสภาพแสงที่กำหนด

วิทยานิพนธ์นี้ยังมีความสำคัญกับการเตรียมเครื่องให้รองรับกล้องในอุปกรณ์มือถือที่ผลิตออกมาภายหลังจากการทำระบบด้วย เนื่องจากเราสามารถประมาณค่าสีที่ได้จากกล้องใหม่ในสภาพแวดล้อมทางแสงแบบต่าง ๆ แล้วนำไปแปลงภาพบาดแผลในฐานข้อมูลซึ่งได้มาจากกล้องอ้างอิงให้มีสีคล้ายกับภาพที่ได้จากกล้องใหม่

จากความต้องการนี้ เราสามารถสรุปออกมาเป็นวัตถุประสงค์ของวิทยานิพนธ์ได้ดังนี้

1. เพื่อศึกษาวิธีประมาณพารามิเตอร์ในการเชื่อมโยงค่าสีจากกล้องอ้างอิงไปกล้องเป้าหมาย โดยใช้การถดถอย (regression) ในตัวแบบการเรียนรู้ชนิดลึก (deep learning model) และอุปกรณ์เทียบสีกล้อง
2. เพื่อขยายข้อมูลภาพสีโดยใช้ภาพบาดแผลจากกล้องอ้างอิงในฐานข้อมูลผ่านพารามิเตอร์ที่ประมาณได้
3. เพื่อฝึกระบบการแยกพื้นที่และรู้จำชนิดเนื้อเยื่อแผลให้มีความแม่นยำสูงแม้จะทำงานในภาพถ่ายจากกล้องที่ไม่ได้อยู่ในฐานข้อมูลที่ใช้ในการเรียนรู้

4. เพื่อเตรียมระบบให้รองรับกล้องในอุปกรณ์มือถือที่กว้างขวางขึ้น ซึ่งจะทำให้ระบบสามารถตอบสนองต่อการใช้งานที่หลากหลายของกลุ่มผู้ใช้ขนาดใหญ่ได้ตามวัตถุประสงค์ของโครงการหลัก
5. เพื่อประเมินผลของการขยายข้อมูลภาพต่อการเพิ่มความแม่นยำของระบบในภาพที่ได้จากกล้องที่เครื่องไม่เคยได้รับการฝึกโดยตรง

1.3 ประโยชน์ที่คาดว่าจะได้รับ

1. สามารถขยายข้อมูลภาพโดยใช้ตัวแบบการเรียนรู้เชิงลึกที่ผ่านการฝึกฝน
2. สามารถนำตัวแบบที่ผ่านการฝึกฝนในการเทียบค่าสีระหว่างกล้องสองกล้อง
3. ลดความต้องการในการถ่ายภาพสำหรับฝึกสอนตัวแบบการเรียนรู้เชิงลึกจากกล้องหลายตัว
4. นำตัวแบบที่ผ่านการฝึกฝนไปใช้ในระบบการแพทย์ทางไกลสำหรับจำแนกชนิดแผลและจำแนกชนิดเนื้อเยื่อในแผล
5. สามารถฝึกสอนตัวแบบการเรียนรู้เชิงลึกให้ทำงานได้ดีกับอุปกรณ์กล้องใหม่ๆ

1.4 โครงร่างหัวข้อวิทยานิพนธ์


ลำดับหัวข้องานวิจัยจะเป็นไปดังนี้คือ บทที่ 2 จะกล่าวถึงงานวิจัยที่เกี่ยวข้อง บทที่ 3 กล่าวถึงทฤษฎีที่เกี่ยวข้อง บทที่ 4 วิธีการดำเนินงานวิจัย บทที่ 5 ผลการดำเนินงานวิจัย และบทที่ 6 สรุปผลการดำเนินงานวิจัยและข้อเสนอแนะ

บทที่ 2

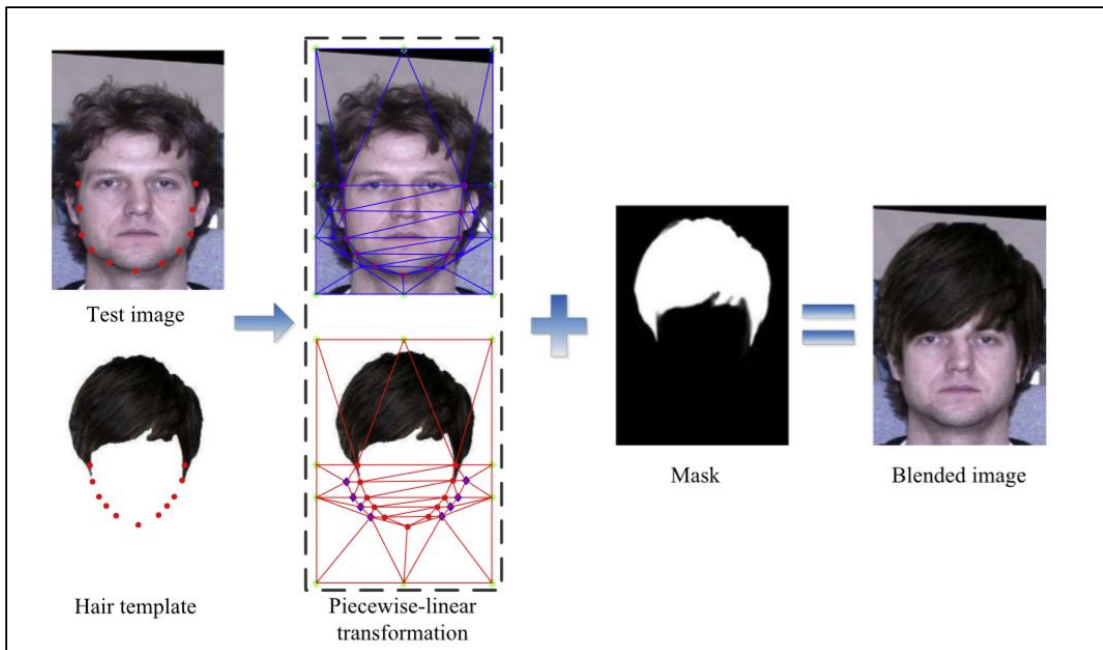
งานวิจัยที่เกี่ยวข้อง

2.1 Data augmentation for face recognition


การขยายข้อมูลรูปภาพที่ใช้กันอยู่ในปัจจุบันนั้นมักจะเกี่ยวข้องกับเทคนิคที่ซับซ้อนที่คิดค้นขึ้นมาโดยเฉพาะสำหรับงานแต่ละงาน ยกตัวอย่างเช่น งานวิจัยของ Lv (Jiang-Jing Lv, 2017) และคณะได้เสนอวิธีการสังเคราะห์รูปภาพ (เรียกอีกนัยหนึ่งคือการขยายข้อมูล) สำหรับขยายข้อมูลในงานเกี่ยวกับการรู้จำใบหน้า โดยใช้เทคนิค 5 แบบในการสังเคราะห์รูปภาพ ได้แก่ การก่อกวนจุดสำคัญของใบหน้า การเปลี่ยนทรงผม การใส่แว่น เปลี่ยนท่าทางในการถ่าย และเปลี่ยนสภาพแสงที่ถ่าย นอกจากนี้ยังใช้เทคนิคในการใส่การรบกวนไปในจุดสำคัญของใบหน้า เพื่อให้ได้ลักษณะเด่นของใบหน้าในแต่ละบุคคลเปลี่ยนไป จึงส่งผลให้เสมือนเกิดเป็นภาพใหม่




รูปที่ 4 ขั้นตอนการสังเคราะห์รูปภาพใหม่ด้วยการก่อกวนจุดสำคัญในใบหน้า



รูปที่ 5 ขั้นตอนการสังเคราะห์รูปภาพใหม่ด้วยการเปลี่ยนทรงผม



รูปที่ 6 ขั้นตอนการสังเคราะห์รูปภาพใหม่ด้วยการสวมแว่น



รูปที่ 7 ขั้นตอนการสังเคราะห์รูปภาพใหม่ด้วยการจำลองการเปลี่ยนท่าทางการถ่าย

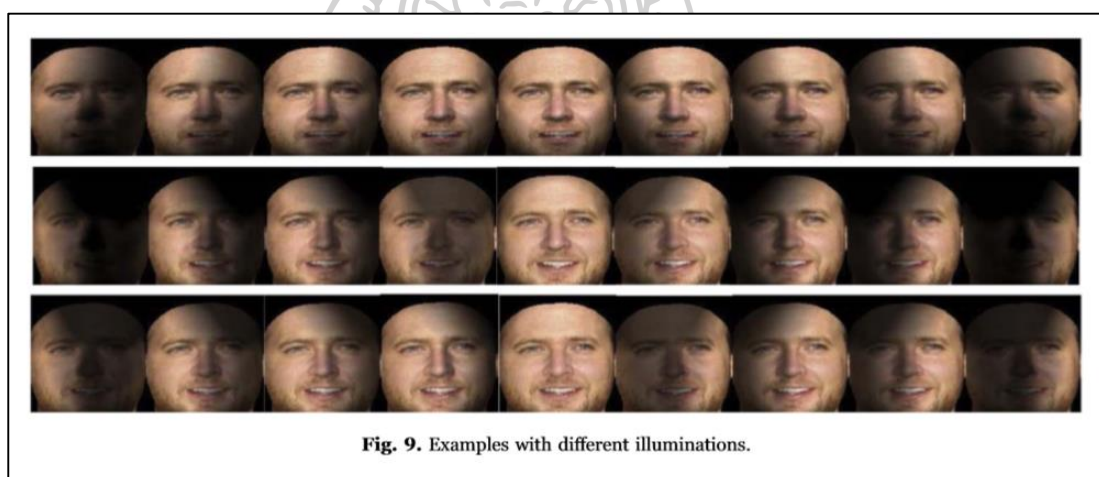


Fig. 9. Examples with different illuminations.

รูปที่ 8 ขั้นตอนการสังเคราะห์รูปภาพใหม่ด้วยการเปลี่ยนสภาพแสง

ผู้วิจัยได้วัดประสิทธิภาพของตัวแบบการเรียนรู้เชิงลึกที่ผ่านการฝึกฝนด้วยภาพจากฐานข้อมูล LFW, YTF UJ-B-A รวมกับภาพที่ผ่านการขยายข้อมูลด้วยวิธีการทั้งห้าวิธีดังกล่าว แล้วนำมาเปรียบเทียบกับตัวแบบการเรียนรู้เชิงลึกที่ฝึกด้วยภาพต้นฉบับจากฐานข้อมูลเพียงอย่างเดียว ผลที่ได้แสดงให้เห็นว่าการขยายข้อมูลช่วยเพิ่มความแม่นยำให้กับตัวแบบการเรียนรู้เชิงลึกอย่างมาก

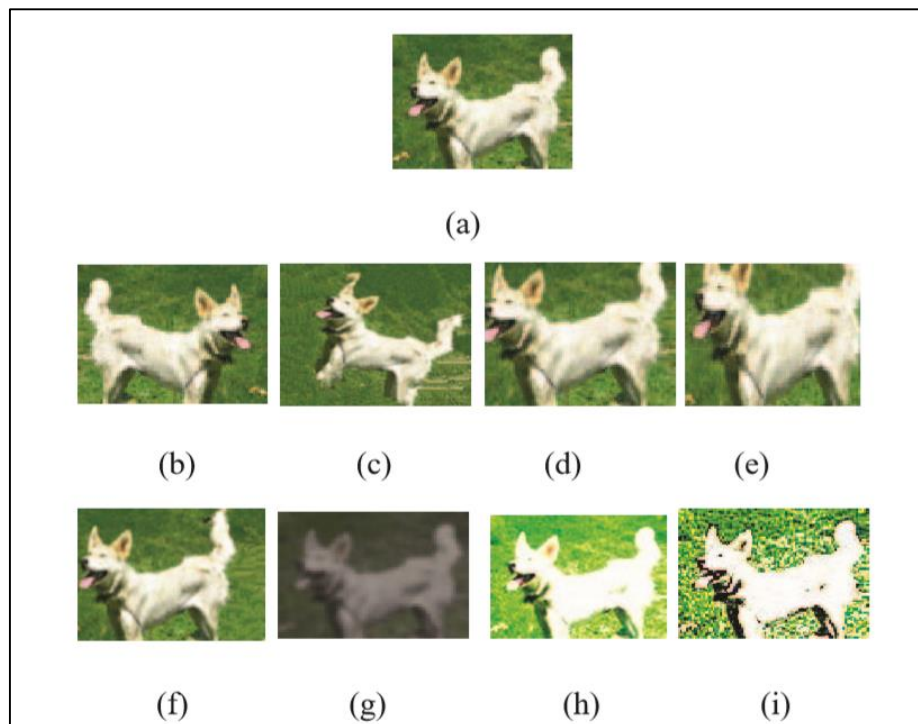
Verification rates (%) with various data augmentation methods on YTF database.	
Method	Accuracy \pm SE
Baseline: No data augmentation	92.00 \pm 1.10
A: Flipping	92.32 \pm 1.09
B: Contrast+Blur+Noise+Color casting	93.28 \pm 0.98
C: Landmark perturbation	93.22 \pm 1.14
D: Synthesis with different hairstyles	92.60 \pm 1.19
E: Synthesis with different glasses	92.88 \pm 0.73
F: Synthesis with different poses	92.22 \pm 1.37
G: Synthesis with different illuminations	92.34 \pm 1.73
Fusion: Combine all data augmentations	94.08 \pm 1.23
DeepFace [4]	91.4 \pm -
DR+Joint Bayse [27]	92.24 \pm 1.28
FaceNet [11]	95.12 \pm 0.39

รูปที่ 9 ความแม่นยำของตัวแบบการรู้จำใบหน้าที่ถูกฝึกโดยข้อมูลในแบบต่างๆ ทั้งข้อมูลต้นฉบับและที่สังเคราะห์ขึ้น

2.2 Research on data augmentation for image classification based on convolution neural networks (Jia Shijie, 2017)

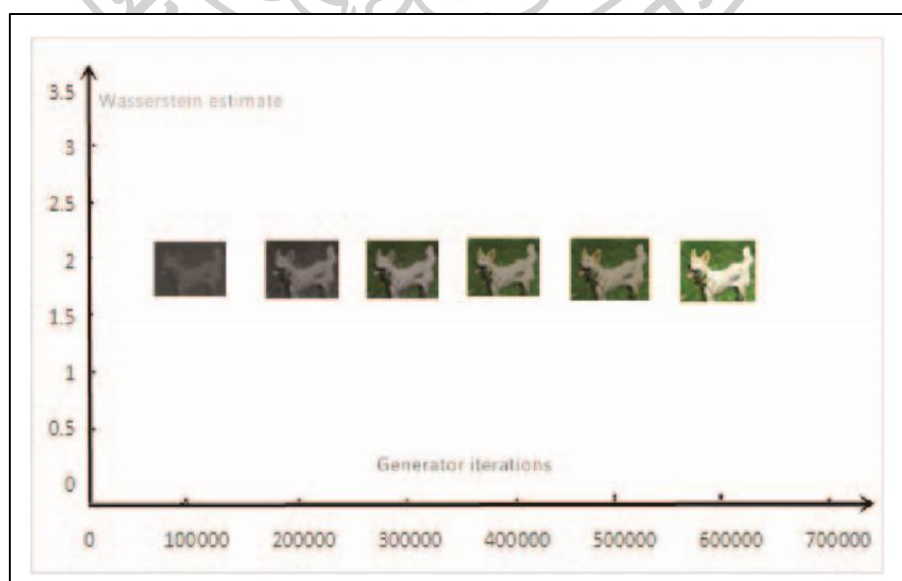
งานวิจัยนี้ได้แบ่งประเภทของการขยายข้อมูลรูปภาพออกเป็นสองประเภท คือ

(1) Unsupervised ซึ่งเป็นการขยายข้อมูลภาพที่วิธีการขยายข้อมูลไม่ขึ้นกับประเภทของรูปภาพ ได้แก่ การกลับภาพ การหมุนภาพ การครอบตัดภาพ การขยับภาพ การปรับสีภาพและการใส่สัญญาณรบกวนลงในภาพ



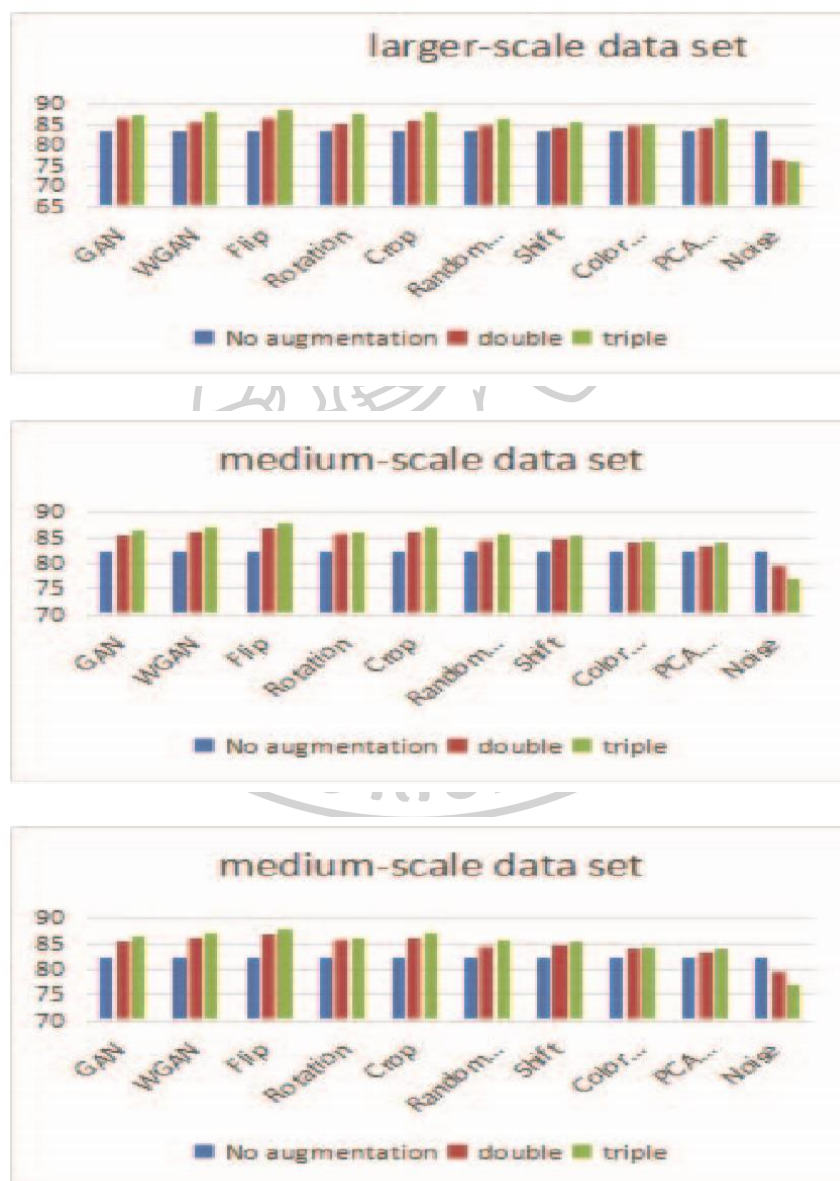
รูปที่ 10 การขยายข้อมูลแบบ Unsupervised (a) ภาพต้นฉบับ (b) การกลับภาพ (c) การหมุนภาพ (d) การครอบตัด (e) การครอบตัดแบบซูม (f) การเลื่อนวัตถุในภาพ (g) การใส่สัญญาณรบกวนลง
ในภาพ (h) color jittering (i) PCA-jittering

(2) Supervised เป็นการขยายข้อมูลภาพที่วิธีการขยายข้อมูลขึ้นอยู่กับประเภทของรูปภาพ



รูปที่ 11 การขยายข้อมูลภาพแบบ Supervised


งานวิจัยนี้ได้้นำเทคนิคการขยายข้อมูลภาพทั้งสองวิธีดังกล่าวไปใช้ขยายข้อมูลภาพบางส่วนจากฐานข้อมูล CIFAR10 (Alex Krizhevsky, 2018) และ ImageNet โดยทำการสุ่มภาพจากแต่ละฐานข้อมูลจำนวน 6000 รวมเป็น 1200 ภาพ แบ่งเป็น 10 ประเภท เช่น ภาพเครื่องบิน รถ นก แมว เป็นต้น เมื่อนำภาพที่ได้จากการขยายข้อมูลรวมเข้ากับข้อมูลเดิมที่มีในฐานข้อมูลไปใช้ในการฝึกสอนตัวแบบการเรียนรู้เชิงลึก พบว่าได้ตัวแบบที่มีความแม่นยำ




รูปที่ 12 ความแม่นยำของตัวแบบการเรียนรู้จำวัตถุที่ฝึกด้วยข้อมูลที่ผ่านการขยายด้วยเทคนิคต่างๆ
ในฐานข้อมูลขนาด เล็ก กลางและใหญ่

2.3 Ensuring color consistency across multiple cameras


(Adrian Ilie, 2005) Ilie และคณะได้เสนอวิธีการปรับค่าสีในภาพที่ถ่ายโดยกล้องที่แตกต่างกัน ชั้นแรกจะทำการปรับที่ระดับฮาร์ดแวร์เพื่อให้ได้ความสมดุลของ dynamic range จากนั้นนำภาพมาผ่านการปรับสีด้วยหนึ่งในสามวิธีการปรับสี ได้แก่ least-square, 3x3 RGB to RGB linear transform และ general polynomial transform ภาพที่ได้หลังจากการปรับสีมีความคล้ายคลึงกับภาพเป้าหมาย ในแง่ของความสว่างและโทนสี



รูปที่ 13 ความแตกต่างของค่าสี RGB จากภาพของกล้องแต่ละตัวก่อนการปรับเทียบในระดับฮาร์ดแวร์



รูปที่ 14 ความแตกต่างของค่าสี RGB จากภาพของกล้องแต่ละตัวหลังการปรับเทียบในระดับฮาร์ดแวร์



รูปที่ 15 ความแตกต่างของค่าสี RGB หลังการปรับเทียบด้วยซอฟต์แวร์ทั้งสามวิธี ได้แก่ least-square, 3x3 RGB to RGB linear transform และ general polynomial transform ตามลำดับ




บทที่ 3 ทฤษฎีที่เกี่ยวข้อง

3.1 ระบบสีอาร์จีบี (RGB Color Model)

RGB เป็นระบบสีแบบ Additive ที่เกิดจากการผสมสีแดง เขียวและน้ำเงินรวมกันในปริมาณที่แตกต่างกันเพื่อสร้างเป็นช่วงของสีที่มีความกว้างมาก ชื่อของระบบสีนี้มาจากสีหลักสามสีที่ใช้เป็นส่วนผสมให้เกิดสีต่างๆ กัน จุดประสงค์หลักของระบบสี RGB นั้นคือเพื่อการรับรู้ การนำเสนอและการแสดงผลรูปภาพในระบบอิเล็กทรอนิกส์ เช่น โทรทัศน์ คอมพิวเตอร์และการถ่ายภาพ

RGB เป็นระบบสีที่ขึ้นอยู่กับอุปกรณ์ถ่ายภาพและแสดงผล อุปกรณ์ที่แตกต่างกันจะตรวจจับและให้ค่าสีในระบบ RGB ที่ต่างกันไปด้วย เนื่องจากส่วนประกอบของสีและการตอบสนองของอุปกรณ์ต่อระดับของค่า R, G และ B แตกต่างกันไปตามผู้ผลิตแต่ละรายและแตกต่างกันเมื่อเวลาผ่านไปแม้จะเป็นอุปกรณ์เดิม ดังนั้นค่า RGB จึงไม่สามารถให้สีที่เหมือนกันในอุปกรณ์ต่างๆ ได้โดยปราศจากการจัดการเทียบสีระหว่างอุปกรณ์




รูปที่ 16 ตัวอย่างการผสมสีในระบบสี RGB การรวมกันของทั้งสามสี แดง เขียวและน้ำเงินในความเข้มเท่ากันทำให้เกิดสีขาวในบริเวณกลางภาพ

(ที่มา <http://newmediawiki.pbworks.com/w/page/126463805/mandalaDigitalColor>)

3.2 การขยายข้อมูล (Data Augmentation)


การขยายข้อมูลเป็นการเพิ่มจำนวนข้อมูลให้มีจำนวนมากขึ้นเพื่อให้เพียงพอต่อการนำไปใช้งาน ในการทำงานกับรูปภาพการขยายข้อมูลหมายถึงการเพิ่มจำนวนของรูปภาพในฐานข้อมูล ในการทำงานกับข้อมูลในลักษณะปกติจะหมายถึงการเพิ่มแถวข้อมูล การขยายข้อมูลถูกนำเนื่องจากมนุษย์มีจำนวนข้อมูลที่จำกัด แต่ตามหลักการแล้วยังมีข้อมูลมากขึ้นโมเดลของ Machine Learning ก็จะมีประสิทธิภาพดีขึ้น อย่างไรก็ตามการประมวลผลข้อมูลในทุกแบบย่อมเกี่ยวข้องกับค่าใช้จ่าย ค่าใช้จ่ายนี้อาจจะเป็นในรูปแบบเงินตรา การลงแรงของมนุษย์ หรือพลังการประมวลผลของคอมพิวเตอร์ และแน่นอนว่าจะต้องเสียเวลาในการประมวลผล ดังนั้นเราจึงต้องการการขยายข้อมูลที่มีอยู่แล้วเพื่อเพิ่มจำนวนของข้อมูลที่จะป้อนให้โมเดล Machine Learning เพื่อให้โมเดลสามารถทำหน้าที่ได้อย่างมีประสิทธิภาพ



รูปที่ 17 ความสัมพันธ์ระหว่างปริมาณของข้อมูลในการฝึกสอนและความแม่นยำของตัวแบบการเรียนรู้เชิงลึก (ที่มา <https://hackernoon.com/%EF%B8%8F-big-challenge-in-deep-learning-training-data-31a88b97b282>)

การขยายข้อมูลสามารถทำได้หลายวิธี ในการทำงานกับรูปภาพจะใช้ การหมุนรูปภาพเดิม เปลี่ยนสภาพแสงในภาพ กรอบตัดภาพให้ลักษณะต่างออกไป ดังนั้นภาพหนึ่งภาพสามารถสร้างเป็นข้อมูลภาพที่แตกต่างกันหลายๆ ภาพได้ตามเทคนิคที่ใช้ในการขยายข้อมูล ด้วยวิธีนี้เองเราสามารถลด

ปัญหาการ Overfit ของโมเดล Machine Learning กล่าวคือปัญหาที่ตัวแบบทำงานได้แม่นยำมากกับข้อมูลรูปภาพที่ใช้ในการฝึก แต่ทำงานได้ไม่แม่นยำในข้อมูลจริงซึ่งเป็นข้อมูลที่ตัวแบบไม่เคยเรียนรู้มาก่อน ในทางกลับกันถ้าใช้เทคนิคที่มีการ over sampling เช่น SMOTE จะทำให้มีโอกาสที่จะเกิด Overfit ซึ่งเป็นสิ่งที่ควรหลีกเลี่ยง



รูปที่ 18 ตัวอย่างการขยายข้อมูลรูปภาพด้วยเทคนิคต่างๆ

3.3 การเรียนรู้เชิงลึก (Deep Learning)

การเรียนรู้เชิงลึก (อังกฤษ: Deep learning) เป็นสาขาของการเรียนรู้ของเครื่อง พื้นฐานของการเรียนรู้เชิงลึกคือ อัลกอริทึมที่พยายามจะสร้างแบบจำลองเพื่อแทนความหมายของข้อมูลในระดับสูงโดยการสร้างสถาปัตยกรรมข้อมูลขึ้นมาที่ประกอบไปด้วยโครงสร้างย่อยๆ หลายอัน และแต่ละอันนั้นได้มาจากการแปลงที่ไม่เป็นเชิงเส้น

การเรียนรู้เชิงลึก อาจมองได้ว่าเป็นวิธีการหนึ่งของการเรียนรู้ของเครื่องที่พยายามเรียนรู้วิธีการแทนข้อมูลอย่างมีประสิทธิภาพ ตัวอย่างเช่น รูปภาพภาพหนึ่ง สามารถแทนได้เป็นเวกเตอร์ของความ

สว่างต่อจุดพิกเซล หรือมองในระดับสูงขึ้นไปเป็นเซตของขอบของวัตถุต่างๆ หรือมองว่าเป็นพื้นที่ของรูปร่างใดๆก็ได้ การแทนความหมายดังกล่าวจะทำให้การเรียนรู้ที่จะทำงานต่างๆทำได้ง่ายขึ้น ไม่ว่าจะเป็นการรู้จำใบหน้าหรือการรู้จำการแสดงออกทางสีหน้า การเรียนรู้เชิงลึกถือว่าเป็นวิธีการที่มีศักยภาพสูงในการจัดการกับพีเจอรส์สำหรับการเรียนรู้แบบไม่มีผู้สอนหรือการเรียนรู้แบบกึ่งมีผู้สอน

นักวิจัยในสาขานี้พยายามจะหาวิธีการที่ดีขึ้นในการแทนข้อมูลแล้วสร้างแบบจำลองเพื่อเรียนรู้จากตัวแทนของข้อมูลเหล่านี้ในระดับใหญ่ บางวิธีการก็ได้แรงบันดาลใจมาจากสาขาประสาทวิทยาชั้นสูง โดยเฉพาะเรื่องกระบวนการตีความหมายในกระบวนการประมวลผลข้อมูลในสมอง ตัวอย่างของกระบวนการที่การเรียนรู้เชิงลึกนำไปใช้ได้แก่ การเข้ารหัสประสาท อันเป็นกระบวนการหาความสัมพันธ์ระหว่างตัวกระตุ้นกับการตอบสนองของเซลล์ประสาทในสมอง

นักวิจัยด้านการเรียนรู้ของเครื่องได้เสนอสถาปัตยกรรมการเรียนรู้หลายแบบบนหลักการของการเรียนรู้เชิงลึกนี้ ได้แก่ โครงข่ายประสาทเทียมแบบลึก (Deep Artificial Neural Networks) โครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Networks) โครงข่ายความเชื่อแบบลึก (Deep Belief Networks) และโครงข่ายประสาทเทียมแบบวนซ้ำ (Recurrent Neural Network) ซึ่งมีการนำมาใช้งานอย่างแพร่หลายในทางคอมพิวเตอร์วิทัศน์ การรู้จำเสียงพูด การประมวลผลภาษาธรรมชาติ การรู้จำเสียง และชีวสารสนเทศศาสตร์

การเรียนรู้เชิงลึก เป็นสาขาของการเรียนรู้ของเครื่องที่

- ประกอบไปด้วยชั้นของหน่วยประมวลผลแบบไม่เป็นเชิงเส้นหลายๆ ชั้น ข้อมูลขาออกของแต่ละชั้นก่อนหน้าจะเป็นข้อมูลขาเข้าของชั้นต่อไป
- มาพื้นฐานมาจากการเรียนรู้พีเจอรส์หลายๆ ชั้นหรือการแทนข้อมูลแบบหลายๆ ชั้น (แบบไม่มีผู้สอน) กล่าวคือ พีเจอรส์ในชั้นสูงๆ จะได้มาจากพีเจอรส์ในชั้นที่ต่ำกว่า เพื่อสร้างมาเป็นการแทนข้อมูลแบบหลายๆ ชั้น
- เป็นส่วนหนึ่งของสาขาการเรียนรู้ของเครื่องในการเรียนรู้การแทนข้อมูล


กล่าวคือ การเรียนรู้เชิงลึกประกอบไปด้วย (1) หน่วยประมวลผลแบบไม่เป็นเชิงเส้นหลายๆ ชั้น (2) แต่ละชั้น จะเรียนรู้การแทนพีเจอรส์ อาจจะเป็นแบบมีผู้สอนหรือไม่มีผู้สอนก็ได้ ทั้งนี้ โครงสร้างในแต่ละชั้นของการเรียนรู้เชิงลึกจะขึ้นอยู่กับปัญหาที่ต้องการจะแก้ไข อาจจะเป็น hidden layer ของโครงข่ายประสาทเทียม หรือหน่วยประมวลผลตรรกะที่ซับซ้อนก็ได้ หรืออาจจะเป็นโนดใน deep

generative model อย่างเช่น โครงข่ายความเชื่อแบบลึก (Deep Belief Networks) หรือเครื่องจักรโบลทซ์มันน์เชิงลึก (Deep Boltzmann Machines) ก็ได้

หลักการโดยทั่วไปของการเรียนรู้เชิงลึกคือการมีหน่วยประมวลผลหลายๆชั้น ข้อมูลขาเข้าในแต่ละชั้นได้มาจากปฏิสัมพันธ์กับชั้นอื่นๆ ทั้งนี้ การเรียนรู้เชิงลึกพยายามหาความสัมพันธ์ที่ลึกลับมากขึ้น นั่นคือ เมื่อมีจำนวนของชั้นและหน่วยประมวลผลที่อยู่ในชั้นมากขึ้น ข้อมูลในชั้นสูงๆก็จะยิ่งลึกลับซับซ้อน (abstract) มากขึ้น

สถาปัตยกรรมโครงสร้างของการเรียนรู้เชิงลึกมักจะสร้างแบบเป็นชั้นๆ (layer-by-layer) ไปด้วยวิธี greedy method ซึ่งการหาสิ่งที่ลึกลับซับซ้อนมากขึ้นไปเรื่อยๆในแต่ละชั้นนี้เองที่ทำให้การเรียนรู้เชิงลึกมีประสิทธิภาพมากกว่าวิธีการอื่นๆ ตัวอย่างเช่น ข้อมูลในชั้นต้นๆอาจจะเรียนรู้ว่าภาพที่เข้ามาประกอบด้วยเส้นต่างๆ ชั้นที่สูงไปนำเส้นต่างๆมาประกอบกันเป็นรูปสี่เหลี่ยม และชั้นต่อมาคือการหาความสัมพันธ์ของเส้นสี่เหลี่ยมจนกระทั่งคอมพิวเตอร์รู้ว่าภาพที่เข้ามาเป็นภาพของธงชาติ เป็นต้น

ในการเรียนรู้แบบมีผู้สอนนั้น การเรียนรู้เชิงลึกจะช่วยลดภาระในการหาฟีเจอร์ที่เกี่ยวข้อง เพราะวิธีการนี้จะแปลงข้อมูลไปสู่รูปแบบอื่นในระดับที่สูงขึ้นโดยอัตโนมัติ และให้ความสำคัญกับข้อมูลที่ซ้ำซ้อนลดลงไปด้วย นอกจากนี้ ยังสามารถนำไปปรับใช้กับการเรียนรู้แบบไม่มีผู้สอนได้ด้วย



รูปที่ 19 โครงข่ายประสาทเทียมแบบปรกติและโครงข่ายประสาทเทียมในตัวแบบการเรียนรู้แบบลึก (ที่มา [https://medium.com/@krossovochkin/neural-networks-and-deep-learning-](https://medium.com/@krossovochkin/neural-networks-and-deep-learning-38aaca43ae0f)

38aaca43ae0f)

3.4 การวิเคราะห์การถดถอย (Regression Analysis)

การวิเคราะห์การถดถอย (Regression Analysis) และการวิเคราะห์สหสัมพันธ์ (Correlation Analysis) เป็นการศึกษาเกี่ยวกับความสัมพันธ์ของตัวแปร วัตถุประสงค์หลักของการวิเคราะห์การถดถอยคือ เราต้องการประมาณค่าของตัวแปรตัวหนึ่ง ซึ่งเรียกว่า ตัวแปรตาม (Dependent Variable) นิยมเขียนแทนด้วย Y โดยอาศัยความรู้จากตัวแปรอื่น ซึ่งเรียกว่า ตัวแปรอิสระ (Independent Variable) นิยมเขียนแทนด้วย X หรือกล่าวอีกอย่างหนึ่งว่า เราใช้ความรู้ หรือสารสนเทศจาก X เป็นเกณฑ์ในการประมาณ Y ถ้าใช้ตัวแปร X เพียงตัวแปรเดียวในการประมาณ Y และความสัมพันธ์ของ Y และ X เป็นเชิงเส้นตรง เราเรียกว่า การถดถอยเชิงเส้นอย่างง่าย (Simple Linear Regression)

จุดประสงค์ของการใช้ Regression Analysis ก็เพื่อต้องการหาสมการความสัมพันธ์ (Transfer function) ของตัวแปรฝั่งที่เรา รู้ค่า (Predictor) กับฝั่งที่เราไม่ รู้ค่า (Response) เพื่อที่จะนำไปสู่การคาดการณ์หรือประมาณค่า ของตัวแปรที่เราไม่ รู้ค่าได้ในที่สุด และที่สำคัญการจะนำสมการความสัมพันธ์ไปใช้ได้ จะต้องมีการตรวจสอบเสียก่อนว่าสมการที่ได้มานั้นมีความถูกต้อง พอที่จะใช้เป็นสมการในการคาดการณ์ตัวแปรที่ไม่รู้ค่าได้จริงหรือไม่

การวิเคราะห์การถดถอยมีหลายชนิด ขึ้นกับลักษณะของตัวแปรตาม รูปแบบความสัมพันธ์ และการกำหนดตัวแปรอิสระ (ตัวแปรต้น) ซึ่งโดยทั่วไปแบ่งการวิเคราะห์การถดถอยได้เป็น 2 ประเภทคือ

- การวิเคราะห์การถดถอยเชิงเส้น (Linear regression analysis) เป็นการวิเคราะห์การถดถอยที่ตัวแปรอิสระส่วนใหญ่เป็นตัวแปรเชิงปริมาณ ส่วนตัวแปรตามเป็นจะต้องเป็นตัวแปรเชิงปริมาณเท่านั้น รูปแบบของความสัมพันธ์ระหว่างตัวแปรอิสระและตัวแปรตาม สามารถแทนได้ด้วยสมการทางคณิตศาสตร์ที่เป็นเชิงเส้น (Linear model)

- การวิเคราะห์การถดถอยแบบไม่เป็นเชิงเส้น (Non - linear regression) เป็นการวิเคราะห์การถดถอย ที่รูปแบบของความสัมพันธ์ระหว่างตัวแปรอิสระและตัวแปรตาม สามารถแทนได้ด้วยสมการทางคณิตศาสตร์ที่ไม่เป็นเชิงเส้น (non - Linear model)

บทที่ 4 วิธีการดำเนินงานวิจัย

4.1 การเลือกอุปกรณ์ถ่ายภาพ

จากความต้องการที่จะนำวิธีที่เสนอในงานวิจัยนี้ไปใช้งานกับระบบการแพทย์ทางไกล เพื่อให้สามารถใช้งานได้ในวงกว้าง การเลือกอุปกรณ์กล้องถ่ายภาพจึงเน้นไปที่อุปกรณ์โทรศัพท์มือถือและแท็บเล็ตเนื่องจากเป็นอุปกรณ์ที่ได้รับความนิยมและมีใช้งานกันอย่างแพร่หลายในปัจจุบัน เกณฑ์ในการเลือกอุปกรณ์แต่ละแบบนี้พิจารณาจากระดับราคาและความสะดวกในการใช้งานเป็นหลักเพื่อให้ข้อมูลภาพที่ได้เป็นตัวแทนที่ดีของอุปกรณ์อันหลากหลายที่มีขายในท้องตลาด

ตารางที่ 1 อุปกรณ์ถ่ายภาพและเหตุผลที่เลือกใช้ในการทดลอง

Name	Price(฿)	Camera	F	AF	เหตุผล
Moto C 4G	3,290	5 MP	N/A	Yes	ตัวแทนของอุปกรณ์ถ่ายภาพในกลุ่มราคาต่ำ ให้ภาพที่มีคุณภาพต่ำกว่ากลุ่มอื่น
iPad Mini 4	13,400	8 MP	2.4	Yes	ตัวแทนของอุปกรณ์ในกลุ่มราคาปานกลาง และตัวแทนของอุปกรณ์ประเภทแท็บเล็ต
Galaxy S8+	28,900	12 MP	1.7	Yes	ตัวแทนของอุปกรณ์ถ่ายภาพในกลุ่มราคาสูง ให้ภาพที่มีคุณภาพสูงสุดเมื่อเทียบกับกลุ่มอื่น

หมายเหตุ อุปกรณ์ถ่ายภาพทั้งหมดใช้เซนเซอร์รูปภาพชนิด Complementary Metal Oxide Semiconductor (CMOS)



รูปที่ 21 ราคาของอุปกรณ์ถ่ายภาพที่ใช้ในการทดลอง




รูปที่ 22 คุณสมบัติของกล้องในอุปกรณ์ถ่ายภาพที่ใช้ในการทดลอง

4.2 การเก็บข้อมูลสำหรับฝึกสอนตัวแบบการเรียนรู้เชิงลึก


เป็นที่ทราบกันดีว่าระบบสี R G B นั้นประกอบขึ้นจากค่าสีแดงสีเขียวและน้ำเงินซึ่งมีค่าระหว่าง 0 - 255 ทำให้มีค่าเฉลี่ยที่เป็นไปได้ทั้งหมดประมาณ 16 ล้านเฉลี่ย อย่างไรก็ตามตามนุษย์ไม่สามารถแยกความแตกต่างของเฉลี่ยได้ทั้งหมด งานวิจัยหลายงานได้พยายามหาคำตอบเกี่ยวกับความสามารถในการแยกเฉลี่ยของตามนุษย์ เช่นงานวิจัยของ Calkins, David J. ในปี 1993

กล่าวว่าตามมนุษย์สามารถแยกความต่างของสีได้ประมาณ 1 แสนสี และงานวิจัยของ Kleiner, Kurt ในปี 2004 พบว่ามนุษย์สามารถแยกความแตกต่างของสีได้ประมาณ 2 ล้านเฉดสีหรือคิดเป็น 1 ใน 8 ของสีที่ระบบสี R G B สร้างได้ ซึ่งในงานวิจัยนี้ได้ถือเอาค่าประมาณดังกล่าวในการสร้างภาพสำหรับเก็บข้อมูล

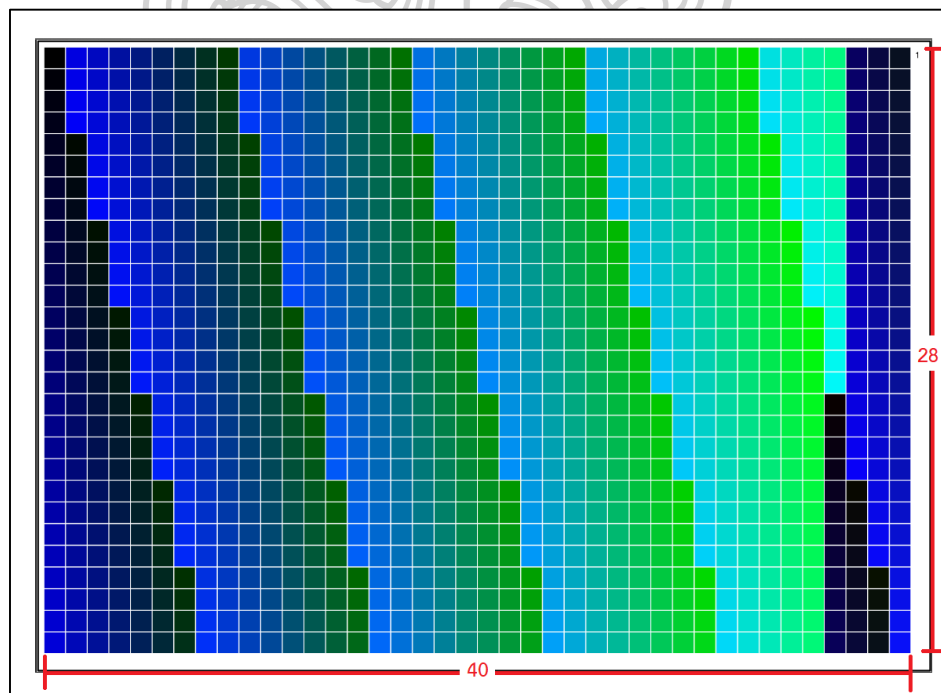
การสร้างภาพสำหรับเก็บข้อมูลนั้นเริ่มต้นด้วยการสร้างเฉดสี RGB ที่มีค่าแตกต่างกันสีละ 8 ทำให้ได้สีทั้งหมด $32 \times 32 \times 32 = 32,768$ สี จากนั้นจึงนำสีลงไปบรรจุในภาพภาพละ 1,120 สี ทำให้ได้ภาพสำหรับเก็บข้อมูลจำนวน 30 ภาพ นอกจากนี้เพื่อให้ได้ข้อมูลภาพเฉดเทาจึงได้สร้างเฉดสีเทาเพิ่มอีกจำนวน 256 เฉดสีและนำไปสร้างเป็นภาพที่ 31



รูปที่ 23 วิธีการสร้างข้อมูลสำหรับฝึกสอนตัวแบบแปลงค่าสี




รูปที่ 24 เฉดสีทั้งหมดที่ใช้เป็นข้อมูลฝึกสอนตัวแบบแปลงค่าสี จำนวน 32,768 สี




รูปที่ 25 ภาพหมายเลขหนึ่งสำหรับใช้เป็นข้อมูลฝึกสอนตัวแบบแปลงค่าสี ประกอบด้วยเฉดสีทั้งหมด 1,120 สี ภายในตารางขนาด 40 * 28

เมื่อได้ภาพแล้วจึงพิมพ์และถ่ายภาพที่พิมพ์ออกมาเหล่านั้นในสภาพแสงเดียวกันด้วยกล้อง จากอุปกรณ์ที่เลือกทั้งสามอุปกรณ์ เนื่องจากขนาดของภาพที่ถ่ายโดยกล้องของแต่ละอุปกรณ์แตกต่างกันและภาพที่ได้มีความลาดเอียงที่ไม่เท่ากัน เพื่อให้การเก็บข้อมูลเป็นไปได้โดยง่ายจึงทำการปรับขนาดของภาพที่ถ่ายโดยอุปกรณ์ที่เลือกให้เป็นขนาดเดียวกันที่ 1600×1200 พิกเซล แล้วใช้การทำ perspective transform และครอบตัดภาพ



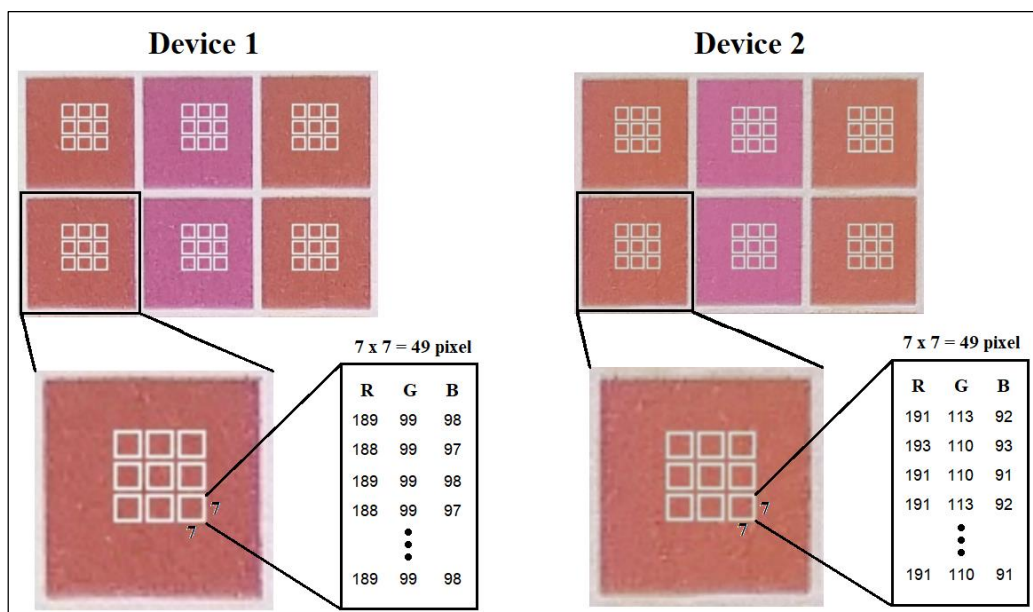
รูปที่ 26 การทำ Perspective Transform และการครอบตัดเพื่อแก้ไขความลาดเอียงของภาพ

การทำ perspective transform นั้นทำได้โดยการเก็บพิกัดจุดที่มุมทั้งสี่ด้านของภาพ แล้วจึงคำนวณความกว้างและความยาวของรูปใหม่ที่ได้หลังจาก transform แล้ว ผลของการ transform ทำให้ภาพที่ได้มีความตรงในแนวระนาบมากขึ้น อย่างไรก็ตามการทำ Transform นั้นใช้ว่าจะแก้ไขปัญหาได้ทั้งหมด เนื่องจากภาพที่ได้ยังมีปัญหาความเอียงในแนวตั้งอยู่ ทำให้การเก็บข้อมูลยังไม่แม่นยำเป็นที่น่าพอใจนัก ผู้วิจัยจึงแก้ปัญหาด้วยการแบ่งภาพต้นฉบับแต่ละภาพออกเป็นสี่ส่วนก่อนแล้วจึงนำไปผ่านกระบวนการ perspective transform วิธีนี้จะทำให้ความเอียงของภาพลดลง ส่งผลให้สามารถเก็บข้อมูลได้แม่นยำมากขึ้น จากนั้นจึงใช้โปรแกรมเก็บค่าสีในภาพแต่ละภาพเพื่อนำมาใช้เป็นข้อมูลในการฝึกตัวแบบ



รูปที่ 27 การแบ่งภาพออกเป็นสี่ส่วนแล้วจึงทำ Perspective Transform และครอบตัดภาพเพื่อให้
เก็บข้อมูลที่มีความแม่นยำมากขึ้น

สำหรับวิธีการเก็บค่าสีนั้นภายในกรอบของแต่ละสีจะเก็บค่า 9 บริเวณ โดยแต่ละบริเวณมี
ขนาด 7×7 พิกเซล ดังนั้นเมื่อรวมข้อมูลที่เก็บได้ในทุกเฉดสีในทุกภาพเข้าด้วยกันแล้วทำให้ได้ข้อมูล
เฉดสีสำหรับการฝึกสอนตัวแบบในแต่ละอุปกรณ์จำนวน $7 \times 7 \times 9 \times 320 \times 104$ สี หรือประมาณ 14
ล้านสี



รูปที่ 28 การเก็บข้อมูลสำหรับฝึกสอนตัวแบบแปลงค่าสีจากรูปที่ถ่ายโดยอุปกรณ์ที่ใช้ในการทดลอง


หลังจากเก็บข้อมูลสำหรับฝึกสอนแล้วจะนำข้อมูลของแต่ละอุปกรณ์มาทำการจับคู่กัน ยกตัวอย่างเช่น เมื่อต้องการข้อมูลฝึกสอนสำหรับตัวแบบแปลงค่าสี iPad เป็น MotoC จะนำข้อมูลของ MotoC ใส่ในฝั่งของ Label (กรอบสีฟ้า) และข้อมูลของ iPad ใส่ในฝั่งของ Features (กรอบสีเขียว) ดังรูปที่ 29 และเนื่องจากมีอุปกรณ์ถ่ายภาพทั้งหมดสามอุปกรณ์จึงทำให้ได้ข้อมูล 6 คู่ สำหรับฝึกสอนตัวแบบแปลงค่าสีหกตัวแบบ

หลังจากจับคู่ข้อมูลแล้วจะนำข้อมูลมาแบ่งออกเป็นสามส่วน ดังนี้

1. **Train Set** = ข้อมูลสำหรับฝึกสอนตัวแบบแปลงค่าสี เป็นจำนวน 60% จากข้อมูลของแต่ละคู่
2. **Validate Set** = ข้อมูลสำหรับทดสอบเพื่อหาตัวแบบที่ดีที่สุด โดยข้อมูลในเซตนี้จะเป็นข้อมูลที่ไม่ปรากฏในเทรนเซต (Disjoint) เป็นจำนวน 20% จากข้อมูลของแต่ละคู่
3. **Test Set** = ข้อมูลสำหรับใช้ทดสอบเปรียบเทียบกับวิธีการแปลงค่าสีแบบอื่นๆ โดยข้อมูลในเซตนี้จะเป็นข้อมูลที่ไม่ปรากฏในเทรนเซต (Disjoint) เป็นจำนวน 20% จากข้อมูลของแต่ละคู่

	Device 1	Device 2
1	labels 67 64 190	features 54 42 184
2	labels 67 64 190	features 55 43 185
3	labels 67 64 190	features 55 43 185
4	labels 67 64 190	features 51 39 181
5	labels 67 64 190	features 51 39 181
6	labels 67 64 190	features 51 39 181
7	labels 67 64 190	features 51 39 181
8	labels 67 64 190	features 52 40 182
9	labels 67 64 190	features 55 43 185
10	labels 67 64 190	features 57 45 187

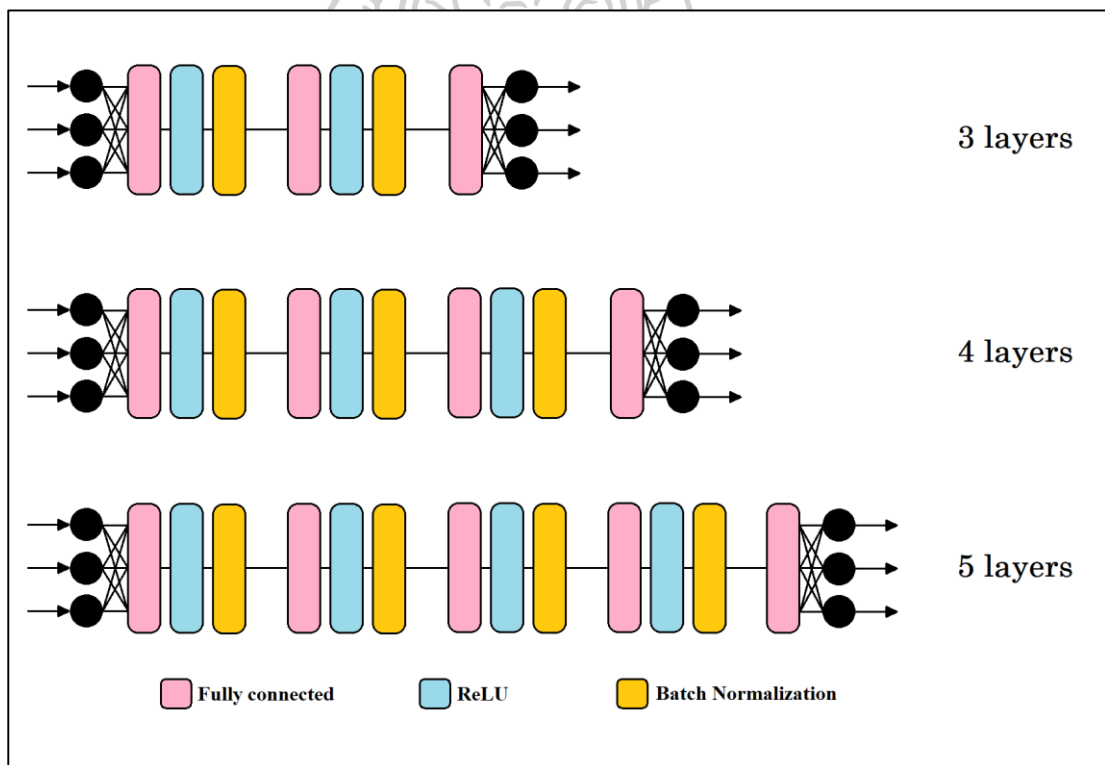
รูปที่ 29 การจับคู่ข้อมูลสำหรับสร้างเป็นข้อมูลฝึกสอนตัวแบบแปลงค่าสีระหว่างอุปกรณ์



รูปที่ 30 สรุปลขั้นตอนการเก็บข้อมูลสำหรับฝึกสอนตัวแบบการเรียนรู้เชิงลึกสำหรับการแปลงค่าสี
ระหว่างอุปกรณ์

4.3 การออกแบบโครงข่ายประสาทเทียมสำหรับแปลงค่าสี

เนื่องจากเป้าหมายของการออกแบบเครือข่ายคือการจับคู่ค่า RGB ของภาพหนึ่งเพื่อส่งออกมา RGB ของอุปกรณ์ถ่ายภาพอีกเครื่องหนึ่ง ดังนั้นทั้งขาเข้าและขาออกจะประกอบด้วยค่า RGB สามค่า ด้านในของเครือข่ายประกอบด้วยเซตของเลเยอร์จำนวนสามถึงห้าเซต โดยแต่ละเซตประกอบด้วย Dense Layer ซึ่งเชื่อมต่อกันแบบ Fully Connected โดยแต่ละเลเยอร์ใช้ฟังก์ชัน Rectified Linear Unit (ReLU) เป็น Activation Function ผลลัพธ์จากฟังก์ชัน ReLU จะถูกส่งไปสู่อเลเยอร์ Batch Normalization เพื่อลดค่าความผิดพลาดที่เกิดจากเลเยอร์ก่อนหน้านี้ จากนั้นจึงส่งต่อผลลัพธ์ไปที่ Dense Layer ซึ่งเป็นชั้นสุดท้าย รูปที่ 31 แสดงสถาปัตยกรรมโครงข่ายประสาทเทียมที่นำเสนอ



รูปที่ 31 สถาปัตยกรรมโครงข่ายประสาทเทียมของตัวแบบการเรียนรู้เชิงลึกทั้งสามแบบที่ใช้ในการ

ทดลอง

4.4 กลไกการฝึกและทดสอบตัวแบบการเรียนรู้เชิงลึกอย่างเป็นระบบ

ในการฝึกโครงข่ายประสาทเทียมนั้นเพื่อให้ได้ตัวแบบที่มีความแม่นยำจำเป็นต้องทดลองหลายครั้งด้วยค่าพารามิเตอร์หลายค่าและสถาปัตยกรรมโครงข่ายประสาทเทียมที่แตกต่างกันไปในแต่ละครั้ง งานวิจัยนี้จึงได้ออกแบบกลไกสำหรับทดลองฝึกโครงข่ายประสาทเทียมหลายครั้งอย่างเป็นระบบ เพื่อสะดวกต่อการบันทึกผลและการค้นหาตัวแบบที่ให้ผลดีที่สุดสำหรับการแปลงค่าสีในรูปภาพของอุปกรณ์แต่ละคู่

กลไกการฝึกโครงข่ายประสาทเทียมเริ่มต้นที่การใช้โปรแกรมสร้างไฟล์พารามิเตอร์เซตของการทดลองในแต่ละครั้ง หน้าทีของไฟล์พารามิเตอร์เซตคือการกำหนดขอบเขตของตัวแปรต่างๆ ที่จะป้อนให้โครงข่ายประสาทเทียมและกำหนดชนิดของโครงข่ายประสาทเทียมที่ใช้ในการทดลองแต่ละครั้ง โดยภายในไฟล์พารามิเตอร์เซตประกอบด้วยข้อมูลดังนี้

1. **Label** = อุปกรณ์เป้าหมายในการแปลงค่าสี
2. **Feature** = อุปกรณ์ต้นแบบ
3. **Experiment No** = หมายเลขการทดลอง
4. **hidden_layer_dim** = ลิสต์เก็บจำนวนโน้ดใน Hidden Layer ของโครงข่ายประสาทเทียม
5. **Minibatch_size** = ลิสต์เก็บขนาดของ Minibatch Size
6. **num_train_sample_per_sweep** = จำนวนข้อมูลสำหรับฝึกสอน
7. **num_test_sample** = จำนวนข้อมูลสำหรับทดสอบ
8. **combination** = จำนวนกลุ่มของพารามิเตอร์ทั้งหมดที่ป้อนให้โครงข่ายประสาทเทียม โดยคิดจากขนาดของลิสต์ hidden_layer_dim * ขนาดของลิสต์ Minibatch_size
9. **num_dense_layer** = จำนวนชั้นของ hidden_layer มีค่าตั้งแต่ 3 – 5
10. **train_file_name** = ไฟล์ข้อมูลที่ใช้ในการฝึกสอนตัวแบบ
11. **test_file_name** = ไฟล์ข้อมูลที่ใช้ในการทดสอบตัวแบบ

1	Experiment_No_____	: 60
2	Label_____	: MotoC
3	Feature_____	: iPad
4	hidden_layer_dim_____	: [6, 9, 12, 15, 18, 21, 24, 27, 30, 33]
5	num_dense_layer_____	: 3
6	combination_____	: 10
7	num_train_samples_per_sweep_____	: 4518606
8	num_test_samples_____	: 1554447
9	minibatch_size_____	: [500]
10	train_file_name_____	: ./Data/MotoC_iPad_plus_train_data_7.txt
11	test_file_name_____	: ./Data/MotoC_iPad_plus_vali_data_7.txt

รูปที่ 32 ตัวอย่างไฟล์พารามิเตอร์เซตในการทดลองครั้งที่ 60 ซึ่งเป็นการทดลองสร้างตัวแบบแปลงค่าสีจาก iPad Mini 4 เป็น MotoC โดยมีกลุ่มพารามิเตอร์ทั้งหมด 10 กลุ่ม (Combination) และใช้สถาปัตยกรรมโครงข่ายประสาทเทียมแบบ 3 เลเยอร์

ลำดับต่อไปโปรแกรมควบคุมการทดลองจะอ่านไฟล์พารามิเตอร์เซต จากนั้นจะเรียกใช้งานโครงข่ายประสาทเทียมตามจำนวนเลเยอร์ที่ระบุในไฟล์พารามิเตอร์เซต และป้อนค่าพารามิเตอร์กลุ่มแรกให้กับโครงข่าย เมื่อโครงข่ายได้รับค่าพารามิเตอร์แล้วจะอ่านข้อมูลสำหรับใช้ฝึกตามจำนวนพารามิเตอร์ num_train_sample_per_sweep และอ่านข้อมูลสำหรับใช้ทดสอบตามจำนวนพารามิเตอร์ num_test_samples เมื่ออ่านข้อมูลเสร็จสิ้นแล้วจะเข้าสู่ขั้นตอนของการฝึกและทดสอบ เมื่อเสร็จสิ้นการฝึกและทดสอบจะเขียนไฟล์บันทึกผลที่ได้จากการฝึกและทดสอบ จากนั้นโปรแกรมควบคุมการทดลองจะป้อนค่าพารามิเตอร์กลุ่มถัดไปให้กับโครงข่ายเพื่อทำการฝึกและทดสอบต่อไปจนครบทุกกลุ่มพารามิเตอร์

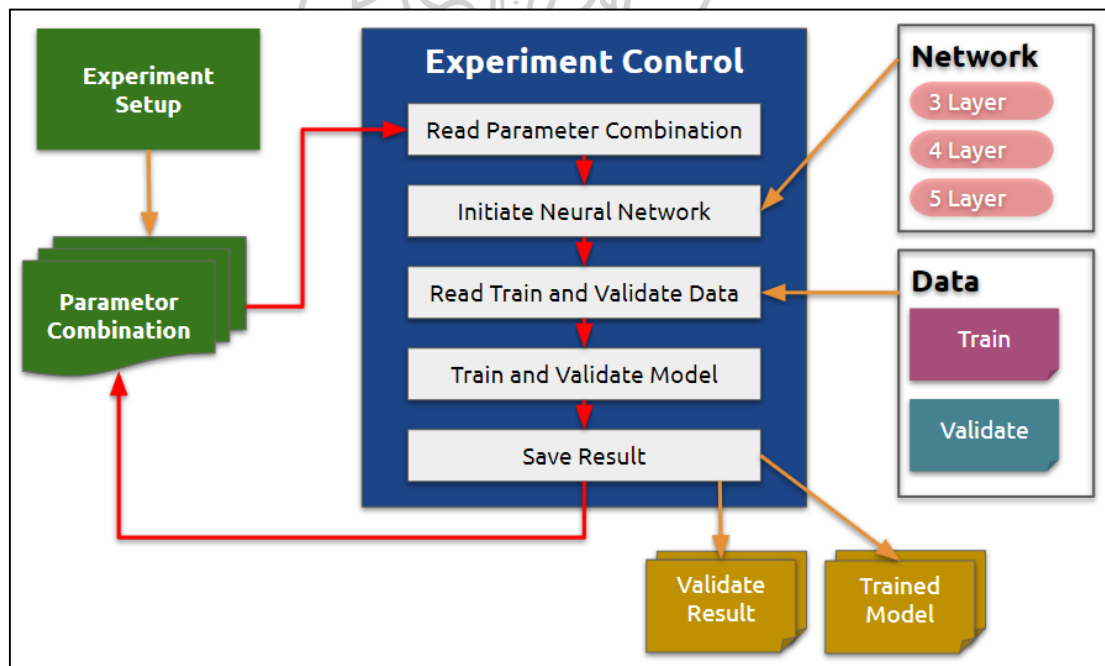
ภายในไฟล์ผลลัพธ์จากการฝึกแต่ละครั้งนั้นประกอบด้วยค่าหาค่าสำหรับตรวจสอบความแม่นยำ ได้แก่

- [1] ค่าความต่างที่มากที่สุดระหว่างข้อมูลเป้าหมายและข้อมูลต้นฉบับ ซึ่งคำนวณจาก $\max(|\text{Label}(v) - \text{Feature}(v)|)$ เมื่อ v คือค่าสีจากหนึ่งแชนแนลสีในระบบ RGB
- [2] ค่าความต่างมากที่สุดระหว่างข้อมูลเป้าหมายและค่าที่ทำนายได้จากตัวแบบ คำนวณได้จาก $\max(|\text{Label}(v) - \text{Predict}(v)|)$ เมื่อ v คือค่าสีจากหนึ่งแชนแนลสีในระบบ RGB
- [3] ค่าเฉลี่ยความต่างระหว่างข้อมูลเป้าหมายและข้อมูลต้นฉบับ $\text{avg}(|\text{Label}(v) - \text{Feature}(v)|)$
- [4] ค่าเฉลี่ยความต่างระหว่างข้อมูลเป้าหมายและค่าที่ทำนายได้ $\text{avg}(|\text{Label}(v) - \text{Predict}(v)|)$
- [5] ส่วนเบี่ยงเบนมาตรฐานของค่าเฉลี่ยความต่างระหว่างข้อมูลเป้าหมายและค่าที่ทำนายได้

max color difference between cameras (R G B)_____:	83.0	73.0	79.0
max mapping error (R G B)_____:	76.0	83.0	85.0
average color difference between cameras (R G B)___:	19.90	11.39	13.88
average mapping error (R G B)_____:	7.88	6.24	8.08
Standard Deviation of mapping errors (R G B)_____:	6.04	4.95	6.34

รูปที่ 33 ตัวอย่างผลลัพธ์ที่ได้จากการฝึกโดยกลุ่มพารามิเตอร์หนึ่งกลุ่ม

หลังจากทดลองเสร็จนั้นการหาตัวแบบแปลงค่าสีระหว่างอุปกรณ์ที่ให้ประสิทธิภาพดีที่สุดทำได้โดยการเปรียบเทียบค่าความแตกต่างโดยเฉลี่ยระหว่างข้อมูลเป้าหมายกับค่าที่ทำนายได้จากตัวแบบ (avg Label – Predict diff) โดยตัวแบบใดให้ค่าความแตกต่างน้อยที่สุดจะเป็นตัวแบบที่แปลงค่าสีได้ใกล้เคียงกับภาพเป้าหมายมากที่สุดจึงให้ประสิทธิภาพดีที่สุด รูปที่ 34 สรุปกลไกการฝึกสอนและทดสอบตัวแบบการเรียนรู้เชิงลึกสำหรับแปลงค่าสีระหว่างอุปกรณ์อย่างเป็นระบบ

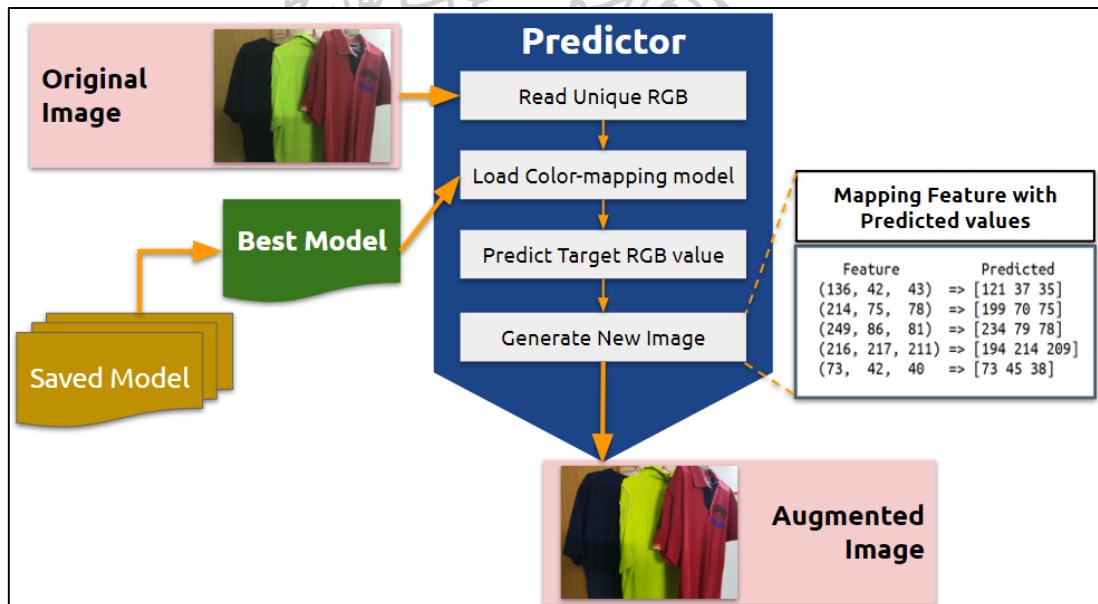


รูปที่ 34 กลไกการฝึกสอนตัวแบบการเรียนรู้เชิงลึกสำหรับแปลงค่าสีระหว่างอุปกรณ์อย่างเป็นระบบ

4.5 การนำตัวแบบการเรียนรู้ที่ผ่านการฝึกมาใช้ในการขยายข้อมูลภาพ

การขยายข้อมูลภาพเริ่มด้วยการคัดเลือกผลลัพธ์การฝึกที่ดีที่สุดโดยดูจากไฟล์ผลลัพธ์ที่ได้เขียนไว้ในการฝึกแต่ละครั้ง โดยค่าที่ใช้เป็นเกณฑ์ในการเลือกผลลัพธ์ที่ดีที่สุดคือค่าความต่างโดยเฉลี่ยระหว่าง Label – Predict (ค่าที่ทำนายได้) ผลลัพธ์ใดที่ให้ค่าความต่างโดยเฉลี่ยน้อยที่สุดจะถือว่าเป็นผลลัพธ์ที่ดีที่สุด จากนั้นโปรแกรมตัวทำนายจะอ่านภาพที่ต้องการขยายข้อมูลและดึงเอาสีที่แตกต่างกันทั้งหมดจากภาพที่ต้องการขยายข้อมูลและส่งให้โครงข่ายประสาทเทียมที่คัดเลือกไว้ทำนายค่าสีที่ควรจะเป็น (Predicted) และเก็บข้อมูลเป็น Key – Value เพื่อความสะดวกในการเรียกใช้

เมื่อทำนายค่าครบแล้วลำดับต่อไปโปรแกรมตัวทำนายจะคัดลอกภาพจากภาพต้นฉบับ แล้วปรับสีในภาพคัดลอกตามข้อมูลแบบ Key – Value ที่ได้จากการทำนาย จากนั้นจึงบันทึกภาพที่แก้ไขแล้วเพื่อความสะดวกในการตรวจสอบต่อไป สุดท้ายโปรแกรมจะรายงานเวลาทั้งหมดที่ใช้ไปในการสร้างภาพใหม่ (ขยายข้อมูล) รูปที่ 35 สรุปกลไกในการขยายข้อมูลภาพโดยใช้ตัวแบบการเรียนรู้ที่ผ่านการฝึก



รูปที่ 35 กลไกการใช้ตัวแบบที่ผ่านการฝึกสอนแปลงค่าสีจากภาพต้นฉบับให้เป็นสีจากภาพเป้าหมาย

บทที่ 5


ผลการดำเนินงานวิจัย

5.1 การศึกษาความคงที่ของสีจากภาพของอุปกรณ์ที่ใช้ในการทดลอง


การทดสอบความคงที่ของสีจากภาพของกล้องที่ใช้ในการทดลองเริ่มต้นโดยการนำอุปกรณ์ทั้งสามติดตั้งบนขาตั้งกล้อง แล้วจึงถ่ายรูป color palette จำนวน 30 รูปต่ออุปกรณ์ จากนั้นจึงใช้โปรแกรมเก็บค่าสีจากจุดเดียวกันในแต่ละรูปของ color palette เพื่อนำมาพล็อตกราฟ โดยหาอุปกรณ์ใดมีความคงที่ของสีมาก จุดสีในกราฟจะมีความเกาะกลุ่มกันมากกว่าอุปกรณ์ที่มีความคงที่ของสีน้อย




รูปที่ 36 Color Palette สำหรับใช้ทดสอบความคงที่ของสีจากภาพที่ถ่ายโดยอุปกรณ์ที่ใช้ในการทดลอง



รูปที่ 37 ความคงที่ของสีจากภาพของ MotoC เมื่อมองจากมุมมองตามแกน R แกน G และแกน B ตามลำดับ



รูปที่ 38 ความคงที่ของสีจากภาพของ iPad Mini 4 เมื่อมองจากมุมมองตามแกน R แกน G และแกน B ตามลำดับ



รูปที่ 39 ความคงที่ของสีจากภาพของ Galaxy S8 เมื่อมองจากมุมมองตามแกน R แกน G และแกน B ตามลำดับ

จากกราฟความคงที่สีของทั้งสามอุปกรณ์แสดงให้เห็นว่า Galaxy S8 มีความคงที่ของสีมากที่สุด รองลงมาคือ iPad Mini 4 และ MotoC เป็นอุปกรณ์ที่มีความคงที่ของสีต่ำสุดในบรรดาอุปกรณ์ที่เลือกใช้ในการทดลอง

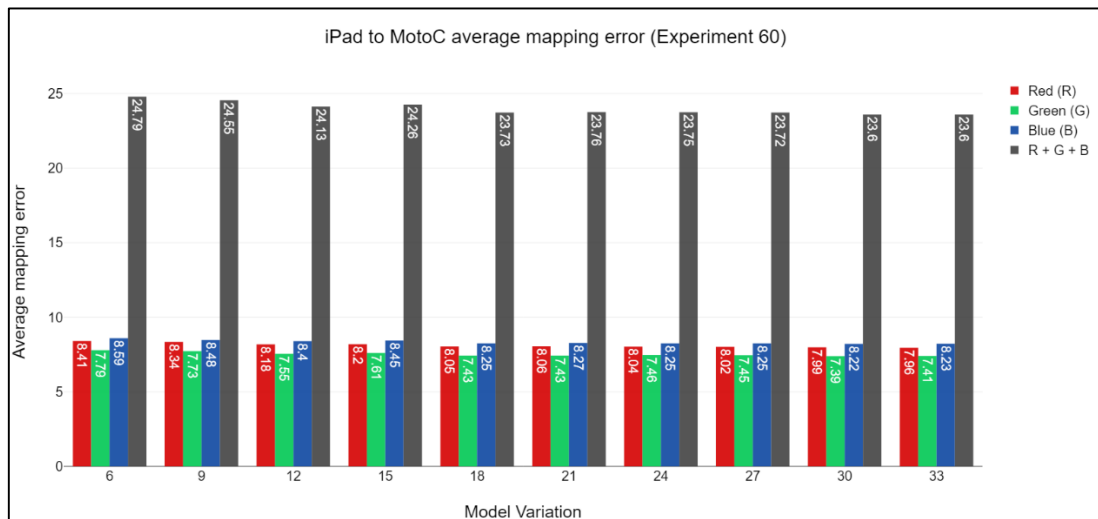
ความคงที่ของสีมีผลต่อความแม่นยำที่ได้ในหัวข้อ 5.4 การทดสอบด้วยภาพจริงจากอุปกรณ์ถ่ายภาพที่ใช้ในการทดลองจากผลการทดสอบในหัวข้อดังกล่าวพบว่าตัวแบบที่ฝึกสอนด้วยข้อมูลจากตัวแบบแปลงค่าสีเป็น MotoC ทำให้เกิดการเพิ่มความแม่นยำในรูปจาก iPad Mini4 มากที่สุดแทนที่จะเป็นรูปจาก MotoC เอง สาเหตุที่เกิดปรากฏการณ์นี้สามารถอธิบายได้จากผลทดสอบความคงที่ของสีจากกล้องของ MotoC ซึ่งพบว่ามีความคงที่ของสีต่ำสุดในบรรดาอุปกรณ์ทดสอบทั้งสาม ดังนั้นในการถ่ายภาพแต่ละครั้งของ MotoC จึงให้สีที่ไม่เหมือนกันโดยในบางครั้งอาจให้สีคล้ายกับสีที่ได้จากกล้องของ iPad Mini4 ซึ่งมีความคงที่ของสีเป็นลำดับถัดมา จึงทำให้ความแม่นยำเพื่อขึ้นมากกว่าเมื่อทดสอบด้วยรูปจริงจาก iPad Mini4

5.2 ตัวแบบแปลงค่าสีระหว่างอุปกรณ์

ส่วนนี้จะกล่าวถึงการทดลองและผลของวิธีการที่เสนอ เริ่มต้นด้วยการแสดงความถูกต้องของตัวแบบโครงข่ายประสาทเทียมที่ทดลองใช้สำหรับ (1) ตัวแบบแปลงค่าสีจาก iPad Mini4 เป็น MotoC และ (2) ตัวแบบแปลงค่าสีจาก MotoC เป็น iPad Mini4 (3) ตัวแบบแปลงค่าสีจาก iPad Mini4 เป็น Galaxy S8 (4) ตัวแบบแปลงค่าสีจาก Galaxy S8 เป็น iPad Mini4 (5) ตัวแบบแปลงค่าสีจาก Galaxy S8 เป็น MotoC (6) ตัวแบบแปลงค่าสีจาก MotoC เป็น Galaxy S8 และ (7) เป็นการเปรียบเทียบประสิทธิภาพของตัวแบบแต่ละตัวเทียบกับวิธี Poly Fit

5.2.1 ตัวแบบแปลงค่าสีจาก iPad Mini 4 เป็น MotoC

ผลลัพธ์ที่ดีที่สุดของตัวแบบแปลงค่าสีจาก iPad Mini 4 เป็น MotoC นั้นมาจากกลุ่มพารามิเตอร์ที่ 10 ในการทดลองครั้งที่ 60 โดยกลุ่มพารามิเตอร์ดังกล่าวมีจำนวนชั้น Hidden Layer 3 ชั้น จำนวนโหนดใน Hidden Layer แต่ละชั้นจำนวน 33 โหนด และมี Minibatch Size ขนาด 500 รูปที่ 40 แสดงกราฟสรุปผลการฝึกและทดสอบของทุกกลุ่มพารามิเตอร์ในการทดลองครั้งที่ 60 และตารางที่ 2 แสดงรายละเอียดผลการฝึกและทดสอบตัวแบบที่ใช้พารามิเตอร์กลุ่มที่ 10



รูปที่ 40 ประสิทธิภาพของตัวแบบแปลงค่าสีจาก iPad Mini 4 ไปเป็น MotoC แท่งสีแดงเขียวและน้ำเงินแสดงค่าเฉลี่ยของการแมปสีที่ผิดพลาดของตัวแบบแต่ละตัว แท่งสีค่าแสดงผลรวมของการแมปสีที่ผิดพลาดจากทั้งสามแขนแนลสี

ตารางที่ 2 รายละเอียดผลการทดสอบตัวแบบการแปลงค่าสีจากกลุ่มพารามิเตอร์ที่ 10 ซึ่งเป็นตัวแบบที่ดีที่สุดที่ได้จากการทดลองแปลงค่าสีจาก iPad Mini 4 ไปเป็น MotoC


Metrics	R	G	B
ความแตกต่างมากที่สุดระหว่างสีจาก MotoC และ iPad Mini 4	85.0	75.0	77.0
ความแตกต่างมากที่สุดระหว่างสีจาก MotoC และค่าที่ทำนายได้	66.0	71.0	74.0
ค่าเฉลี่ยความแตกต่างระหว่างสีจาก MotoC และ iPad Mini 4	14.12	12.21	10.73
ค่าเฉลี่ยความแตกต่างระหว่างสีจาก MotoC และค่าที่ทำนายได้	7.96	7.40	8.23
ส่วนเบี่ยงเบนมาตรฐานของค่าเฉลี่ยความแตกต่างระหว่างสีจาก MotoC และค่าที่ทำนายได้	6.25	5.84	6.70

จากผลลัพธ์การทดสอบของตัวแบบที่ใช้พารามิเตอร์กลุ่มที่ 10 นั้นแสดงให้เห็นว่าโดยเฉลี่ยแล้วความแตกต่างระหว่างแต่ละจุดในภาพของ MotoC (Label) และ iPad Mini 4 (Feature) อยู่ที่ประมาณ 14.12 12.21 10.73 ตามลำดับสี RGB แต่ค่าความแตกต่างโดยเฉลี่ยระหว่างแต่ละจุดในภาพของ MotoC ซึ่งเป็นภาพเป้าหมาย และค่าที่ทำนายได้มีความต่างกันโดยเฉลี่ยประมาณ 7.96

7.40 8.23 ตามลำดับ RGB แสดงให้เห็นว่าค่าสีที่ทำนายได้จากตัวแบบมีความใกล้เคียงกับภาพเป้าหมายมากขึ้นหลังจากผ่านการแปลงค่าสีแล้ว

5.2.2 ตัวแบบแปลงค่าสีจาก MotoC เป็น iPad Mini 4

ผลลัพธ์ที่ดีที่สุดของตัวแบบแปลงค่าสีจาก MotoC เป็น iPad Mini 4 นั้นมาจากกลุ่มพารามิเตอร์ที่ 10 ในการทดลองครั้งที่ 63 โดยกลุ่มพารามิเตอร์ดังกล่าวมีจำนวนชั้น Hidden Layer 3 ชั้น จำนวนโหนดใน Hidden Layer แต่ละชั้นจำนวน 33 โหนด และมี Minibatch Size ขนาด 500 รูปที่ 41 แสดงกราฟสรุปผลการฝึกและทดสอบของทุกกลุ่มพารามิเตอร์ในการทดลองครั้งที่ 63 และตารางที่ 3 แสดงรายละเอียดผลการฝึกและทดสอบตัวแบบที่ใช้พารามิเตอร์กลุ่มที่ 10



รูปที่ 41 ประสิทธิภาพของตัวแบบแปลงค่าสีจาก MotoC ไปเป็น iPad Mini 4 แท่งสีแดงและน้ำเงินแสดงค่าเฉลี่ยของการแมปสีที่ผิดพลาดของตัวแบบแต่ละตัว แท่งสีดำแสดงผลรวมของการแมปสีที่ผิดพลาดจากทั้งสามแชนแนลสี

ตารางที่ 3 รายละเอียดผลการทดสอบตัวแบบการแปลงค่าสีจากกลุ่มพารามิเตอร์ที่ 10 ซึ่งเป็นตัวแบบที่ดีที่สุดที่ได้จากการทดลองแปลงค่าสีจาก MotoC ไปเป็น iPad Mini 4


Metrics	R	G	B
ความแตกต่างมากที่สุดระหว่างสีจาก iPad Mini 4 และ MotoC	83.0	73.0	77.0
ความแตกต่างมากที่สุดระหว่างสีจาก iPad Mini 4 และค่าที่ทำนายได้	78.0	62.0	76.0

ค่าเฉลี่ยความแตกต่างระหว่างสีจาก iPad Mini 4 และ MotoC	14.14	12.22	10.75
ค่าเฉลี่ยความแตกต่างระหว่างสีจาก iPad Mini 4 และค่าที่ทำนายได้	7.58	6.70	6.58
ส่วนเบี่ยงเบนมาตรฐานของค่าเฉลี่ยความแตกต่างระหว่างสีจาก iPad Mini 4 และค่าที่ทำนายได้	6.16	5.55	5.36

จากผลลัพธ์การทดสอบของตัวแบบที่ใช้พารามิเตอร์กลุ่มที่ 10 นั้นแสดงให้เห็นว่าโดยเฉลี่ยแล้วความแตกต่างระหว่างแต่ละจุดในภาพของ iPad Mini 4 (Label) และ MotoC (Feature) อยู่ที่ประมาณ 14.14 12.22 10.75 ตามลำดับสี RGB แต่ค่าความแตกต่างโดยเฉลี่ยระหว่างแต่ละจุดในภาพของ iPad Mini 4 ซึ่งเป็นภาพเป้าหมายและค่าที่ทำนายได้มีความต่างกันโดยเฉลี่ยประมาณ 7.58 6.70 6.58 ตามลำดับ RGB แสดงให้เห็นว่าค่าสีที่ทำนายได้จากตัวแบบมีความใกล้เคียงกับภาพเป้าหมายมากขึ้นหลังจากผ่านการแปลงค่าสีแล้ว

5.2.3 ตัวแบบแปลงค่าสีจาก iPad Mini 4 เป็น Galaxy S8

ผลลัพธ์ที่ดีที่สุดของตัวแบบแปลงค่าสีจาก iPad Mini 4 เป็น Galaxy S8 นั้นมาจากกลุ่มพารามิเตอร์ที่ 10 ในการทดลองครั้งที่ 66 โดยกลุ่มพารามิเตอร์ดังกล่าวมีจำนวนชั้น Hidden Layer 3 ชั้น จำนวนโหนดใน Hidden Layer แต่ละชั้นจำนวน 33 โหนด และมี Minibatch Size ขนาด 500 รูปที่ 42 แสดงกราฟสรุปผลการฝึกและทดสอบของทุกกลุ่มพารามิเตอร์ในการทดลองครั้งที่ 66 และตารางที่ 4 แสดงรายละเอียดผลการฝึกและทดสอบตัวแบบที่ใช้พารามิเตอร์กลุ่มที่ 10



รูปที่ 42 ประสิทธิภาพของตัวแบบแปลงค่าสีจาก iPad Mini 4 ไปเป็น Galaxy S8 แ่งสีแดงเขียว และน้ำเงินแสดงค่าเฉลี่ยของการแมพสีที่ผิดพลาดของตัวแบบแต่ละตัว แ่งสีดำแสดงผลรวมของการแมพสีที่ผิดพลาดจากทั้งสามแชนแนลสี

ตารางที่ 4 รายละเอียดผลการทดสอบตัวแบบการแปลงค่าสีจากกลุ่มพารามิเตอร์ที่ 10 ซึ่งเป็นตัวแบบ ที่ดีที่สุดที่ได้จากการทดลองแปลงค่าสีจาก iPad Mini 4 ไปเป็น Galaxy S8


Metrics	R	G	B
ความแตกต่างมากที่สุดระหว่างสีจาก Galaxy S8 และ iPad Mini 4	53.0	51.0	68.0
ความแตกต่างมากที่สุดระหว่างสีจาก Galaxy S8 และค่าที่ทำนายได้	63.0	46.0	65.0
ค่าเฉลี่ยความแตกต่างระหว่างสีจาก Galaxy S8 และ iPad Mini 4	11.65	7.83	16.62
ค่าเฉลี่ยความแตกต่างระหว่างสีจาก Galaxy S8 และค่าที่ทำนายได้	6.63	5.27	7.17
ส่วนเบี่ยงเบนมาตรฐานของค่าเฉลี่ยความแตกต่างระหว่างสีจาก Galaxy S8 และค่าที่ทำนายได้	5.18	4.39	6.04

จากผลลัพธ์การทดสอบของตัวแบบที่ใช้พารามิเตอร์กลุ่มที่ 10 นั้นแสดงให้เห็นว่าโดยเฉลี่ยแล้วความแตกต่างระหว่างแต่ละจุดในภาพของ Galaxy S8 (Label) และ iPad Mini 4 (Feature) อยู่ที่ประมาณ 11.65 7.83 16.62 ตามลำดับสี RGB แต่ค่าความแตกต่างโดยเฉลี่ยระหว่างแต่ละจุดในภาพของ Galaxy S8 ซึ่งเป็นภาพเป้าหมายและค่าที่ทำนายได้มีความต่างกันโดยเฉลี่ยประมาณ 6.63

5.27 7.14 ตามลำดับ RGB แสดงให้เห็นว่าค่าสีที่ทำนายได้จากตัวแบบมีความใกล้เคียงกับภาพเป้าหมายมากขึ้นหลังจากผ่านการแปลงค่าสีแล้ว

5.2.4 ตัวแบบแปลงค่าสีจาก Galaxy S8 เป็น iPad Mini 4

ผลลัพธ์ที่ดีที่สุดของตัวแบบแปลงค่าสีจาก Galaxy S8 เป็น iPad Mini 4 นั้นมาจากกลุ่มพารามิเตอร์ที่ 10 ในการทดลองครั้งที่ 69 โดยกลุ่มพารามิเตอร์ดังกล่าวมีจำนวนชั้น Hidden Layer 3 ชั้น จำนวนโหนดใน Hidden Layer แต่ละชั้นจำนวน 33 โหนด และมี Minibatch Size ขนาด 500 รูปที่ 43 แสดงกราฟสรุปผลการฝึกและทดสอบของทุกกลุ่มพารามิเตอร์ในการทดลองครั้งที่ 69 และตารางที่ 5 แสดงรายละเอียดผลการฝึกและทดสอบตัวแบบที่ใช้พารามิเตอร์กลุ่มที่ 10



รูปที่ 43 ประสิทธิภาพของตัวแบบแปลงค่าสีจาก Galaxy S8 ไปเป็น iPad Mini 4 แ่งสีแดงเขียว และน้ำเงินแสดงค่าเฉลี่ยของการแมพสีที่ผิดพลาดของตัวแบบแต่ละตัว แ่งสีดำแสดงผลรวมของการแมพสีที่ผิดพลาดจากทั้งสามแขนแนลสี

ตารางที่ 5 รายละเอียดผลการทดสอบตัวแบบการแปลงค่าสีจากกลุ่มพารามิเตอร์ที่ 10 ซึ่งเป็นตัวแบบที่ดีที่สุดที่ได้จากการทดลองแปลงค่าสีจาก Galaxy S8 ไปเป็น iPad Mini 4


Metrics	R	G	B
ความแตกต่างมากที่สุดระหว่างสีจาก iPad Mini 4 และ Galaxy S8	53.0	49.0	68.0
ความแตกต่างมากที่สุดระหว่างสีจาก iPad Mini 4 และค่าที่ทำนายได้	64.0	44.0	55.0

ค่าเฉลี่ยความแตกต่างระหว่างสีจาก iPad Mini 4 และ Galaxy S8	11.63	7.81	16.63
ค่าเฉลี่ยความแตกต่างระหว่างสีจาก iPad Mini 4 และค่าที่ทำนายได้	6.69	5.32	6.25
ส่วนเบี่ยงเบนมาตรฐานของค่าเฉลี่ยความแตกต่างระหว่างสีจาก iPad Mini 4 และค่าที่ทำนายได้	5.50	4.63	5.15

จากผลลัพธ์การทดสอบของตัวแบบที่ใช้พารามิเตอร์กลุ่มที่ 10 นั้นแสดงให้เห็นว่าโดยเฉลี่ยแล้วความแตกต่างระหว่างแต่ละจุดในภาพของ iPad Mini 4 (Label) และ Galaxy S8 (Feature) อยู่ที่ประมาณ 11.63 7.81 16.63 ตามลำดับสี RGB แต่ค่าความแตกต่างโดยเฉลี่ยระหว่างแต่ละจุดในภาพของ iPad Mini 4 ซึ่งเป็นภาพเป้าหมายและค่าที่ทำนายได้มีความต่างกันโดยเฉลี่ยประมาณ 6.69 5.32 6.25 ตามลำดับ RGB แสดงให้เห็นว่าค่าสีที่ทำนายได้จากตัวแบบมีความใกล้เคียงกับภาพเป้าหมายมากขึ้นหลังจากผ่านการแปลงค่าสีแล้ว

5.2.5 ตัวแบบแปลงค่าสีจาก Galaxy S8 เป็น MotoC

ผลลัพธ์ที่ดีที่สุดของตัวแบบแปลงค่าสีจาก Galaxy S8 เป็น MotoC นั้นมาจากกลุ่มพารามิเตอร์ที่ 10 ในการทดลองครั้งที่ 72 โดยกลุ่มพารามิเตอร์ดังกล่าวมีจำนวนชั้น Hidden Layer 3 ชั้น จำนวนโนดใน Hidden Layer แต่ละชั้นจำนวน 33 โหนด และมี Minibatch Size ขนาด 500 รูปที่ 44 แสดงกราฟสรุปผลการฝึกและทดสอบของทุกกลุ่มพารามิเตอร์ในการทดลองครั้งที่ 72 และตารางที่ 6 แสดงรายละเอียดผลการฝึกและทดสอบตัวแบบที่ใช้พารามิเตอร์กลุ่มที่ 10



รูปที่ 44 ประสิทธิภาพของตัวแบบแปลงค่าสีจาก Galaxy S8 ไปเป็น MotoC แ่งสีแดงเขียวและน้ำเงินแสดงค่าเฉลี่ยของการแมพสีที่ผิดพลาดของตัวแบบแต่ละตัว แ่งสีดำแสดงผลรวมของการแมพสีที่ผิดพลาดจากทั้งสามแชนแนลสี

ตารางที่ 6 รายละเอียดผลการทดสอบตัวแบบการแปลงค่าสีจากกลุ่มพารามิเตอร์ที่ 10 ซึ่งเป็นตัวแบบที่ดีที่สุดที่ได้จากการทดลองแปลงค่าสีจาก Galaxy S8 ไปเป็น MotoC

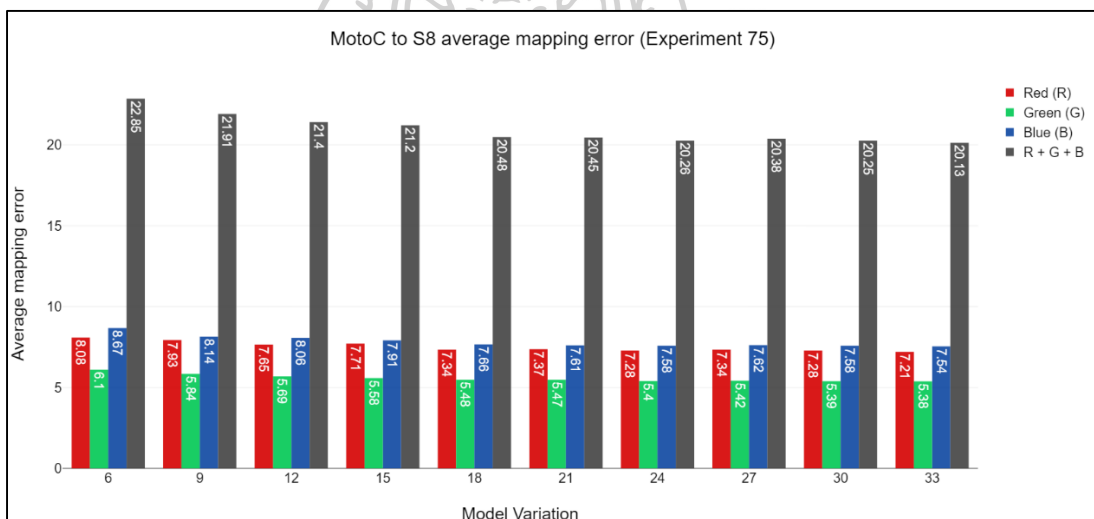
Metrics	R	G	B
ความแตกต่างมากที่สุดระหว่างสีจาก MotoC และ Galaxy S8	83.0	73.0	79.0
ความแตกต่างมากที่สุดระหว่างสีจาก MotoC และค่าที่ทำนายได้	76.0	83.0	85.0
ค่าเฉลี่ยความแตกต่างระหว่างสีจาก MotoC และ Galaxy S8	19.91	11.40	13.88
ค่าเฉลี่ยความแตกต่างระหว่างสีจาก MotoC และค่าที่ทำนายได้	7.89	6.24	8.09
ส่วนเบี่ยงเบนมาตรฐานของค่าเฉลี่ยความแตกต่างระหว่างสีจาก MotoC และค่าที่ทำนายได้	6.05	4.95	6.35

จากผลลัพธ์การทดสอบของตัวแบบที่ใช้พารามิเตอร์กลุ่มที่ 10 นั้นแสดงให้เห็นว่าโดยเฉลี่ยแล้วความแตกต่างระหว่างแต่ละจุดในภาพของ MotoC (Label) และ Galaxy S8 (Feature) อยู่ที่ประมาณ 19.91 11.40 13.88 ตามลำดับสี RGB แต่ค่าความแตกต่างโดยเฉลี่ยระหว่างแต่ละจุดในภาพของ MotoC ซึ่งเป็นภาพเป้าหมายและค่าที่ทำนายได้มีความต่างกันโดยเฉลี่ยประมาณ 7.89

6.24 8.09 ตามลำดับ RGB แสดงให้เห็นว่าค่าสีที่ทำนายได้จากตัวแบบมีความใกล้เคียงกับภาพเป้าหมายมากขึ้นหลังจากผ่านการแปลงค่าสีแล้ว

5.2.6 ตัวแบบแปลงค่าสีจาก MotoC เป็น Galaxy S8

ผลลัพธ์ที่ดีที่สุดของตัวแบบแปลงค่าสีจาก MotoC เป็น Galaxy S8 นั้นมาจากกลุ่มพารามิเตอร์ที่ 10 ในการทดลองครั้งที่ 75 โดยกลุ่มพารามิเตอร์ดังกล่าวมีจำนวนชั้น Hidden Layer 3 ชั้น จำนวนโหนดใน Hidden Layer แต่ละชั้นจำนวน 33 โหนด และมี Minibatch Size ขนาด 500 รูปที่ 45 แสดงกราฟสรุปผลการฝึกและทดสอบของทุกกลุ่มพารามิเตอร์ในการทดลองครั้งที่ 75 และตารางที่ 7 แสดงรายละเอียดผลการฝึกและทดสอบตัวแบบที่ใช้พารามิเตอร์กลุ่มที่ 10



รูปที่ 45 ประสิทธิภาพของตัวแบบแปลงค่าสีจาก MotoC ไปเป็น Galaxy S8 แห่งสีแดงเขียวและน้ำเงินแสดงค่าเฉลี่ยของการแมพสีที่ผิดพลาดของตัวแบบแต่ละตัว แห่งสีดำแสดงผลรวมของการแมพสีที่ผิดพลาดจากทั้งสามแขนแนลสี

ตารางที่ 7 รายละเอียดผลการทดสอบตัวแบบการแปลงค่าสีจากกลุ่มพารามิเตอร์ที่ 10 ซึ่งเป็นตัวแบบที่ดีที่สุดที่ได้จากการทดลองแปลงค่าสีจาก MotoC ไปเป็น Galaxy S8

Metrics	R	G	B
ความแตกต่างมากที่สุดระหว่างสีจาก Galaxy S8 และ MotoC	78.0	71.0	77.0
ความแตกต่างมากที่สุดระหว่างสีจาก Galaxy S8 และค่าที่ทำนายได้	79.0	83.0	89.0


ค่าเฉลี่ยความแตกต่างระหว่างสีจาก Galaxy S8 และ MotoC	19.85	11.42	13.87
ค่าเฉลี่ยความแตกต่างระหว่างสีจาก Galaxy S8 และค่าที่ทำนายได้	7.21	5.38	7.54
ส่วนเบี่ยงเบนมาตรฐานของค่าเฉลี่ยความแตกต่างระหว่างสีจาก Galaxy S8 และค่าที่ทำนายได้	5.83	4.26	6.44

จากผลลัพธ์การทดสอบของตัวแบบที่ใช้พารามิเตอร์กลุ่มที่ 10 นั้นแสดงให้เห็นว่าโดยเฉลี่ยแล้วความแตกต่างระหว่างแต่ละจุดในภาพของ Galaxy S8 (Label) และ MotoC (Feature) อยู่ที่ประมาณ 19.85 11.42 13.87 ตามลำดับสี RGB แต่ค่าความแตกต่างโดยเฉลี่ยระหว่างแต่ละจุดในภาพของ Galaxy S8 ซึ่งเป็นภาพเป้าหมายและค่าที่ทำนายได้มีความต่างกันโดยเฉลี่ยประมาณ 7.21 5.38 7.54 ตามลำดับ RGB แสดงให้เห็นว่าค่าสีที่ทำนายได้จากตัวแบบมีความใกล้เคียงกับภาพเป้าหมายมากขึ้นหลังจากผ่านการแปลงค่าสีแล้ว

5.2.7 เปรียบเทียบประสิทธิภาพของตัวแบบแปลงค่าสี

ในส่วนนี้จะกล่าวถึงการนำตัวแบบแปลงค่าสีทั้งหมดมาเปรียบเทียบประสิทธิภาพของการปรับค่าสีเทียบกับวิธี PolyFit ในข้อมูลทดสอบสองชุดได้แก่ชุดที่สร้างขึ้นพร้อมกับชุดข้อมูลที่ใช้ฝึกฝนตัวแบบโดยต่อไปนี้จะเรียกว่า Generate Set และชุดข้อมูลที่สร้างขึ้นโดยการสุ่มค่าสีโดยต่อไปนี้จะเรียกว่า Random Set นอกจากนี้จะมีการเปรียบเทียบภาพตัวอย่างที่ผ่านการขยายข้อมูลโดยวิธีทั้งสอง

สำหรับการสร้าง Random Set นั้นได้ทำการสุ่มค่าสี RGB ขึ้นมาทั้งหมด 11,200 สีแล้วนำมาจัดเรียงลงตารางขนาด $40 * 28$ ภายในขนาดของกระดาษ A4 โดยแต่ละภาพจะประกอบด้วย สี 1120 สี จากนั้นจึงพิมพ์ภาพทั้งหมดแล้วนำอุปกรณ์ถ่ายภาพที่เลือกทั้งสามอุปกรณ์ถ่ายภาพที่พิมพ์ออกมาแล้วจึงใช้โปรแกรมเก็บค่าสีในช่องสีแต่ละช่องแล้วนำมาจับคู่เพื่อสร้างเป็น Random Set



รูปที่ 46 ภาพสำหรับเก็บข้อมูลเพื่อสร้างข้อมูลชุด Random Set แต่ละภาพประกอบด้วยสีที่ถูกสุ่มขึ้นมาจำนวน 1,120 สี

ค่าที่ใช้ในการวัดประสิทธิภาพของตัวแบบที่ผ่านการฝึกและวิธี Poly Fit จะใช้การคำนวณ Euclidean Distance โดยมีสมการดังนี้

$$D_{rgb_1} = \sqrt{(R_1 - R_0)^2 + (G_1 - G_0)^2 + (B_1 - B_0)^2}$$

$$D_{rgb_2} = \sqrt{(R_2 - R_0)^2 + (G_2 - G_0)^2 + (B_2 - B_0)^2}$$

โดยที่

R_0, G_0, B_0 คือ ค่า RGB จากภาพเป้าหมายการแปลงสีภาพ

R_1, G_1, B_1 คือ ค่า RGB จากภาพที่ผ่านการแปลงสีด้วยโมเดล


R_2, G_2, B_2 คือ ค่า RGB จากภาพที่ผ่านการแปลงสีด้วยวิธี Poly Fit

ผู้วิจัยทำการคำนวณค่า D_{rgb_1} และ D_{rgb_2} ในแต่ละจุดจากข้อมูลทดสอบแล้วจึงนำมาหาค่าเฉลี่ย ถ้าค่าเฉลี่ยของ $D_{rgb_1} < D_{rgb_2}$ แสดงว่าภาพที่ผ่านการปรับสีด้วยโมเดลมีความใกล้เคียงกับภาพเป้าหมายมากกว่าภาพที่ปรับสีด้วยวิธี Poly Fit

เนื่องจากการทดลองสร้างตัวแบบแปลงค่าสีระหว่างอุปกรณ์แต่ละคู่จะได้ตัวแบบแปลงค่าสีเป็นจำนวนมาก และตัวแบบแต่ละตัวนั้นให้ประสิทธิภาพในการแปลงค่าสีไม่เท่ากัน จึงได้ทำการสร้างกราฟสำหรับการเทียบประสิทธิภาพของตัวแบบหลายตัวกับวิธี Poly Fit โดยกราฟเปรียบเทียบนั้นเป็นกราฟสามมิติ แกน X เป็นค่าจำนวนโหนดใน hidden layer แกน Y เป็นค่าจำนวนชั้นของ hidden layer แกน Z เป็นค่า Euclidean Distance ระบายสีเขียวแทนค่า Euclidean Distance ของวิธี Poly Fit และจุดกลมแต่ละจุดแทนตัวแบบแปลงค่าสีแต่ละตัว

วิธีการประเมินผลจากกราฟทำได้โดยการสังเกตจุดวงกลมเทียบกับระบายสีเขียว หากจุดวงกลมใดอยู่ในระดับต่ำกว่าระบายสีเขียวตามแนวแกน Z แสดงให้เห็นว่าค่า Euclidean Distance จากตัวแบบต่ำกว่า Euclidean Distance จากวิธี Poly Fit ตัวแบบดังกล่าวจึงเป็นตัวแบบที่มีประสิทธิภาพดีกว่าวิธี Poly Fit


ตัวแบบแปลงค่าสีจาก iPad Mini 4 เป็น MotoC



รูปที่ 47 การเปรียบเทียบประสิทธิภาพของตัวแบบแปลงค่าสีจาก iPad Mini 4 เป็น MotoC กราฟด้านซ้ายทดสอบโดย Generate Set และกราฟด้านขวาทดสอบโดย Random Set




รูปที่ 48 เปรียบเทียบภาพที่ขยายข้อมูลโดยตัวแบบแปลงค่าสี iPadtoMotoC (A) ภาพต้นฉบับจาก iPad Mini 4 (B) ภาพเป้าหมายจาก MotoC (C) ภาพต้นฉบับที่แปลงค่าสีด้วยวิธี Poly Fit (D) ภาพต้นฉบับที่แปลงค่าสีด้วยตัวแบบแปลงค่าสี iPadtoMotoC



รูปที่ 49 เปรียบเทียบ Histogram จากภาพที่ขยายข้อมูลโดยตัวแบบแปลงค่าสี iPadtoMotoC (A) ภาพต้นฉบับจาก iPad Mini 4 (B) ภาพเป้าหมายจาก MotoC (C) ภาพต้นฉบับที่แปลงค่าสีด้วยวิธี Poly Fit (D) ภาพต้นฉบับที่แปลงค่าสีด้วยตัวแบบแปลงค่าสี iPadtoMotoC


ตัวแบบแปลงค่าสีจาก MotoC เป็น iPad Mini 4



รูปที่ 50 การเปรียบเทียบประสิทธิภาพของตัวแบบแปลงค่าสีจาก MotoC เป็น iPad Mini 4 กราฟด้านซ้ายทดสอบโดย Generate Set และกราฟด้านขวาทดสอบโดย Random Set




รูปที่ 51 เปรียบเทียบภาพที่ขยายข้อมูลโดยตัวแบบแปลงค่าสี MotoCtoiPad (A) ภาพต้นฉบับจาก MotoC (B) ภาพเป้าหมายจาก iPad Mini 4 (C) ภาพต้นฉบับที่แปลงค่าสีด้วยวิธี Poly Fit (D) ภาพต้นฉบับที่แปลงค่าสีด้วยตัวแบบแปลงค่าสี MotoCtoiPad



รูปที่ 52 เปรียบเทียบ Histogram จากภาพที่ขยายข้อมูลโดยตัวแบบแปลงค่าสี MotoCtoiPad (A) ภาพต้นฉบับจาก MotoC (B) ภาพเป้าหมายจาก iPad Mini 4 (C) ภาพต้นฉบับที่แปลงค่าสีด้วยวิธี Poly Fit (D) ภาพต้นฉบับที่แปลงค่าสีด้วยตัวแบบแปลงค่าสี MotoCtoiPad


ตัวแบบแปลงค่าสีจาก iPad Mini 4 เป็น Galaxy S8



รูปที่ 53 การเปรียบเทียบประสิทธิภาพของตัวแบบแปลงค่าสีจาก iPad Mini 4 เป็น Galaxy S8 กราฟด้านซ้ายทดสอบโดย Generate Set และกราฟด้านขวาทดสอบโดย Random Set

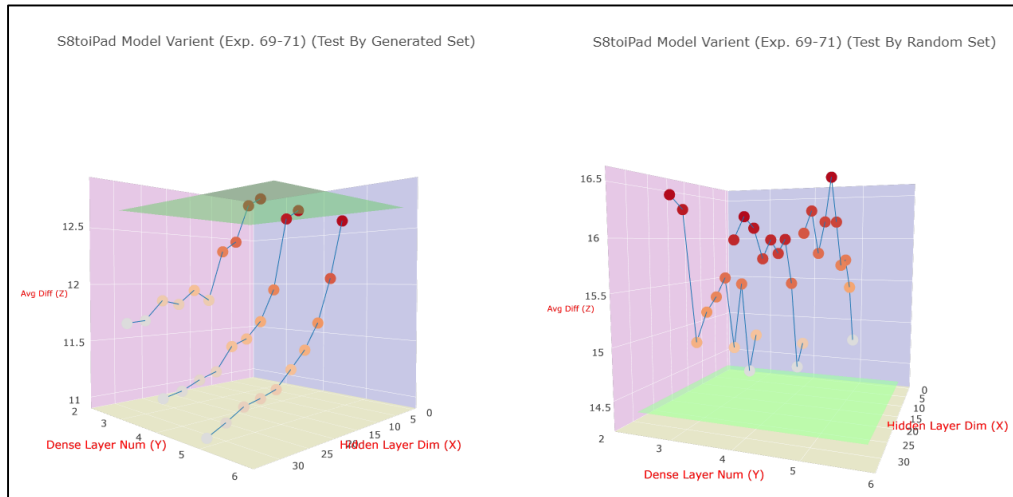


รูปที่ 54 เปรียบเทียบภาพที่ขยายข้อมูลโดยตัวแบบแปลงค่าสี iPadtoS8 (A) ภาพต้นฉบับจาก iPad Mini 4 (B) ภาพเป้าหมายจาก Galaxy S8 (C) ภาพต้นฉบับที่แปลงค่าสีด้วยวิธี Poly Fit (D) ภาพต้นฉบับที่แปลงค่าสีด้วยตัวแบบแปลงค่าสี iPadtoS8



รูปที่ 55 เปรียบเทียบ Histogram จากภาพที่ขยายข้อมูลโดยตัวแบบแปลงค่าสี iPadtoS8 (A) ภาพต้นฉบับจาก iPad Mini 4 (B) ภาพเป้าหมายจาก Galaxy S8 (C) ภาพต้นฉบับที่แปลงค่าสีด้วยวิธี Poly Fit (D) ภาพต้นฉบับที่แปลงค่าสีด้วยตัวแบบแปลงค่าสี iPadtoS8


ตัวแบบแปลงค่าสีจาก Galaxy S8 เป็น iPad Mini 4



รูปที่ 56 การเปรียบเทียบประสิทธิภาพของตัวแบบแปลงค่าสีจาก Galaxy S8 เป็น iPad Mini 4
กราฟด้านซ้ายทดสอบโดย Generate Set และกราฟด้านขวาทดสอบโดย Random Set




รูปที่ 57 เปรียบเทียบภาพที่ขยายข้อมูลโดยตัวแบบแปลงค่าสี S8toiPad (A) ภาพต้นฉบับจาก Galaxy S8 (B) ภาพเป้าหมายจาก iPad Mini 4 (C) ภาพต้นฉบับที่แปลงค่าสีด้วยวิธี Poly Fit (D) ภาพต้นฉบับที่แปลงค่าสีด้วยตัวแบบแปลงค่าสี S8toiPad



รูปที่ 58 เปรียบเทียบ Histogram จากภาพที่ขยายข้อมูลโดยตัวแบบแปลงค่าสี S8toiPad (A) ภาพต้นฉบับจาก Galaxy S8 (B) ภาพเป้าหมายจาก iPad Mini 4 (C) ภาพต้นฉบับที่แปลงค่าสีด้วยวิธี Poly Fit (D) ภาพต้นฉบับที่แปลงค่าสีด้วยตัวแบบแปลงค่าสี S8toiPad


ตัวแบบแปลงค่าสีจาก Galaxy S8 เป็น MotoC



รูปที่ 59 การเปรียบเทียบประสิทธิภาพของตัวแบบแปลงค่าสีจาก Galaxy S8 เป็น MotoC กราฟด้านซ้ายทดสอบโดย Generate Set และกราฟด้านขวาทดสอบโดย Random Set




รูปที่ 60 เปรียบเทียบภาพที่ขยายข้อมูลโดยตัวแบบแปลงค่าสี S8toMotoC (A) ภาพต้นฉบับจาก Galaxy S8 (B) ภาพเป้าหมายจาก MotoC (C) ภาพต้นฉบับที่แปลงค่าสีด้วยวิธี Poly Fit (D) ภาพต้นฉบับที่แปลงค่าสีด้วยตัวแบบแปลงค่าสี S8toMotoC



รูปที่ 61 เปรียบเทียบ Histogram จากภาพที่ขยายข้อมูลโดยตัวแบบแปลงค่าสี S8toMotoC (A) ภาพต้นฉบับจาก Galaxy S8 (B) ภาพเป้าหมายจาก MotoC (C) ภาพต้นฉบับที่แปลงค่าสีด้วยวิธี Poly Fit (D) ภาพต้นฉบับที่แปลงค่าสีด้วยตัวแบบแปลงค่าสี S8toMotoC


ตัวแบบแปลงค่าสีจาก MotoC เป็น Galaxy S8



รูปที่ 62 การเปรียบเทียบประสิทธิภาพของตัวแบบแปลงค่าสีจาก Galaxy S8 เป็น MotoC กราฟด้านซ้ายทดสอบโดย Generate Set และกราฟด้านขวาทดสอบโดย Random Set



รูปที่ 63 เปรียบเทียบภาพที่ขยายข้อมูลโดยตัวแบบแปลงค่าสี MotoCtoS8 (A) ภาพต้นฉบับจาก MotoC (B) ภาพเป้าหมายจาก Galaxy S8 (C) ภาพต้นฉบับที่แปลงค่าสีด้วยวิธี Poly Fit (D) ภาพต้นฉบับที่แปลงค่าสีด้วยตัวแบบแปลงค่าสี MotoCtoS8



รูปที่ 64 เปรียบเทียบ Histogram จากภาพที่ขยายข้อมูลโดยตัวแบบแปลงค่าสี MotoCtoS8 (A) ภาพต้นฉบับจาก MotoC (B) ภาพเป้าหมายจาก Galaxy S8 (C) ภาพต้นฉบับที่แปลงค่าสีด้วยวิธี Poly Fit (D) ภาพต้นฉบับที่แปลงค่าสีด้วยตัวแบบแปลงค่าสี MotoCtoS8

จากกราฟเปรียบเทียบทั้งหกตัวแบบกับวิธี Poly Fit ใน Generate Set และ Random Set นั้นพบว่า ตัวแบบทั้งหมดมีประสิทธิภาพในการปรับเทียบสีดีกว่าวิธี Poly Fit เมื่อใช้ข้อมูล Generate Set เป็นข้อมูลทดสอบ ในข้อมูล Random Set นั้นตัวแบบสี่ตัวทำหน้าที่ในการปรับเทียบสีได้ดีกว่าวิธี Poly Fit ส่วนอีกสองตัวแบบซึ่งได้แก่ MotoCtoiPad และ S8toiPad มีประสิทธิภาพไม่เท่าวิธี Poly Fit

ตารางที่ 8 สรุปผลการเปรียบเทียบประสิทธิภาพในการแปลงสีภาพระหว่างตัวแบบแปลงค่าสีทั้งหมดกับวิธี Poly Fit

Data \ Model	iPadtoMotoC	MotoCtoiPad	iPadtoS8	S8toiPad	S8toMotoC	MotoCtoS8
Generated	Win	Win	Win	Win	Win	Win
Random	Win	Lose	Win	Lose	Win	Win

หมายเหตุ Win หมายถึงมีตัวแบบใดตัวแบบหนึ่งในการทดลองที่มีประสิทธิภาพดีกว่าวิธี Poly Fit


และ Lose หมายถึงไม่มีตัวแบบใดในการทดลองที่มีประสิทธิภาพดีกว่าวิธี Poly Fit

5.3 การนำตัวแบบแปลงค่าสีมาใช้ในการขยายข้อมูลภาพจากฐานข้อมูล

ในส่วนนี้จะกล่าวถึงประสิทธิภาพของการนำตัวแบบแปลงค่าสีมาใช้ในการขยายข้อมูลจากฐานข้อมูลภาพที่ไม่ทราบที่มาของอุปกรณ์ถ่ายภาพและมีลักษณะแตกต่างกันสี่ฐานข้อมูล ได้แก่ (1) ฐานข้อมูล CIFAR-10 (2) ฐานข้อมูล CIFAR-100 (3) ฐานข้อมูล PascalVOC (4) ฐานข้อมูลภาพบาดแผล Medetec โดยในแต่ละฐานข้อมูลจะทำการวัดค่าความแม่นยำ (Accuracy) เปรียบเทียบกับวิธีการ PCA-jittering

5.3.1 ฐานข้อมูล CIFAR-10

ฐานข้อมูล CIFAR-10 เป็นฐานข้อมูลที่ประกอบด้วยภาพขนาด 32 * 32 พิกเซล จำนวน 60,000 ภาพ โดยแบ่งออกเป็น 10 หมวดหมู่ ได้แก่ เครื่องบิน, รถยนต์, นก, แมว, กวาง, สุนัข, กบ, ม้า, เรือ และ รถบรรทุก แต่ละหมวดหมู่มีภาพทั้งสิ้น 6,000 ภาพ ฐานข้อมูลมีการแบ่งภาพจำนวน 50,000 ภาพสำหรับใช้ฝึกสอนและ 10,000 ภาพสำหรับใช้ทดสอบ



รูปที่ 65 ตัวอย่างภาพทั้ง 10 หมวดหมู่จากฐานข้อมูล CIFAR-10

ผู้วิจัยได้สร้างโครงข่ายประสาทเทียมแบบคอนโวลูชันในรูปแบบ ResNet20 เพื่อใช้ในงานแบ่งประเภทภาพ (Classification) จากนั้นจึงนำภาพจากฐานข้อมูล CIFAR-10 มาขยายข้อมูลด้วยตัวแบบแปลงค่าสีทั้งหกตัวและด้วยวิธี PCA-jittering ต่อมาจึงนำภาพที่ผ่านการขยายข้อมูลทั้งหมดมาใช้ฝึกสอนโครงข่ายประสาทเทียมแบบ ResNet20 ที่ได้สร้างไว้ และวัดความแม่นยำด้วยชุดข้อมูลภาพทดสอบจำนวน 10,000 ภาพจากฐานข้อมูล CIFAR-10

การวัดประสิทธิภาพแบ่งออกได้เป็นการทดลองสามครั้ง โดยแต่ละครั้งมีรายละเอียดดังนี้

การทดลองครั้งที่ 1

ข้อมูลสำหรับฝึกสอนโครงข่ายประสาทเทียม

- | | |
|--|------------|
| 1. Base = Base data from CIFAR-10 DB | 50,000 ภาพ |
| 2. M1 = Data from CIFAR-10 Augment by S8toiPad Model | 50,000 ภาพ |
| 3. M2 = Data from CIFAR-10 Augment by MotoCtoS8 Model | 50,000 ภาพ |
| 4. M3 = Data from CIFAR-10 Augment by iPadtoMotoC Model | 50,000 ภาพ |
| 5. PCAJ = Data from CIFAR-10 Augment by PCA-jittering | 50,000 ภาพ |

ในการทดลองครั้งที่ 1 นี้ได้แบ่งออกเป็นการทดลองย่อยทั้งหมด 4 ครั้งเพื่อเปรียบเทียบประสิทธิภาพความแม่นยำของตัวแบบโครงข่ายประสาทเทียมแบบ ResNet20 ที่ฝึกสอนโดยข้อมูลต่างๆ กัน 4 แบบ ได้แก่ (1) ข้อมูลพื้นฐานจาก CIFAR-10 ที่ไม่ผ่านการขยายข้อมูล (2) ขยายข้อมูลโดยตัวแบบแปลงค่าสีสามตัว (3) ขยายข้อมูลด้วยวิธี PCA-jittering (4) ขยายข้อมูลโดยใช้ตัวแบบแปลงค่าสีร่วมกับวิธี PCA-jittering โดยแต่ละการทดลองย่อยมีพารามิเตอร์ดังตารางที่ 9


ตารางที่ 9 พารามิเตอร์สำหรับการทดลองแบ่งประเภทภาพในการทดลองที่ 1 ของฐานข้อมูล CIFAR-10

	Experiment	Experiment	Experiment	Experiment
	#1-1	#1-2	#1-3	#1-4

Train Epoch	50,000 (Base)	200,000 (Base+M1toM3)	100,000 (Base+PCAJ)	250,000 (Base+M1toM3+PCAJ)
Max Epochs	400	100	200	80
Total	20,000,000	20,000,000	20,000,000	20,000,000

ตารางที่ 10 ผลการทดลองแบ่งประเภทภาพการทดลองที่ 1 ในฐานข้อมูล CIFAR-10

	Experiment #1-1	Experiment #1-2	Experiment #1-3	Experiment #1-4
Train Data	Base	Base+M1toM3	Base + PCAJ	Base+M1toM3+ PCAJ
Accuracy	91.07 %	91.89 %	91.61 %	91.77 %



รูปที่ 66 กราฟเปรียบเทียบความแม่นยำของตัวแบบแบ่งประเภทภาพในการทดลองที่ 3 โดยชุดข้อมูลทดสอบจากฐานข้อมูล CIFAR-10 แกนนอนแสดงจำนวน Epoch และแกนตั้งแสดงค่าความแม่นยำ (Accuracy)

จากผลการทดลองครั้งที่ 1 จะเห็นได้ว่าความแม่นยำของตัวแบบโครงข่ายประสาทเทียม ResNet20 ที่ผ่านการฝึกสอนโดยภาพที่ขยายข้อมูลโดยตัวแบบแปลงค่าสีสามตัว ให้ความแม่นยำที่เหนือกว่าตัวแบบที่ฝึกสอนด้วยภาพจากฐานข้อมูลธรรมชาติ 0.82 % ให้ความแม่นยำที่เหนือกว่าตัวแบบที่ฝึกสอนด้วยภาพที่ขยายข้อมูลด้วยวิธี PCA-jittering 0.28 %

การทดลองครั้งที่ 2

ข้อมูลสำหรับฝึกสอนโครงข่ายประสาทเทียม

- | | |
|--|------------|
| 1. Base = Base data from CIFAR-10 DB | 50,000 ภาพ |
| 2. M1 = Data from CIFAR-10 Augment by S8toiPad Model | 50,000 ภาพ |
| 3. M2 = Data from CIFAR-10 Augment by MotoCtoS8 Model | 50,000 ภาพ |
| 4. M3 = Data from CIFAR-10 Augment by iPadtoMotoC Model | 50,000 ภาพ |
| 5. M4 = Data from CIFAR-10 Augment by MotoCtoS8 Model | 50,000 ภาพ |
| 6. M5 = Data from CIFAR-10 Augment by S8toiPad Model | 50,000 ภาพ |
| 7. M6 = Data from CIFAR-10 Augment by S8toMotoC Model | 50,000 ภาพ |
| 8. PCAJ = Data from CIFAR-10 Augment by PCA Jittering | 50,000 ภาพ |


ในการทดลองครั้งที่ 2 นี้ได้แบ่งออกเป็นการทดลองย่อยทั้งหมด 4 ครั้งเพื่อเปรียบเทียบประสิทธิภาพความแม่นยำของตัวแบบโครงข่ายประสาทเทียมแบบ ResNet20 ที่ฝึกสอนโดยข้อมูลต่างๆ กัน 4 แบบ ได้แก่ (1) ข้อมูลพื้นฐานจาก CIFAR-10 ที่ไม่ผ่านการขยายข้อมูล (2) ขยายข้อมูลโดยตัวแบบแปลงค่าสีหกตัว (3) ขยายข้อมูลด้วยวิธี PCA-jittering (4) ขยายข้อมูลโดยใช้ตัวแบบแปลงค่าสีร่วมกับวิธี PCA-jittering โดยแต่ละการทดลองย่อยมีพารามิเตอร์ดังตารางที่ 11

ตารางที่ 11 พารามิเตอร์สำหรับการทดลองแบ่งประเภทภาพในการทดลองที่ 2 ของฐานข้อมูล CIFAR-10

	Experiment #2-1	Experiment #2-2	Experiment #2-3	Experiment #2-4
Train Epoch	50,000 Base	350,000 (Base+M1toM6)	100,000 (Base+PCAJ)	400,000 (Base+M1toM6+PCAJ)
Max Epochs	1120	160	560	140
Total	56,000,000	56,000,000	56,000,000	56,000,000

ตารางที่ 12 ผลการทดลองแบ่งประเภทภาพการทดลองที่ 2 ในฐานข้อมูล CIFAR-10

	Experiment #2-1	Experiment #2-2	Experiment #2-3	Experiment #2-4
Train Data	Base	Base+M1toM6	Base+PCAJ	Base+M1toM6+ PCAJ
Accuracy	90.88 %	92.65 %	91.40 %	92.84 %



รูปที่ 67 กราฟเปรียบเทียบความแม่นยำของตัวแบบแบ่งประเภทภาพในการทดลองที่ 2 โดยชุดข้อมูลทดสอบจากฐานข้อมูล CIFAR-10 แกนนอนแสดงจำนวน Epoch และแกนตั้งแสดงค่าความแม่นยำ (Accuracy)

จากผลการทดลองครั้งที่ 2 จะเห็นได้ว่าความแม่นยำของตัวแบบโครงข่ายประสาทเทียม ResNet20 ที่ผ่านการฝึกสอนโดยภาพที่ขยายข้อมูลโดยตัวแบบแปลงค่าสีหกตัว ให้ความแม่นยำที่เหนือกว่าตัวแบบที่ฝึกสอนด้วยภาพจากฐานข้อมูลธรรมดา 1.77 % ให้ความแม่นยำที่เหนือกว่าตัวแบบที่ฝึกสอนด้วยภาพที่ขยายข้อมูลด้วยวิธี PCA-jittering 1.25 % และตัวแบบที่ฝึกด้วยข้อมูลรวมระหว่างภาพจากตัวแบบแปลงค่าสีและภาพจากวิธี PCA-jittering ให้ค่าความแม่นยำสูงสุดที่ 92.84 % เป็นการแสดงให้เห็นว่าสามารถนำวิธีการขยายข้อมูลทั้งสองแบบมาใช้ร่วมกันเพื่อให้ประสิทธิภาพดีขึ้นได้อีกด้วย

การทดลองครั้งที่ 3

ข้อมูลสำหรับฝึกสอนโครงข่ายประสาทเทียม


- | | |
|--|------------|
| 1. Base = Base data from CIFAR-10 DB | 50,000 ภาพ |
| 2. M1 = Data from CIFAR-10 Augment by S8toiPad Model | 50,000 ภาพ |
| 3. M2 = Data from CIFAR-10 Augment by MotoCtoS8 Model | 50,000 ภาพ |
| 4. M3 = Data from CIFAR-10 Augment by iPadtoMotoC Model | 50,000 ภาพ |
| 5. M4 = Data from CIFAR-10 Augment by MotoCtoS8 Model | 50,000 ภาพ |
| 6. M5 = Data from CIFAR-10 Augment by S8toiPad Model | 50,000 ภาพ |
| 7. M6 = Data from CIFAR-10 Augment by S8toMotoC Model | 50,000 ภาพ |
| 8. M7 = Data from CIFAR-10 Augment by iPadtoMotoC and MotoCtoS8 Model | 50,000 ภาพ |
| 9. M8 = Data from CIFAR-10 Augment by iPadtoS8 and S8toMotoC Model | 50,000 ภาพ |
| 10. M9 = Data from CIFAR-10 Augment by MotoCtoiPad and iPadtoS8 Model | 50,000 ภาพ |
| 11. M10 = Data from CIFAR-10 Augment by MotoCtoS8 and S8toiPad Model | 50,000 ภาพ |

12. **M11** = Data from CIFAR-10 Augment by S8toiPad and iPadtoMotoC Model
50,000 ภาพ
13. **M12** = Data from CIFAR-10 Augment by S8toMotoC and MotoCtoiPad Model
50,000 ภาพ
14. **PCAJ** = Data from CIFAR-10 Augment by PCA Jittering
50,000 ภาพ

ในการทดลองครั้งที่ 3 นี้ได้แบ่งออกเป็นการทดลองย่อยทั้งหมด 4 ครั้งเพื่อเปรียบเทียบประสิทธิภาพความแม่นยำของตัวแบบโครงข่ายประสาทเทียมแบบ ResNet20 ที่ฝึกสอนโดยข้อมูลต่างๆ กัน 4 แบบ ได้แก่ (1) ข้อมูลพื้นฐานจาก CIFAR-10 ที่ไม่ผ่านการขยายข้อมูล (2) ขยายข้อมูลโดยตัวแบบแปลงค่าสีหกดตัวรวมกับการขยายข้อมูลโดยใช้ตัวแบบแปลงค่าสีสองตัวต่อกัน (3) ขยายข้อมูลด้วยวิธี PCA-jittering (4) ขยายข้อมูลโดยใช้ตัวแบบแปลงค่าสีรวมกับวิธี PCA-jittering โดยแต่ละการทดลองย่อยมีพารามิเตอร์ดังตารางที่ 13

ตารางที่ 13 พารามิเตอร์สำหรับการทดลองแบ่งประเภทภาพในการทดลองที่ 3 ของฐานข้อมูล CIFAR-10


	Experiment #3-1	Experiment #3-2	Experiment #3-3	Experiment #3-4
Train	50,000	650,000	100,000	700,000
Epoch	Base	(Base+M1toM12)	(Base+PCAJ)	(Base+M1toM12+PCAJ)
Max Epochs	2730	210	1365	195
Total	136,500,000	136,500,000	136,500,000	136,500,000



รูปที่ 68 ตัวอย่างภาพจากฐานข้อมูล CIFAR-10 ที่ผ่านการขยายข้อมูล คอลัมน์ 1 แสดงภาพจากฐานข้อมูลที่ไม่ได้ผ่านการแปลงสี คอลัมน์ 2 ถึง 7 แสดงภาพที่แปลงสีโดยตัวแบบแปลงสีทั้งหกตัว คอลัมน์ 8 ถึง 13 แสดงภาพที่ผ่านการแปลงสีโดยใช้ตัวแบบแปลงสีสองตัว และคอลัมน์ที่สิบสี่แสดงภาพที่แปลงสีโดยวิธี PCA-jittering

ตารางที่ 14 ผลการทดลองแบ่งประเภทภาพการทดลองที่ 3 ในฐานข้อมูล CIFAR-10

	Experiment #3-1	Experiment #3-2	Experiment #3-3	Experiment #3-4
Train Data	Base	Base+M1toM12	Base+PCAJ	Base+M1toM12+PCAJ
Accuracy	91.15 %	92.89 %	91.84 %	92.62 %



รูปที่ 69 กราฟเปรียบเทียบความแม่นยำของตัวแบบแบ่งประเภทภาพในการทดลองที่ 3 โดยชุดข้อมูลทดสอบจากฐานข้อมูล CIFAR-10 แกนนอนแสดงจำนวน Epoch และแกนตั้งแสดงค่าความแม่นยำ (Accuracy)

จากผลการทดลองครั้งที่ 3 จะเห็นได้ว่าความแม่นยำของตัวแบบโครงข่ายประสาทเทียม ResNet20 ที่ผ่านการฝึกสอนโดยภาพที่ขยายข้อมูลโดยตัวแบบแปลงค่าสีหกตัวรวมกับภาพที่ขยายข้อมูลสองครั้ง ให้ความแม่นยำที่เหนือกว่าตัวแบบที่ฝึกสอนด้วยภาพจากฐานข้อมูลธรรมดา 1.74 % ให้ความแม่นยำที่เหนือกว่าตัวแบบที่ฝึกสอนด้วยภาพที่ขยายข้อมูลด้วยวิธี PCA-jittering 1.05 %

ตารางที่ 15 สรุปผลการทดลองแบ่งประเภทภาพจากฐานข้อมูล CIFAR-10 ด้วยตัวแบบการเรียนรู้เชิงลึก ResNet20 ที่ฝึกสอนโดยข้อมูลต่างๆ กันสี่แบบ

Ex No \ Train Data	Base	Base+M	Base+PCAJ	Base+M+PCAJ
Experiment #1 (3 Model)	91.07 %	91.89 %	91.61 %	91.77 %
Experiment #2 (6 Model)	90.88 %	92.65 %	91.40 %	92.84 %
Experiment #3 (12 Model)	91.15 %	92.89 %	91.84 %	92.62 %

5.3.2 ฐานข้อมูล CIFAR-100

ฐานข้อมูล CIFAR-100 เป็นฐานข้อมูลภาพที่มีความคล้ายคลึงกับฐานข้อมูล CIFAR-10 โดยมีข้อแตกต่างกันคือมีหมวดหมู่ของภาพทั้งหมด 100 หมวดหมู่ ซึ่งแต่ละหมวดหมู่ประกอบด้วยภาพจำนวน 600 ภาพ โดยทั้ง 100 หมวดหมู่สามารถจัดเป็นกลุ่มใหญ่ได้ 20 กลุ่ม ได้แก่ สัตว์เลี้ยงลูกด้วยนมที่อาศัยในน้ำ, ปลา, ดอกไม้, ภาชนะบรรจุอาหาร, ผักและผลไม้, เครื่องใช้ไฟฟ้าภายในบ้าน, เฟอร์นิเจอร์, แมลง, สัตว์กินเนื้อขนาดใหญ่, สิ่งก่อสร้างขนาดใหญ่, วิวทิวทัศน์ธรรมชาติ, สัตว์กินพืชขนาดใหญ่, สัตว์เลี้ยงลูกด้วยนมขนาดกลาง, สัตว์ไม่มีกระดูกสันหลังที่ไม่ใช่แมลง, ผู้คน, สัตว์เลื้อยคลาน, สัตว์เลี้ยงลูกด้วยนมขนาดเล็ก, ต้นไม้, ยานพาหนะแบบที่ 1 และแบบที่ 2

Superclass	Classes
aquatic mammals	beaver, dolphin, otter, seal, whale
fish	aquarium fish, flatfish, ray, shark, trout
flowers	orchids, poppies, roses, sunflowers, tulips
food containers	bottles, bowls, cans, cups, plates
fruit and vegetables	apples, mushrooms, oranges, pears, sweet peppers
household electrical devices	clock, computer keyboard, lamp, telephone, television
household furniture	bed, chair, couch, table, wardrobe
insects	bee, beetle, butterfly, caterpillar, cockroach
large carnivores	bear, leopard, lion, tiger, wolf
large man-made outdoor things	bridge, castle, house, road, skyscraper
large natural outdoor scenes	cloud, forest, mountain, plain, sea
large omnivores and herbivores	camel, cattle, chimpanzee, elephant, kangaroo
medium-sized mammals	fox, porcupine, possum, raccoon, skunk

รูปที่ 70 ตัวอย่างหมวดหมู่ภาพจากฐานข้อมูล CIFAR-100 ซึ่งมีหมวดหมู่ภาพกว่า 100 หมวดหมู่

ผู้วิจัยได้สร้างโครงข่ายประสาทเทียมแบบคอนโวลูชันในรูปแบบ ResNet32 เพื่อใช้ในงานแบ่งประเภทภาพ (Classification) จากนั้นจึงนำภาพจากฐานข้อมูล CIFAR-100 มาขยายข้อมูลด้วยตัวแบบแปลงค่าสีทั้งหกตัวและด้วยวิธี PCA-jittering ต่อมาจึงนำภาพที่ผ่านการขยายข้อมูลทั้งหมดมาใช้ฝึกสอนโครงข่ายประสาทเทียมแบบ ResNet32 ที่ได้สร้างไว้ และวัดความแม่นยำด้วยชุดข้อมูลภาพทดสอบจำนวน 10,000 ภาพของฐานข้อมูล CIFAR-100

การวัดประสิทธิภาพแบ่งออกได้เป็นการทดลองสามครั้ง โดยแต่ละครั้งมีรายละเอียดดังนี้

การทดลองครั้งที่ 1

ข้อมูลสำหรับฝึกสอนโครงข่ายประสาทเทียม

1. **Base** = Base data from CIFAR-100 DB 50,000 ภาพ
2. **M1** = Data from CIFAR-100 Augment by S8toiPad Model 50,000 ภาพ
3. **M2** = Data from CIFAR-100 Augment by MotoCtoS8 Model 50,000 ภาพ
4. **M3** = Data from CIFAR-100 Augment by iPadtoMotoC Model 50,000 ภาพ
5. **PCAJ** = Data from CIFAR-100 Augment by PCA-jittering 50,000 ภาพ


ในการทดลองครั้งที่ 1 นี้ได้แบ่งออกเป็นการทดลองย่อยทั้งหมด 4 ครั้งเพื่อเปรียบเทียบประสิทธิภาพความแม่นยำของตัวแบบโครงข่ายประสาทเทียมแบบ ResNet32 ที่ฝึกสอนโดยข้อมูลต่างๆ กัน 4 แบบ ได้แก่ (1) ข้อมูลพื้นฐานจาก CIFAR-100 ที่ไม่ผ่านการขยายข้อมูล (2) ขยายข้อมูลโดยตัวแบบแปลงค่าสีสามตัว (3) ขยายข้อมูลด้วยวิธี PCA-jittering (4) ขยายข้อมูลโดยใช้ตัวแบบแปลงค่าสีร่วมกับวิธี PCA-jittering โดยแต่ละการทดลองย่อยมีพารามิเตอร์ดังตารางที่ 16

ตารางที่ 16 พารามิเตอร์สำหรับการทดลองแบ่งประเภทภาพในการทดลองที่ 1 ของฐานข้อมูล CIFAR-100

	Experiment #1-1	Experiment #1-2	Experiment #1-3	Experiment #1-4
Train Epoch	50,000 (Base)	200,000 (Base+M1toM3)	100,000 (Base+PCAJ)	250,000 (Base+M1toM3+ PCAJ)
Max Epochs	800	200	400	160
Total	40,000,000	40,000,000	40,000,000	40,000,000

ตารางที่ 17 ผลการทดลองแบ่งประเภทภาพการทดลองที่ 1 ในฐานข้อมูล CIFAR-100

	Experiment #1-1	Experiment #1-2	Experiment #1-3	Experiment #1-4
Train Data	Base	Base+M1toM3	Base+PCAJ	Base+M1toM3+PCAJ
Accuracy	68.45 %	69.10 %	68.46 %	69.08 %



รูปที่ 71 กราฟเปรียบเทียบความแม่นยำของตัวแบบแบ่งประเภทภาพในการทดลองที่ 1 โดยชุดข้อมูลทดสอบจากฐานข้อมูล CIFAR-100 แกนนอนแสดงจำนวน Epoch และแกนตั้งแสดงค่าความแม่นยำ (Accuracy)

จากผลการทดลองครั้งที่ 1 จะเห็นได้ว่าความแม่นยำของตัวแบบโครงข่ายประสาทเทียม ResNet32 ที่ผ่านการฝึกสอนโดยภาพที่ขยายข้อมูลโดยตัวแบบแปลงค่าสีสามตัว ให้ความแม่นยำที่เหนือกว่าตัวแบบที่ฝึกสอนด้วยภาพจากฐานข้อมูลธรรมดา 0.65 % ให้ความแม่นยำที่เหนือกว่าตัวแบบที่ฝึกสอนด้วยภาพที่ขยายข้อมูลด้วยวิธี PCA-jittering 0.64 %

การทดลองครั้งที่ 2

ข้อมูลสำหรับฝึกสอนโครงข่ายประสาทเทียม

1. **Base** = Base data from CIFAR-100 DB

50,000 ภาพ

2. **M1** = Data from CIFAR-100 Augment by S8toiPad Model 50,000 ภาพ
3. **M2** = Data from CIFAR-100 Augment by MotoCtoS8 Model 50,000 ภาพ
4. **M3** = Data from CIFAR-100 Augment by iPadtoMotoC Model 50,000 ภาพ
5. **M4** = Data from CIFAR-100 Augment by MotoCtoS8 Model 50,000 ภาพ
6. **M5** = Data from CIFAR-100 Augment by S8toiPad Model 50,000 ภาพ
7. **M6** = Data from CIFAR-100 Augment by S8toMotoC Model 50,000 ภาพ
8. **PCAJ** = Data from CIFAR-100 Augment by PCA Jittering 50,000 ภาพ


ในการทดลองครั้งที่ 2 นี้ได้แบ่งออกเป็นกรทดลองย่อยทั้งหมด 4 ครั้งเพื่อเปรียบเทียบประสิทธิภาพความแม่นยำของตัวแบบโครงข่ายประสาทเทียมแบบ ResNet32 ที่ฝึกสอนโดยข้อมูลต่างๆ กัน 4 แบบ ได้แก่ (1) ข้อมูลพื้นฐานจาก CIFAR-100 ที่ไม่ผ่านการขยายข้อมูล (2) ขยายข้อมูลโดยตัวแบบแปลงค่าสีหกตัว (3) ขยายข้อมูลด้วยวิธี PCA-jittering (4) ขยายข้อมูลโดยใช้ตัวแบบแปลงค่าสีร่วมกับวิธี PCA-jittering โดยแต่ละการทดลองย่อยมีพารามิเตอร์ดังนี้

ตารางที่ 18 พารามิเตอร์สำหรับการทดลองแบ่งประเภทภาพในการทดลองที่ 2 ของฐานข้อมูล CIFAR-100

	Experiment #2-1	Experiment #2-2	Experiment #2-3	Experiment #2-4
Train Epoch	50,000	350,000	100,000	400,000
	Base	(Base+M1toM6)	(Base+PCAJ)	(Base+M1toM6+PCAJ)
Max Epochs	1120	160	560	140
Total	56,000,000	56,000,000	56,000,000	56,000,000

ตารางที่ 19 ผลการทดลองแบ่งประเภทภาพการทดลองที่ 2 ในฐานข้อมูล CIFAR-100

	Experiment #2-1	Experiment #2-2	Experiment #2-3	Experiment #2-4
Train Data	Base	Base+M1toM6	Base+PCAJ	Base+M1toM6+ PCAJ
Accuracy	67.71 %	69.27 %	67.85 %	69.92 %



รูปที่ 72 กราฟเปรียบเทียบความแม่นยำของตัวแบบแบ่งประเภทภาพในการทดลองที่ 2 โดยชุดข้อมูลทดสอบจากฐานข้อมูล CIFAR-100 แกนนอนแสดงจำนวน Epoch และแกนตั้งแสดงค่าความแม่นยำ (Accuracy)

จากผลการทดลองครั้งที่ 2 จะเห็นได้ว่าความแม่นยำของตัวแบบโครงข่ายประสาทเทียม ResNet32 ที่ผ่านการฝึกสอนโดยภาพที่ขยายข้อมูลโดยตัวแบบแปลงค่าสีหกตัว ให้ความแม่นยำที่เหนือกว่าตัวแบบที่ฝึกสอนด้วยภาพจากฐานข้อมูลธรรมดา 1.56 % ให้ความแม่นยำที่เหนือกว่าตัวแบบที่ฝึกสอนด้วยภาพที่ขยายข้อมูลด้วยวิธี PCA-jittering 1.42 % และตัวแบบที่ฝึกด้วยข้อมูลรวมระหว่างภาพจากตัวแบบแปลงค่าสีและภาพจากวิธี PCA-jittering ให้ค่าความแม่นยำสูงสุดที่ 69.92 % เป็นการแสดงให้เห็นว่าสามารถนำวิธีการขยายข้อมูลทั้งสองแบบมาใช้ร่วมกันเพื่อให้ประสิทธิภาพดีขึ้นได้อีกด้วย

การทดลองครั้งที่ 3

ข้อมูลสำหรับฝึกสอนโครงข่ายประสาทเทียม

- | | |
|---|------------|
| 1. Base = Base data from CIFAR-100 DB | 50,000 ภาพ |
| 2. M1 = Data from CIFAR-100 Augment by S8toiPad Model | 50,000 ภาพ |
| 3. M2 = Data from CIFAR-100 Augment by MotoCtoS8 Model | 50,000 ภาพ |
| 4. M3 = Data from CIFAR-100 Augment by iPadtoMotoC Model | 50,000 ภาพ |
| 5. M4 = Data from CIFAR-100 Augment by MotoCtoS8 Model | 50,000 ภาพ |
| 6. M5 = Data from CIFAR-100 Augment by S8toiPad Model | 50,000 ภาพ |
| 7. M6 = Data from CIFAR-100 Augment by S8toMotoC Model | 50,000 ภาพ |
| 8. M7 = Data from CIFAR-100 Augment by iPadtoMotoC and MotoCtoS8 Model | 50,000 ภาพ |
| 9. M8 = Data from CIFAR-100 Augment by iPadtoS8 and S8toMotoC Model | 50,000 ภาพ |
| 10. M9 = Data from CIFAR-100 Augment by MotoCtoiPad and iPadtoS8 Model | 50,000 ภาพ |
| 11. M10 = Data from CIFAR-100 Augment by MotoCtoS8 and S8toiPad Model | 50,000 ภาพ |
| 12. M11 = Data from CIFAR-100 Augment by S8toiPad and iPadtoMotoC Model | 50,000 ภาพ |
| 13. M12 = Data from CIFAR-100 Augment by S8toMotoC and MotoCtoiPad Model | 50,000 ภาพ |
| 14. PCAJ = Data from CIFAR-100 Augment by PCA Jittering | 50,000 ภาพ |


ในการทดลองครั้งที่ 3 นี้ได้แบ่งออกเป็นการทดลองย่อยทั้งหมด 4 ครั้งเพื่อเปรียบเทียบประสิทธิภาพของตัวแบบโครงข่ายประสาทเทียมแบบ ResNet32 ที่ฝึกสอนโดยข้อมูลต่างๆ กัน 4

แบบ ได้แก่ (1) ข้อมูลพื้นฐานจาก CIFAR-100 ที่ไม่ผ่านการขยายข้อมูล (2) ขยายข้อมูลโดยตัวแบบแปลงค่าสีหกตัวรวมกับการขยายข้อมูลโดยใช้ตัวแบบแปลงค่าสีสองตัวต่อกัน (3) ขยายข้อมูลด้วยวิธี PCA-jittering (4) ขยายข้อมูลโดยใช้ตัวแบบแปลงค่าสีร่วมกับวิธี PCA-jittering โดยแต่ละการทดลองย่อยมีพารามิเตอร์ดังตารางที่ 20

ตารางที่ 20 พารามิเตอร์สำหรับการทดลองแบ่งประเภทภาพในการทดลองที่ 3 ของฐานข้อมูล CIFAR-100

	Experiment #3-1	Experiment #3-2	Experiment #3-3	Experiment #3-4
Train Epoch	50,000 Base	650,000 (Base+M1toM12)	100,000 (Base+PCAJ)	700,000 (Base+M1toM12+PCAJ)
Max Epochs	2730	210	1365	195
Total	136,500,000	136,500,000	136,500,000	136,500,000






รูปที่ 73 ตัวอย่างภาพจากฐานข้อมูล CIFAR-100 ที่ผ่านการขยายข้อมูล คอลัมน์ 1 แสดงภาพจากฐานข้อมูลที่ไม่ได้ผ่านการแปลงสี คอลัมน์ 2 ถึง 7 แสดงภาพที่แปลงสีโดยตัวแบบแปลงสีทั้งหมด คอลัมน์ 8 ถึง 13 แสดงภาพที่ผ่านการแปลงสีโดยใช้ตัวแบบแปลงสีสองตัว

ตารางที่ 21 ผลการทดลองแบ่งประเภทภาพการทดลองที่ 3 ในฐานข้อมูล CIFAR-100

	Experiment #3-1	Experiment #3-2	Experiment #3-3	Experiment #3-4
Train Data	Base	Base+M1toM12	Base+PCAJ	Base+M1toM12+PCAJ
Accuracy	68.01 %	69.98 %	68.33 %	69.58 %



รูปที่ 74 กราฟเปรียบเทียบความแม่นยำของตัวแบบแบ่งประเภทภาพในการทดลองที่ 3 โดยชุดข้อมูลทดสอบจากฐานข้อมูล CIFAR-100 แกนนอนแสดงจำนวน Epoch และแกนตั้งแสดงค่าความแม่นยำ (Accuracy)

จากผลการทดลองครั้งที่ 3 จะเห็นได้ว่าความแม่นยำของตัวแบบโครงข่ายประสาทเทียม ResNet20 ที่ผ่านการฝึกสอนโดยภาพที่ขยายข้อมูลโดยตัวแบบแปลงค่าสีหกตัวรวมกับภาพที่ขยายข้อมูลสองครั้ง ให้ความแม่นยำที่เหนือกว่าตัวแบบที่ฝึกสอนด้วยภาพจากฐานข้อมูลธรรมดา 1.97 % ให้ความแม่นยำที่เหนือกว่าตัวแบบที่ฝึกสอนด้วยภาพที่ขยายข้อมูลด้วยวิธี PCA-jittering 1.65 %

ตารางที่ 22 สรุปผลการทดลองแบ่งประเภทภาพจากฐานข้อมูล CIFAR-100 ด้วยตัวแบบการเรียนรู้เชิงลึก ResNet32 ที่ฝึกสอนโดยข้อมูลต่างๆ กันสี่แบบ

Ex No \ Train Data	Base	Base+M	Base+PCAJ	Base+M+PCAJ
Experiment #1 (3 Model)	68.45 %	69.10%	68.46%	69.08%
Experiment #2 (6 Model)	67.71 %	69.27%	67.85%	69.92%
Experiment #3 (12 Model)	68.01%	69.98%	68.33%	69.58%

5.3.3 ฐานข้อมูล Pascal VOC

ฐานข้อมูล Pascal VOC (Pascal Visual Object Classes Challenge) เป็นฐานข้อมูลภาพที่มีจุดมุ่งหมายในการเป็นฐานข้อมูลมาตรฐานสำหรับการวัดประสิทธิภาพของงานด้านการจำแนกวัตถุ และเป็นตัวกลางในการเปรียบเทียบประสิทธิภาพระหว่างวิธีการรู้จำวัตถุที่ต่างกันไป ผู้วิจัยจึงได้เลือกฐานข้อมูลดังกล่าวมาใช้ทดสอบประสิทธิภาพของตัวแบบแปลงค่าสีในงานด้านการจำแนกวัตถุภายในภาพ


ฐานข้อมูล Pascal VOC นั้นแบ่งออกเป็นหลายเวอร์ชันด้วยกัน โดยเวอร์ชันที่นำมาใช้ในงานวิจัยนี้เป็นเวอร์ชัน 2012 ซึ่งเป็นเวอร์ชันใหม่สุด ประกอบด้วยรูปภาพทั้งหมด 11,530 ภาพที่มีขนาดต่างกัน โดยมีประเภทวัตถุสำหรับการรู้จำทั้งหมด 20 ประเภท ได้แก่ เครื่องบิน, จักรยาน, เรือ, ขวดแก้ว, รถบัส, รถยนต์, แมว, แก้ว, ทีวี, โต๊ะอาหาร, สุนัข, ม้า, รถจักรยานยนต์, บุคคล, หม้อ, ต้นไม้, เกษะ, รถไฟ และโทรทัศน์ โดยโมเดลมีหน้าที่จำแนกวัตถุที่พบโดยใช้การแต้มนสีที่เป็นตัวแทนของประเภทนั้นลงในบริเวณที่โมเดลจำแนกว่าเป็นวัตถุ ดังในรูปที่ 75



รูปที่ 75 ตัวอย่างการ Segmentation ภาพจากฐานข้อมูล PascalVOC โดยโมเดลจำแนกวัตถุ

สำหรับการวัดประสิทธิภาพนั้นจะใช้ค่า IoU หรือ Intersection over Union (IoU) ซึ่งคำนวณได้โดยนำภาพ Ground Truth และ Prediction มาซ้อนกัน และนำบริเวณที่ Intersect

ด้วยบริเวณที่ Union กันของวัตถุแต่ละประเภท โดยหาค่า IoU ใกล้เคียงหนึ่งมากเท่าไรแสดงว่า โมเดลสามารถจำแนกวัตถุได้แม่นยำใกล้เคียงกับความเป็นจริงมากขึ้น



รูปที่ 76 ตัวอย่างการคำนวณค่า IoU

ผู้วิจัยได้สร้างโครงข่ายประสาทเทียมแบบคอนโวลูชันในรูปแบบ DeepLabV3+ เพื่อใช้ในงานจำแนกวัตถุ (Segmentation) จากนั้นจึงนำภาพจากฐานข้อมูล PascalVOC มาขยายข้อมูลด้วยตัวแบบแปลงค่าสีทั้งหกตัวและด้วยวิธี PCA-jittering ต่อมาจึงนำภาพที่ผ่านการขยายข้อมูลทั้งหมดมาใช้ฝึกสอนโครงข่ายประสาทเทียมแบบ DeepLabV3+ ที่ได้สร้างไว้ และวัดความแม่นยำด้วยชุดข้อมูลภาพทดสอบจำนวน 1,449 ภาพของฐานข้อมูล PascalVOC

ข้อมูลสำหรับฝึกสอนโครงข่ายประสาทเทียม

- | | |
|---|------------|
| 1. Base = Base data from PascalVOC DB | 10,582 ภาพ |
| 2. M1 = Data from PascalVOC Augment by S8toiPad Model | 10,582 ภาพ |
| 3. M2 = Data from PascalVOC Augment by MotoCtoS8 Model | 10,582 ภาพ |
| 4. M3 = Data from PascalVOC Augment by iPadtoMotoC Model | 10,582 ภาพ |

5. **M4** = Data from PascalVOC Augment by MotoCtoS8 Model 10,582 ภาพ
6. **M5** = Data from PascalVOC Augment by S8toiPad Model 10,582 ภาพ
7. **M6** = Data from PascalVOC Augment by S8toMotoC Model 10,582 ภาพ
8. **PCAJ** = Data from PascalVOC Augment by PCA Jittering 10,582 ภาพ


การทดลองครั้งนี้ได้แบ่งออกเป็นการทดลองย่อยทั้งหมด 4 ครั้งเพื่อเปรียบเทียบประสิทธิภาพความแม่นยำของตัวแบบโครงข่ายประสาทเทียมแบบ DeepLabV3+ ที่ฝึกสอนโดยข้อมูลต่างๆ กัน 4 แบบ ได้แก่ (1) ข้อมูลพื้นฐานจาก PascalVOC ที่ไม่ผ่านการขยายข้อมูล (2) ขยายข้อมูลโดยตัวแบบแปลงค่าสีหกตัว (3) ขยายข้อมูลด้วยวิธี PCA-jittering (4) ขยายข้อมูลโดยใช้ตัวแบบแปลงค่าสีหกตัวร่วมกับวิธี PCA-jittering โดยแต่ละการทดลองย่อยมีพารามิเตอร์ดังตารางที่ 23

ตารางที่ 23 พารามิเตอร์สำหรับการทดลองจำแนกวัตถุในภาพของฐานข้อมูล PascalVOC

	Experiment #1-1	Experiment #1-2	Experiment #1-3	Experiment #1-4
Train Epoch	10,582	74,074	21,164	84,656
	Base	(Base+M1toM6)	(Base+PCAJ)	(Base+M1toM6+PCAJ)
Max Epochs	57	9	30	8
Total	≈ 600,000	≈ 600,000	≈ 600,000	≈ 600,000


ตารางที่ 24 ผลการทดลองจำแนกวัตถุในภาพจากฐานข้อมูล PascalVOC

	Experiment #1-1	Experiment #1-2	Experiment #1-3	Experiment #1-4
Train Data	Base	Base+M1toM6	Base+PCAJ	Base+M1toM6+ PCAJ
meanIoU	76.04 %	76.50 %	75.40 %	75.99 %



รูปที่ 77 กราฟเปรียบเทียบความแม่นยำของตัวแบบจำแนกวัตถุ โดยชุดข้อมูลทดสอบจากฐานข้อมูล PascalVOC แกนนอนแสดงจำนวน Steps และแกนตั้งแสดงค่าเฉลี่ยของ IoU





รูปที่ 78 เปรียบเทียบการจำแนกวัตถุโดยตัวแบบทั้งสี่ตัวจากการทดลองในรูปภาพตัวอย่างจาก
ฐานข้อมูล PascalVOC

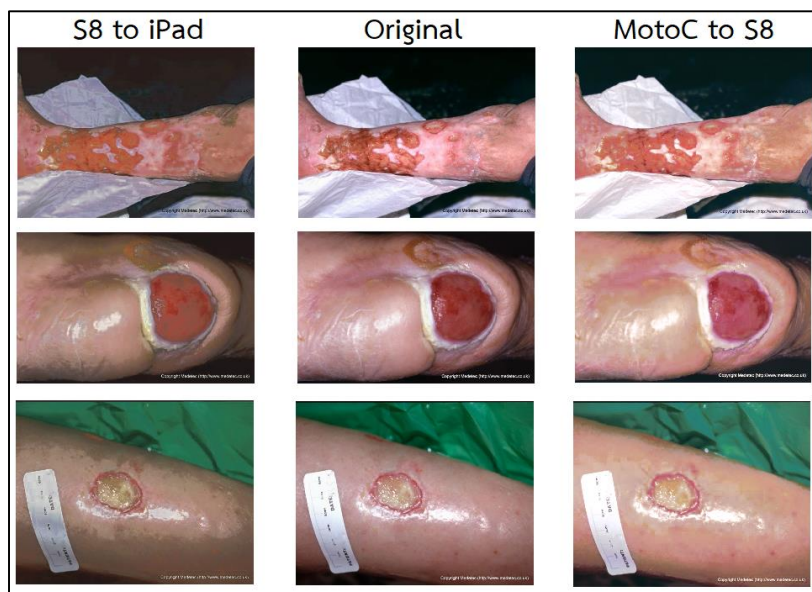
จากรูปที่ 78 จะเห็นได้อย่างชัดเจนว่าตัวแบบที่ผ่านการฝึกด้วยภาพที่ขยายข้อมูลด้วยตัวแบบแปลงค่าสีสามารถจำแนกวัตถุในภาพได้แม่นยำกว่าตัวแบบอื่นอย่างชัดเจนโดยในภาพที่ได้จากตัวแบบอื่นๆ นั้นจะปรากฏบริเวณสีม่วงในบริเวณสีชมพูเป็นการแสดงให้เห็นว่าตัวแบบเข้าใจว่าในบริเวณขาของนักปั่น (Person = สีชมพู) มีม้า (Horse = สีม่วง) ปรากฏอยู่ด้วยซึ่งไม่ถูกต้องตามความเป็นจริงแต่อย่างใด

5.3.4 ฐานข้อมูลภาพบาดแผล Medetec

ในส่วนนี้จะเป็นการนำตัวแบบแปลงค่าสีมาใช้ในสถานะการที่ต้องการจำแนกพื้นที่บาดแผลออกจากส่วนที่เหลือของภาพบาดแผลโดยการใช้ Pixel Classification ในสถานะการนี้ผู้วิจัยได้ใช้ตัวแบบแปลงค่าสีเพื่อขยายข้อมูลภาพ จากนั้นจึงวัดประสิทธิภาพของการแบ่งพื้นที่บาดแผลเพื่อตรวจสอบประสิทธิภาพของวิธีการขยายข้อมูลที่เสนอในงานวิจัย

ผู้วิจัยได้สร้างชุดข้อมูลการฝึกสอนโครงข่ายประสาทเทียมสองชุด ชุดแรกประกอบด้วยภาพบาดแผลที่เป็นต้นฉบับจากฐานข้อมูลของ Medetec ชุดที่สองเป็นการรวมชุดข้อมูลชุดแรกกับภาพที่ผ่านการขยายข้อมูลโดยใช้ตัวแบบแปลงค่าสีจาก MotoC เป็น Galaxy S8 และ Galaxy S8 ไปเป็น iPad Mini 4 ทำให้ขนาดข้อมูลชุดที่สองมากกว่าชุดแรกสามเท่า

รูปที่ 79 แสดงการเปรียบเทียบระหว่างภาพที่ผ่านการขยายข้อมูลกับภาพต้นฉบับ จะสังเกตเห็นได้ว่าสีของภาพทั้งหมดดูสมจริงแม้ว่าภาพต้นฉบับจะไม่ได้มาจาก Galaxy S8 iPad Mini 4 หรือ MotoC แต่อย่างใด เป็นการแสดงให้เห็นว่าวิธีการที่นำเสนอสามารถนำไปใช้แม้ในขณะที่ภาพต้นฉบับไม่ได้รับการบันทึกโดยอุปกรณ์ที่ใช้ในการฝึกอบรมแบบจำลอง เมื่อข้อมูลได้รับการรวบรวมแล้วผู้วิจัยจึงนำชุดข้อมูลแต่ละชุดไปใช้เพื่อฝึกตัวแบบโครงข่ายประสาทเทียมสำหรับการจำแนกพื้นที่บาดแผล จากนั้นจึงทำการเปรียบเทียบความถูกต้องของตัวแบบทั้งสอง



รูปที่ 79 เปรียบเทียบภาพบาดแผลจากฐานข้อมูล Medetec กับภาพที่ผ่านการขยายข้อมูลด้วยตัวแบบ S8toiPad และ MotoCtoS8

เป้าหมายของการเปรียบเทียบประสิทธิภาพคือเพื่อแสดงให้เห็นว่าการขยายข้อมูลภาพตัวแบบแปลงค่าสามารถปรับปรุงสมรรถนะในการจำแนกฟิสิกเซลบาดแผลของโครงข่ายประสาทเทียมได้ ด้วยเหตุนี้จึงแบ่งข้อมูลออกเป็นสามส่วนประกอบด้วยภาพต่อไปนี้ตามลำดับ: (A) ภาพต้นฉบับจากฐานข้อมูล (B) ภาพที่ผ่านการขยายข้อมูลโดยตัวแบบแปลงค่า MotoC ไปเป็น Galaxy S8 และ (C) ภาพที่ผ่านการขยายข้อมูลโดยตัวแบบแปลงค่า Galaxy S8 ไปเป็น iPad Mini 4

การวัดสมรรถนะทำได้โดยการวัดค่า Precision, Recall, F-measure และ Accuracy ของแบบจำลองที่ผ่านการฝึกจากข้อมูล (1) ในส่วน A และ (2) ข้อมูลทั้งสามส่วนรวมกัน ตารางที่ 25 แสดงรายละเอียดเกี่ยวกับประสิทธิภาพของแบบจำลองที่ผ่านการฝึกอบรมจากข้อมูลในส่วน A ในขณะที่ตารางที่ 26 แสดงสมรรถนะจากแบบจำลองที่ผ่านการฝึกอบรมมาจากข้อมูลทั้งสามส่วน ชุดทดสอบถูกแยกออกเป็น ส่วน ๆ เพื่อศึกษาประสิทธิภาพของการใช้ข้อมูลในแต่ละชุด

ตารางที่ 25 ผลการทดสอบตัวแบบที่ฝึกโดยใช้ข้อมูลเฉพาะในส่วน A (ข้อมูลต้นฉบับจากฐานข้อมูล) หน่วยทั้งหมดอยู่ในรูปแบบเปอร์เซ็นต์

Test set	Precision	Recall	F-measure	Accuracy
Part A	39.7	80.4	53.1	74.9
Part B	44.9	79.3	57.4	78.0
Part C	43.3	78.8	55.9	76.8
All combined	42.6	79.5	55.5	76.6

ตารางที่ 26 ผลการทดสอบของตัวแบบที่ได้รับการฝึกฝนโดยข้อมูลทั้งสามส่วน (รวมข้อมูลที่สร้างโดยการขยายข้อมูลด้วยตัวแบบแปลงค่าสี) ตัวเลขในวงเล็บแสดงว่ามีการเปลี่ยนแปลงประสิทธิภาพการทำงานอย่างไร หน่วยทั้งหมดเป็นเปอร์เซ็นต์

Test set	Precision	Recall	F-measure	Accuracy
Part A	48.60 (+8.95)	68.99 (-11.4)	57.03 (+3.91)	81.60 (+6.73)
Part B	55.34 (+10.4)	65.37 (-14.0)	59.94 (+2.58)	83.71 (+5.69)
Part C	80.54 (+37.3)	50.11 (-28.7)	61.78 (+5.92)	88.45 (+11.7)
All combined	61.50 (+18.9)	61.49 (-18.0)	59.58 (+4.13)	84.59 (+8.03)

ผลการทดลองแสดงให้เห็นว่าตัวแบบที่ได้รับการฝึกฝนมาพร้อมกับภาพที่ผ่านการขยายข้อมูลมีประสิทธิภาพมากกว่าตัวแบบที่ได้รับการฝึกฝนจากภาพต้นฉบับเพียงอย่างเดียวในเกือบทุกเมตริก รวมถึงส่วนที่ไม่มีภาพที่ผ่านการขยายข้อมูล จะสามารถสังเกตเห็นการเพิ่มประสิทธิภาพได้อย่างชัดเจนเมื่อโมเดลได้รับการทดสอบกับข้อมูลในส่วน B และ C ซึ่งแสดงให้เห็นว่าตัวแบบจะมีประสิทธิภาพระดับใดเมื่อทำงานกับภาพที่ถ่ายจากอุปกรณ์อื่น ๆ และประสิทธิภาพที่ดีขึ้นได้อย่างไรโดยไม่ต้องใช้อุปกรณ์อื่นโดยตรงในการถ่ายภาพสำหรับนำมาใช้เป็นข้อมูลในการฝึกฝนเพิ่มเติม ผู้วิจัยเชื่อว่าการเพิ่มข้อมูลสีใหม่นี้ยังสามารถประยุกต์ใช้กับแอปพลิเคชันที่หลากหลายได้โดยไม่จำกัดเพียงการจำแนกพื้นที่แผล

5.4 การทดสอบด้วยภาพจริงจากอุปกรณ์ถ่ายภาพที่ใช้ในการทดลอง

ในส่วนนี้จะกล่าวถึงการนำตัวแบบจำแนกประเภทภาพที่ถูกฝึกโดยข้อมูลที่ผ่านมาการขยายด้วยตัวแบบแปลงค่าสีมาทดสอบกับชุดข้อมูลทดสอบจากภาพจริงที่ถ่ายโดยกล้องที่ใช้ในการทดลอง ซึ่งได้แก่กล้องของ MotoC, Galaxy S8 และ iPad Mini 4

การสร้างชุดข้อมูลทดสอบเริ่มต้นจากการนำอุปกรณ์ถ่ายภาพทั้งสามไปถ่ายรูปสองหมวดหมู่ ได้แก่ รถยนต์และสุนัข ในบริเวณรอบๆ มหาวิทยาลัยศิลปากรวิทยาเขตพระราชวังสนามจันทร์ โดยแต่ละหมวดหมู่ถ่ายภาพจำนวน 100 ภาพ จากนั้นจึงทำการครอบตัดภาพทั้งหมดเพื่อกำจัดสิ่งรบกวนอื่นๆ เป้าหมายคือให้ภายในภาพมีสิ่งของเพียงหนึ่งชนิดเท่านั้น ลำดับต่อไปจึงทำการปรับขนาดภาพที่ผ่านการครอบตัดทั้งหมดให้เป็นขนาดเดียวกับภาพจากฐานข้อมูล CIFAR-10 ซึ่งคือขนาด 32 * 32 พิกเซล แล้วจึงจัดภาพออกเป็นข้อมูลทดสอบสี่ชุดดังนี้

1. **Base** = ภาพทดสอบจากฐานข้อมูล CIFAR-10
2. **MotoC Test** = ภาพทดสอบถ่ายโดย MotoC
3. **S8 Test** = ภาพทดสอบถ่ายโดย Galaxy S8
4. **iPad Test** = ภาพทดสอบถ่ายโดย iPad Mini 4

จากนั้นจึงฝึกสอนตัวแบบจำแนกประเภทภาพทั้งหมดสี่ตัวแบบโดยใช้ข้อมูลฝึกสอนที่แตกต่างกันสี่แบบ ได้แก่


1. **Base Model** = ฝึกสอนโดยข้อมูลจากฐานข้อมูล CIFAR-10 50,000 ภาพ
2. **MotoC Model** = ฝึกสอนโดยข้อมูลจาก CIFAR-10 รวมกับข้อมูลจาก CIFAR-10 ที่ผ่านการขยายข้อมูลด้วยตัวแบบแปลงค่าสี S8toMotoC และ iPadtoMotoC 150,000 ภาพ
3. **S8 Model** = ฝึกสอนโดยข้อมูลจาก CIFAR-10 รวมกับข้อมูลจาก CIFAR-10 ที่ผ่านการขยายข้อมูลด้วยตัวแบบแปลงค่าสี iPadtoS8 และ MotoCtoS8 150,000 ภาพ
4. **iPad Model** = ฝึกสอนโดยข้อมูลจาก CIFAR-10 รวมกับข้อมูลจาก CIFAR-10 ที่ผ่านการขยายข้อมูลด้วยตัวแบบแปลงค่าสี MotoCtoiPad และ S8toiPad 150,000 ภาพ

ตารางที่ 27 พารามิเตอร์สำหรับการทดลองด้วยภาพจริงจากอุปกรณ์ถ่ายภาพ

ExpNo\TrainBy	Base	Base + S8toMotoC + iPadtoMotoC	Base + MotoCtoiPad + S8toiPad	Base + iPadtoS8 + MotoCtoS8
Experiment #1	50,000 Images	150,000 Images	150,000 Images	150,000 Images
	300 Epoch	100 Epoch	100 Epoch	100 Epoch
	15 Millions	15 Millions	15 Millions	15 Millions

เมื่อได้ตัวแบบจำแนกประเภทภาพแล้วจึงนำตัวแบบแต่ละตัวไปทดสอบในข้อมูลทดสอบทุกๆ ชุดและวัดค่าความแม่นยำที่ได้

การฝึกสอนโดยใช้ข้อมูลพื้นฐานจาก CIFAR-10




รูปที่ 80 ความแม่นยำในการจำแนกประเภทภาพของตัวแบบที่ฝึกสอนโดยข้อมูลจากฐานข้อมูล CIFAR-10

จากผลการทดลองนำตัวแบบจำแนกรูปภาพที่ฝึกสอนโดยภาพจากฐานข้อมูล CIFAR-10 ที่ไม่ผ่านการขยายข้อมูลใดๆ มาทดสอบกับชุดข้อมูลทดสอบทั้งสี่ชุดพบว่าความแม่นยำในชุดข้อมูล Base ซึ่งเป็นข้อมูลทดสอบจาก CIFAR-10 ได้ความแม่นยำที่ 91.02% ในชุดข้อมูลภาพที่ถ่ายโดย iPad Mini

4 ได้ความแม่นยำที่ 58.64.94% ในชุดข้อมูลภาพที่ถ่ายโดย MotoC ได้ความแม่นยำที่ 57.59% และสุดท้ายในชุดข้อมูลภาพที่ถ่ายโดย Galaxy S8 ได้ความแม่นยำที่ 63.87%

การฝึกสอนด้วยข้อมูลจากตัวแบบแปลงค่าสีเป็น MotoC



รูปที่ 81 ความแม่นยำในการจำแนกประเภทภาพของตัวแบบที่ฝึกสอนโดยข้อมูลจาก CIFAR-10 รวมกับภาพที่ผ่านการขยายข้อมูลด้วยตัวแบบแปลงค่าสี S8toMotoC และ iPadtoMotoC


จากผลการทดลองนำตัวแบบจำแนกรูปภาพที่ฝึกสอนโดยข้อมูลจาก CIFAR-10 รวมกับข้อมูลจากตัวแบบแปลงค่าสีเป็น MotoC (S8toMotoC และ iPadtoMotoC) มาทดสอบกับชุดข้อมูลทดสอบทั้งสี่ชุดพบว่าความแม่นยำในชุดข้อมูล Base ซึ่งเป็นข้อมูลทดสอบจาก CIFAR-10 ได้ความแม่นยำที่ 91.75% เพิ่มขึ้น 0.8% เมื่อเทียบกับความแม่นยำของตัวแบบจำแนกรูปภาพที่ไม่ได้ผ่านการฝึกฝนด้วยภาพที่ขยายข้อมูล

ในชุดข้อมูลภาพที่ถ่ายโดย iPad Mini 4 ได้ความแม่นยำที่ 61.26% เพิ่มขึ้น 4.47% เมื่อเทียบกับตัวแบบจำแนกรูปภาพที่ไม่ได้ผ่านการฝึกฝนด้วยภาพที่ขยายข้อมูล ในชุดข้อมูลภาพที่ถ่ายโดย MotoC ได้ความแม่นยำที่ 59.16% เพิ่มขึ้น 2.73% เมื่อเทียบกับตัวแบบจำแนกรูปภาพที่ไม่ได้ผ่านการฝึกฝนด้วยภาพที่ขยายข้อมูล และสุดท้ายในชุดข้อมูลภาพที่ถ่ายโดย Galaxy S8 ได้ความแม่นยำที่

62.83% ลดลง 1.63% เมื่อเทียบกับตัวแบบจำแนกรูปภาพที่ไม่ได้ผ่านการฝึกฝนด้วยภาพที่ขยายข้อมูล

อย่างไรก็ตามเป็นที่น่าสังเกตว่าตัวแบบจำแนกรูปภาพที่ฝึกสอนโดยข้อมูลจากตัวแบบแปลงค่าสีเป็น MotoC นั้น ทำให้ความแม่นยำในภาพที่ถ่ายโดย iPad Mini4 เพิ่มขึ้นกว่าภาพจริงที่ถ่ายโดย MotoC

การฝึกสอนด้วยข้อมูลจากตัวแบบแปลงค่าสีเป็น Galaxy S8



รูปที่ 82 ความแม่นยำในการจำแนกประเภทภาพของตัวแบบที่ฝึกสอนโดยข้อมูลจาก CIFAR-10 รวมกับภาพที่ผ่านการขยายข้อมูลด้วยตัวแบบแปลงค่าสี iPadtoS8 และ MotoCtoS8


จากผลการทดลองนำตัวแบบจำแนกรูปภาพที่ฝึกสอนโดยข้อมูลจาก CIFAR-10 รวมกับข้อมูลจากตัวแบบแปลงค่าสีเป็น Galaxy S8 (iPadtoS8 และ MotoCtoS8) มาทดสอบกับชุดข้อมูลทดสอบ ทั้งสี่ชุดพบว่าความแม่นยำในชุดข้อมูล Base ซึ่งเป็นข้อมูลทดสอบจาก CIFAR-10 ได้ความแม่นยำที่ 91.84% เพิ่มขึ้น 0.9% เมื่อเทียบกับความแม่นยำของตัวแบบจำแนกรูปภาพที่ไม่ได้ผ่านการฝึกฝนด้วยภาพที่ขยายข้อมูล

ในชุดข้อมูลภาพที่ถ่ายโดย iPad Mini 4 ได้ความแม่นยำที่ 63.35% เพิ่มขึ้น 8.03% เมื่อเทียบกับตัวแบบจำแนกรูปภาพที่ไม่ได้ผ่านการฝึกฝนด้วยภาพที่ขยายข้อมูล ในชุดข้อมูลภาพที่ถ่ายโดย

MotoC ได้ความแม่นยำที่ 59.16% เพิ่มขึ้น 2.73% เมื่อเทียบกับตัวแบบจำแนกรูปภาพที่ไม่ได้ผ่านการฝึกฝนด้วยภาพที่ขยายข้อมูล และสุดท้ายในชุดข้อมูลภาพที่ถ่ายโดย Galaxy S8 ได้ความแม่นยำที่ 63.35% ลดลง 0.81% เมื่อเทียบกับตัวแบบจำแนกรูปภาพที่ไม่ได้ผ่านการฝึกฝนด้วยภาพที่ขยายข้อมูล

จากผลการทดลองจะเห็นได้ว่าตัวแบบจำแนกรูปภาพที่ผ่านการฝึกโดยข้อมูลจากตัวแบบแปลงค่าสีเป็น Galaxy S8 จะทำงานได้ดีทั้งในรูปที่ถ่ายโดย MotoC และ iPad Mini4

การฝึกสอนด้วยข้อมูลจากตัวแบบแปลงค่าสีเป็น iPad Mini 4




รูปที่ 83 ความแม่นยำในการจำแนกประเภทภาพของตัวแบบที่ฝึกสอนโดยข้อมูลจาก CIFAR-10 รวมกับภาพที่ผ่านการขยายข้อมูลด้วยตัวแบบแปลงค่าสี MotoCtoiPad และ S8toiPad

จากผลการทดลองนำตัวแบบจำแนกรูปภาพที่ฝึกสอนโดยข้อมูลจาก CIFAR-10 รวมกับข้อมูลจากตัวแบบแปลงค่าสีเป็น iPad Mini 4 (MotoCtoiPad และ S8toiPad) มาทดสอบกับชุดข้อมูลทดสอบทั้งสี่ชุดพบว่าความแม่นยำในชุดข้อมูล Base ซึ่งเป็นข้อมูลทดสอบจาก CIFAR-10 ได้ความแม่นยำที่ 91.74% เพิ่มขึ้น 0.79% เมื่อเทียบกับความแม่นยำของตัวแบบจำแนกรูปภาพที่ไม่ได้ผ่านการฝึกฝนด้วยภาพที่ขยายข้อมูล

ในชุดข้อมูลภาพที่ถ่ายโดย iPad Mini 4 ได้ความแม่นยำที่ 63.87% เพิ่มขึ้น 8.92% เมื่อเทียบกับตัวแบบจำแนกรูปภาพที่ไม่ได้ผ่านการฝึกฝนด้วยภาพที่ขยายข้อมูล ในชุดข้อมูลภาพที่ถ่ายโดย MotoC ได้ความแม่นยำที่ 56.54% ลดลง 1.82% เมื่อเทียบกับตัวแบบจำแนกรูปภาพที่ไม่ได้ผ่านการฝึกฝนด้วยภาพที่ขยายข้อมูล และสุดท้ายในชุดข้อมูลภาพที่ถ่ายโดย Galaxy S8 ได้ความแม่นยำที่ 70.16% เพิ่มขึ้น 9.85% เมื่อเทียบกับตัวแบบจำแนกรูปภาพที่ไม่ได้ผ่านการฝึกฝนด้วยภาพที่ขยายข้อมูล

อย่างไรก็ตามเป็นที่น่าสังเกตว่าตัวแบบจำแนกรูปภาพที่ฝึกสอนโดยข้อมูลจากตัวแบบแปลงค่าสีเป็น iPad Mini 4 นั้น ทำให้ความแม่นยำในภาพที่ถ่ายโดย Galaxy S8 เพิ่มมากขึ้นกว่าภาพจริงที่ถ่ายโดย iPad Mini 4



บทที่ 6

สรุปผลการดำเนินงานวิจัยและข้อเสนอแนะ

วิทยานิพนธ์นี้ได้เสนอวิธีการเรียนรู้แบบลึกสำหรับการแปลงสีจากภาพที่ถ่ายโดยกล้องถ่ายภาพตัวหนึ่งเพื่อสังเคราะห์เป็นภาพที่ถ่ายโดยกล้องอีกตัวหนึ่ง จากผลกาทดลองแสดงให้เห็นว่าความแม่นยำในการแปลงสีนั้นดีกว่าวิธีดั้งเดิมที่ใช้ในการปรับค่าสี ถึงแม้วิธีการที่นำเสนอจะสามารถนำมาใช้ปรับปรุงการปรับเทียบสีได้ แต่เป้าหมายหลักของงานวิจัยคือการนำเสนอวิธีการใหม่สำหรับการขยายข้อมูลภาพสี จึงได้ทำการเปรียบเทียบประสิทธิภาพในการขยายข้อมูลด้วยตัวแบบการเรียนรู้ที่นำเสนอเทียบกับวิธีอื่นที่เป็นที่นิยมใช้กันในฐานะข้อมูลภาพสีทั้งสามฐานข้อมูล

ผลการทดลองแสดงให้เห็นว่าวิธีการขยายข้อมูลด้วยตัวแบบการเรียนรู้เชิงลึกที่นำเสนอช่วยเพิ่มความแม่นยำได้มากกว่าวิธีการขยายข้อมูลเดิมทั้งในงานด้าน Classification จากฐานข้อมูล CIFAR-10 และ CIFAR-100 งาน Segmentation จากฐานข้อมูล PascalVOC และฐานข้อมูลภาพบาดแผล Medetec วิธีการขยายข้อมูลด้วยตัวแบบการเรียนรู้เชิงลึกนี้จะเป็นประโยชน์อย่างมากในการจัดเตรียมตัวแบบโครงข่ายประสาทเทียมเพื่อให้สามารถทำงานได้ดีในภาพจากกล้องอื่นๆ ที่ตัวแบบไม่เคยพบมาก่อน

วิธีการที่ผู้วิจัยนำเสนอจะมีความสำคัญขึ้นเรื่อยๆ เนื่องจากความสามารถในการมองเห็นด้วยคอมพิวเตอร์ (Computer Vision) ได้รับการติดตั้งอุปกรณ์เคลื่อนที่สำหรับผู้ใช้งานทั่วไป นอกจากนี้ความจำเป็นของเทคนิคที่นำเสนอจะกลายเป็นที่ชัดเจนเมื่อมีความต้องการวิธีที่มีประสิทธิภาพในการจัดการกับกล้องถ่ายภาพใหม่ซึ่งไม่สามารถจัดหาได้ในขณะที่ผู้ทดลองสร้างข้อมูลสำหรับการฝึกสอน นอกจากนี้ผู้วิจัยยังได้จำลองสถานการณ์ในชุดข้อมูลจากฐานข้อมูล CIFAR-10, CIFAR-100 และภาพบาดแผลเรื้อรังเพื่อแสดงถึงการนำวิธีการที่เสนอในงานวิจัยนี้ไปประยุกต์ใช้เพื่อเพิ่มความแม่นยำให้กับตัวแบบลักษณะต่างๆ

รายการอ้างอิง

- Adrian Ilie, G. W. (2005). *Ensuring color consistency across multiple cameras*. Paper presented at the The 10th IEEE International Conference on Computer Vision.
- Alex Krizhevsky, V. N., Geoffrey Hinton. (2018). The CIFAR-10 dataset. Retrieved from <https://www.cs.toronto.edu/~kriz/cifar.html>
- Jia Shijie, W. P., Jia Peiyi, Hu Siping,. (2017). *Research on data augmentation for image classification based on convolution neural networks*. Paper presented at the Chinese Automation Congress(CAC).
- Jiang-Jing Lv, X.-H. S., Jia-ShuiHuang, Xiang-Dong Zhou, Xi Zhou,. (2017). *Data augmentation for face recognition*. Paper presented at the Neurocomputing.





ประวัติผู้เขียน

ชื่อ-สกุล	ชนะไชย พุทธรักษา
วัน เดือน ปี เกิด	19 มกราคม 2537
สถานที่เกิด	อ. หาดใหญ่ จ.สงขลา
วุฒิการศึกษา	สำเร็จการศึกษาปริญญาวิทยาศาสตรบัณฑิต สาขาวิชาเทคโนโลยีสารสนเทศ มหาวิทยาลัยศิลปากร พ.ศ. 2559 อาจารย์ที่ปรึกษาวิทยานิพนธ์ อ.ดร. ภิญโญ แท้ประสาทสิทธิ์ GPA : 3.72 ศึกษาต่อระดับปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาเทคโนโลยีสารสนเทศ มหาวิทยาลัยศิลปากร อาจารย์ที่ปรึกษาวิทยานิพนธ์ อ.ดร. ภิญโญ แท้ประสาทสิทธิ์ GPA : 3.94
ที่อยู่ปัจจุบัน	55/1 ถ.พระยาศรีสุนทร ต.หน้าเมือง อ.เมือง จ.ฉะเชิงเทรา

