

การลดสัญญาฉบับรบกวนภาพชนิดเกาส์เขียนด้วยวิธีการเรียนรู้เชิงลึกและเส้นแบ่งระหว่างวัตถุกับพื้น
หลัง



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต
สาขาวิชาวิทยาศาสตร์คอมพิวเตอร์ ภาควิชาวิศวกรรมคอมพิวเตอร์
คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย
ปีการศึกษา 2561
ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

Image denoising for Gaussian noise using deep learning and edge feature



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

Department of Computer Engineering

Faculty of Engineering

Chulalongkorn University

Academic Year 2018

Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์	การลดสัญญาณรบกวนภาพชนิดเกาส์เซียนด้วยวิธีการเรียนรู้เชิงลึกและเส้นแบ่งระหว่างวัตถุกับพื้นหลัง
โดย	นายศุภกร ชูประภาวรรณ
สาขาวิชา	วิทยาศาสตร์คอมพิวเตอร์
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก	รองศาสตราจารย์ ดร.โชติรัตน์ รัตนามหัทธนะ

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้รับวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

..... คณบดีคณะวิศวกรรมศาสตร์
(ศาสตราจารย์ ดร.สุพจน์ เตชวรสินสกุล)

คณะกรรมการสอบวิทยานิพนธ์

..... ประธานกรรมการ
(อาจารย์ ดร.ดวงดาว วิชาดากุล)

..... อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก
(รองศาสตราจารย์ ดร.โชติรัตน์ รัตนามหัทธนะ)

..... กรรมการภายนอกมหาวิทยาลัย
(ดร.เหมวรรณ ศิวรักษ์)

CHULALONGKORN UNIVERSITY

ศุภกร ชูประภาวรรณ : การลดสัญญาณรบกวนภาพชนิดเกาส์เซียนด้วยวิธีการเรียนรู้เชิงลึกและเส้นแบ่งระหว่างวัตถุกับพื้นหลัง. (Image denoising for Gaussian noise using deep learning and edge feature) อ.ที่ปรึกษาหลัก : รศ. ดร.โชติรัตน์ รัตนามัทธนะ

การลดสัญญาณรบกวนภาพเป็นปัญหาพื้นฐานในงานด้านคอมพิวเตอร์วิชันและได้รับความสนใจในด้านงานวิจัยเป็นอย่างมากในช่วงหลายปีที่ผ่านมาเพื่อที่จะหาวิธีในการลดสัญญาณรบกวนภาพแบบต่าง ๆ โดยในงานวิทยานิพนธ์นี้มุ่งเน้นไปที่งานด้านการลดสัญญาณรบกวนภาพสำหรับสัญญาณรบกวนแบบเกาส์เซียน โดยในปัจจุบันการเรียนรู้เชิงลึกได้ถูกนำมาประยุกต์ใช้กับงานด้านการลดสัญญาณรบกวนภาพแต่ทว่ายังมีข้อจำกัดอยู่คือการเรียนรู้เชิงลึกจะสร้างสิ่งแปลกปลอมขึ้นมาบนภาพ วิทยานิพนธ์นี้เสนอวิธีการใช้การเรียนรู้เชิงลึกร่วมกับเส้นแบ่งระหว่างวัตถุกับพื้นหลัง โดยเส้นแบ่งระหว่างวัตถุกับพื้นหลังนั้นจะได้รับจากอัลกอริทึมแคนนี่ เอจ ดีเทกชัน (Canny edge detection) เพื่อให้โมเดลสามารถกำจัดสิ่งแปลกปลอมได้ สำหรับชุดข้อมูลที่ใช้ในงานวิจัยคือชุดข้อมูลภาพเบิร์กลีย์ 400 ภาพ (BSD400) สำหรับฝึกสอนโมเดลของผู้วิจัย และชุดข้อมูลทดสอบสำหรับทดสอบคือชุดข้อมูลภาพเบิร์กลีย์ 68 ภาพ (BSD68) และชุดข้อมูลภาพ 12 ภาพ (Set12) โดยจากการทดลองของผู้วิจัยบนชุดข้อมูลทดสอบที่มีระดับความเข้มข้นของสัญญาณรบกวนเกาส์เซียนที่ระดับ 15 25 และ 50 พบว่าโมเดลของผู้วิจัยสามารถทำประสิทธิผลได้ดีบนระดับความเข้มข้นที่ 15 และระดับความเข้มข้นที่ 25 แต่ทว่าบนระดับความเข้มข้นที่ 50 นั้นโมเดลของผู้วิจัยทำประสิทธิผลได้เทียบเท่ากับอัลกอริทึมอื่น และการลดสัญญาณรบกวนภาพจริงนั้นโมเดลของผู้วิจัยสามารถลดสัญญาณรบกวนภาพจริงได้ดีกว่าอัลกอริทึมอื่น

สาขาวิชา วิทยาศาสตร์คอมพิวเตอร์

ปีการศึกษา 2561

ลายมือชื่อนิสิต

ลายมือชื่อ อ.ที่ปรึกษาหลัก

6070325121 : MAJOR COMPUTER SCIENCE

KEYWORD: Deep Learning, Image Denoising, Edge feature

Supakorn Chupraphawan : Image denoising for Gaussian noise using deep learning and edge feature. Advisor: Assoc. Prof. CHOTIRAT RATANAMAHATANA, Ph.D.

Image denoising is a classical challenge in computer vision and has attracted a large amount of research in the past few decades in attempts to find new approaches to denoise various types of images. This thesis focuses on image denoising for Gaussian noise. While deep learning has been applied on image denoising nowadays, one of the limitations of deep learning is black artifacts on denoised images. This thesis proposes a new approach by applying a deep learning model with edge feature to denoise an image. Edge feature is extracted from Canny edge detection algorithm, which helps deep learning models understand features of noisy image and eliminate those black artifacts. BSD400 is used for training the model, and BSD68 and Set12 datasets are used for testing the model. The experiment results on Gaussian noise with sigma levels of 15, 25 and 50 demonstrate that the model outperforms other approaches at sigma levels of 15 and 25 while performing comparably with other approaches at sigma level of 50. Moreover, the proposed model also outperforms others in denoising real images.

Field of Study: Computer Science

Student's Signature

Academic Year: 2018

Advisor's Signature

กิตติกรรมประกาศ

ขอขอบพระคุณ อ. ดร.ดวงดาว วิชาดากุล และ ดร.เหมวรรณ ศิวรักษ์ ที่ให้เกียรติเป็นประธาน และกรรมการในการสอบวิทยานิพนธ์ของข้าพเจ้า ขอขอบพระคุณ รศ. ดร.โชติรัตน์ รัตนามัทธนะ อาจารย์ที่ปรึกษาของข้าพเจ้าที่ให้คำปรึกษาในด้านต่าง ๆ ไม่ว่าจะเป็นการเรียน หรือการใช้ชีวิตประจำวัน ขอขอบพระคุณคุณแม่และครอบครัวที่เป็นกำลังใจให้กับข้าพเจ้าในการทำวิทยานิพนธ์มาตลอด ขอขอบพระคุณภาควิชาวิศวกรรมคอมพิวเตอร์ คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัยที่ให้ความรู้และประสบการณ์ต่าง ๆ แก่ข้าพเจ้าอย่างมากมาย ขอขอบคุณพี่เก้า พี่ตง พี่ต่อ และพี่ๆสมาชิกของห้องปฏิบัติการทำเหมืองข้อมูล (Data Mining Lab) และห้องปฏิบัติการแลป 18-01 สำหรับคำแนะนำต่าง ๆ ในการทำวิทยานิพนธ์ สุดท้ายนี้ขอขอบคุณตัวข้าพเจ้าที่ได้มีความพยายามและอดทนต่อการทำวิทยานิพนธ์อย่างเต็มความสามารถ

ศุภกร ชูประภาวรรณ



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ค
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ฉ
สารบัญรูป.....	ฅ
สารบัญตาราง.....	ญ
บทที่ 1 บทนำ	1
1.1 ที่มาและความสำคัญของปัญหา	1
1.2 วัตถุประสงค์ของงานวิจัย	3
1.3 ขอบเขตของงานวิจัย	3
1.3.1 ชุดข้อมูล (Datasets).....	3
1.3.2 การวิเคราะห์ชุดข้อมูล	3
1.4 ประโยชน์ที่คาดว่าจะได้รับ.....	4
บทที่ 2 ทฤษฎีที่เกี่ยวข้อง.....	5
2.1 แนวคิดและทฤษฎีที่เกี่ยวข้อง.....	5
2.1.1 สัญญาณรบกวนภาพ	5
2.1.2 ประเภทของสัญญาณรบกวนภาพ.....	5
2.1.2.1 สัญญาณรบกวนภาพแบบเกาส์เซียน (Gaussian noise).....	5
2.1.2.2 สัญญาณรบกวนภาพแบบเกลือและพริกไทย (Salt-and-pepper noise) ..	6
2.1.2.3 สัญญาณรบกวนภาพแบบปัวซองค์ (Poisson noise).....	7
2.1.3 โครงข่ายประสาทเทียมเชิงลึก (Convolutional Neural Network).....	7

2.1.3.1	ชั้นคอนโวลูชัน (Convolution layer).....	7
2.1.3.2	การขยับและการเสริมเต็ม (Striding and Padding).....	8
2.1.3.3	ชั้นเรคตีไฟด์เชิงเส้น (Rectified Linear Unit layer: ReLU)	10
2.1.3.4	ชั้นพูลลิง (Pooling layer)	11
2.1.3.5	แผนที่การกระตุ้น (Activation map)	12
2.2	งานวิจัยที่เกี่ยวข้อง.....	13
2.2.1	งานวิจัยด้านการลดสัญญาณรบกวนภาพแบบใช้อัลกอริทึม	13
2.2.2	งานวิจัยด้านการลดสัญญาณรบกวนภาพแบบใช้ชุดข้อมูลมาฝึกสอนให้กับโมเดล... ..	16
บทที่ 3	แนวคิดและวิธีการดำเนินงาน.....	18
3.1	แนวคิดที่เสนอในการทดลอง	18
3.2	ขั้นตอนการเตรียมชุดข้อมูลฝึกสอนและชุดข้อมูลทดสอบ	19
3.2.1	ขั้นตอนการประมวลผลก่อนหน้าสำหรับรูปภาพ (Preprocessing image).....	19
3.2.1.1	การเพิ่มสัญญาณรบกวนเกาส์เซียนภาพให้กับรูปภาพ (Noise generation)	20
3.2.1.2	การแปลงรูปภาพให้อยู่ในรูปของเวกเตอร์นัมพาย (NumPy).....	20
3.3	การทดลองและผลการทดลอง.....	21
3.3.1	การฝึกสอน.....	21
3.3.2	การทดสอบ	22
3.3.3	ผลการทดลอง.....	23
3.3.4	แนวคิดใหม่ที่เสนอในการทดลอง	32
3.3.5	ชุดข้อมูลทดสอบ.....	33
3.3.6	ผลการทดลองบนสัญญาณรบกวนภาพจริง	34
3.3.7	ผลการทดลองบนสัญญาณรบกวนภาพเกาส์เซียน	36
บทที่ 4	สรุปผลการดำเนินวิจัย	42

4.1	สรุปผลการวิจัย.....	42
4.2	แนวทางวิจัยในชั้นถัดไป.....	43
	บรรณานุกรม.....	44
	ประวัติผู้เขียน.....	47



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

สารบัญรูป

รูปที่ 1 จุดสีดาบริเวณปีกของผีเสื้อ	2
รูปที่ 2 สัญญาณรบกวนแบบเกาส์เขียนบนภาพขาว-ดำ	6
รูปที่ 3 สัญญาณรบกวนภาพแบบเกลือและพริกไทยบนภาพขาว-ดำ โดยจะมีจุดสังเกตคือ บริเวณพื้นที่มืดจะมีจุดสีขาวปรากฏและบริเวณพื้นที่สว่างจะมีจุดสีดาปรากฏ	7
รูปที่ 4 การทำงานของชั้นคอนโวลูชันโดยนำค่าน้ำหนักแบบสุ่มจากตัวกรองมาคูณกับเมทริกซ์ของภาพเพื่อให้ได้แผนที่การกระตุ้น	8
รูปที่ 5 ตัวอย่างการขยับตัวกรองไปที่ละ 1 หน่วยบนภาพขนาด 5x5 พิกเซล	9
รูปที่ 6 การทำงานของพารามิเตอร์ของการเสริมเต็มภายในชั้นคอนโวลูชัน	10
รูปที่ 7 แผนที่การกระตุ้นที่ผ่านชั้น RELU	11
รูปที่ 8 การลดขนาดของแผนที่การกระตุ้นด้วยชั้นพูลลิง	11
รูปที่ 9 การใช้อัลกอริทึม NLM บนภาพที่ถูกสัญญาณรบกวนแบบเกาส์เขียน	14
รูปที่ 10 ขั้นตอนการทำงานของอัลกอริทึม BM3D	15
รูปที่ 11 ขั้นตอนการทำงานของอัลกอริทึม WNMM	16
รูปที่ 12 สถาปัตยกรรมของโมเดล MLP ซึ่งประกอบไปด้วยชั้นข้อมูลนำเข้า ชั้นซ่อน และชั้นผลลัพธ์	17
รูปที่ 13 แนวคิดที่เสนอในการทดลองในการใช้เส้นแบ่งระหว่างวัตถุกับพื้นหลังเข้ามาประยุกต์ ร่วมกับภาพที่ถูกรบกวนด้วยสัญญาณรบกวนภาพ	19
รูปที่ 14 สัญญาณรบกวนภาพแบบเกาส์เขียนที่ถูกสุ่มขึ้นมา	20
รูปที่ 15 ตัวอย่างของรูปภาพเมื่อถูกแปลงเป็นเวกเตอร์นัมพาย	20
รูปที่ 16 การเพิ่มจำนวนข้อมูลฝึกสอน (AUGMENTATION)	21
รูปที่ 17 โมเดลที่นำเสนอในการลดสัญญาณรบกวนภาพจริงที่ถูกฝึกสอนบนชุดข้อมูลที่ถูกรบกวนด้วยสัญญาณภาพเกาส์เขียนแบบคละระดับความเข้มขั้นที่ 15 25 และ 50	33

สารบัญตาราง

ตารางที่ 1 ตารางเปรียบเทียบผลลัพธ์ของการลดสัญญาณรบกวนภาพเกาส์เซียนบนระดับ ความเข้มข้นที่ 15 ระหว่างอัลกอริทึม BM3D และ DNCNN และโมเดลของผู้วิจัยบนชุด ข้อมูลทดสอบ SET12	24
ตารางที่ 2 ผลการทดลองบนชุดข้อมูลทดสอบ SET12 บนระดับความเข้มข้นที่ 15 (ฝึกสอนแบบ แบ่งระดับความเข้มข้น) ซึ่งวัดในรูปแบบค่า MS-SSIM โดยตัวหนาคือผลลัพธ์ที่ดีที่สุด	25
ตารางที่ 3 ผลการทดลองบนชุดข้อมูลทดสอบ SET12 บนระดับความเข้มข้นที่ 25 (ฝึกสอนแบบ แบ่งระดับความเข้มข้น) ซึ่งวัดในรูปแบบค่า MS-SSIM โดยตัวหนาคือผลลัพธ์ที่ดีที่สุด	26
ตารางที่ 4 ผลการทดลองบนชุดข้อมูลทดสอบ SET12 บนระดับความเข้มข้นที่ 50 (ฝึกสอนแบบ แบ่งระดับความเข้มข้น) ซึ่งวัดในรูปแบบค่า MS-SSIM โดยตัวหนาคือผลลัพธ์ที่ดีที่สุด	27
ตารางที่ 5 ผลการทดสอบบนชุดข้อมูลทดสอบ BSD68 (ฝึกสอนแบบแบ่งระดับความเข้มข้น) ซึ่งวัดในรูปแบบค่าเฉลี่ยของมาตรวัด MS-SSIM โดยตัวหนาคือผลลัพธ์ที่ดีที่สุด	28
ตารางที่ 6 การเปรียบเทียบประสิทธิภาพของโมเดลของผู้วิจัยระหว่างการฝึกสอนแบบคละระดับ ความเข้มข้นกับแบบแบ่งระดับความเข้มข้นบนมาตรวัด MS-SSIM บนชุดข้อมูลทดสอบ SET12.....	31
ตารางที่ 7 การเปรียบเทียบประสิทธิภาพของโมเดลของผู้วิจัยระหว่างการฝึกสอนแบบคละระดับ ความเข้มข้นกับแบบแบ่งระดับความเข้มข้นบนมาตรวัดแบบเฉลี่ย MS-SSIM บนชุด ข้อมูลทดสอบ BSD68.....	32
ตารางที่ 8 ชุดข้อมูลทดสอบภาพที่ถูกรบกวนด้วยสัญญาณรบกวนภาพจริง	34
ตารางที่ 9 ผลการทดลองการลดสัญญาณรบกวนภาพจริงบนชุดข้อมูลทดสอบ	35
ตารางที่ 10 ตารางเปรียบเทียบประสิทธิภาพในการลดสัญญาณรบกวนภาพเกาส์เซียนบนระดับ ความเข้มข้นที่ 15 ซึ่งวัดในรูปแบบค่า MS-SSIM โดยตัวหนาคือผลลัพธ์ที่ดีที่สุด	37
ตารางที่ 11 ตารางเปรียบเทียบประสิทธิภาพในการลดสัญญาณรบกวนภาพเกาส์เซียนบนระดับ ความเข้มข้นที่ 25 ซึ่งวัดในรูปแบบค่า MS-SSIM โดยตัวหนาคือผลลัพธ์ที่ดีที่สุด	38
ตารางที่ 12 ตารางเปรียบเทียบประสิทธิภาพในการลดสัญญาณรบกวนภาพเกาส์เซียนบนระดับ ความเข้มข้นที่ 50 ซึ่งวัดในรูปแบบค่า MS-SSIM โดยตัวหนาคือผลลัพธ์ที่ดีที่สุด	39

ตารางที่ 13 ตารางผลการทดสอบบนชุดข้อมูลทดสอบ BSD68 ซึ่งวัดในรูปแบบค่าเฉลี่ยของ
 มาตรฐาน MS-SSIM โดยตัวหนาคือผลลัพธ์ที่ดีที่สุด 40

ตารางที่ 14 ตารางเปรียบเทียบประสิทธิภาพระหว่างโมเดลของผู้วิจัยที่เสนอ CANNY กับ CANNY
 + HED โดยฝึกสอนแบบคละระดับความเข้มข้นของสัญญาณรบกวนภาพเกาส์เซียนบน
 ชุดข้อมูลทดสอบ SET12..... 40

ตารางที่ 15 ตารางเปรียบเทียบประสิทธิภาพระหว่างโมเดลของผู้วิจัยที่เสนอ CANNY กับ CANNY
 + HED โดยฝึกสอนแบบคละระดับความเข้มข้นของสัญญาณรบกวนภาพเกาส์เซียนบน
 ชุดข้อมูลทดสอบ BSD68 41



บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญของปัญหา

งานวิจัยด้านการลดสัญญาณรบกวนของภาพนั้นถือได้ว่าเป็นหนึ่งในงานวิจัยคอมพิวเตอร์วิชัน (Computer Vision) เนื่องจากเป็นปัญหาวิจัยที่ส่งต่องานวิจัยด้านอื่น ๆ ในงานคอมพิวเตอร์วิชัน เช่น งานวิจัยด้านการจำแนกรูป (Image classification) งานวิจัยด้านการจดจำรูป (Image recognition) และงานวิจัยด้านการแบ่งส่วนรูปภาพ (Image segmentation) เป็นต้น สำหรับงานวิจัยด้านการลดสัญญาณรบกวนของภาพนั้นถือว่าเป็นงานในระดับพื้นฐานของงานวิจัยของคอมพิวเตอร์วิชันและเป้าหมายของงานวิจัยด้านการลดสัญญาณรบกวนของภาพคือกู้คืนภาพต้นฉบับจากภาพที่ถูกรบกวนด้วยสัญญาณรบกวน ซึ่งสัญญาณรบกวนภาพนั้นจะเกิดได้จากหลาย ๆ ปัจจัย เช่น อุณหภูมิของสภาพแวดล้อมในขณะนั้น หรือ การส่งผ่านข้อมูลระหว่างตัวรับรู้ของกล้องถ่ายภาพกับวงจรอิเล็กทรอนิกส์ภายในกล้องถ่ายภาพ หรือ การถ่ายภาพในสภาพแวดล้อมที่มีความสว่างน้อย เป็นต้น นอกจากนั้นภาพที่ได้จากการถ่ายรูปรูปจากกล้องถ่ายภาพดิจิทัลนั้นจะมีหลายปัจจัยที่ถูกรบกวนด้วยสัญญาณรบกวนภาพ เช่น ขนาดของตัวรับรู้ (Sensor size) เนื่องจากขนาดของตัวรับรู้จะเป็นตัวสะสมแสงจากสภาพแวดล้อม ถ้าตัวรับรู้สะสมแสงได้ดีจะทำให้ได้รับภาพที่มีสัญญาณรบกวนน้อยลง แต่ถ้าตัวรับรู้แสงทำงานได้ไม่ดีจะทำให้เกิดสัญญาณรบกวนเพิ่มขึ้น นอกจากนั้นความร้อนบนตัวรับรู้สัญญาณ (Sensor heat) ยังก่อให้เกิดสัญญาณรบกวนได้เช่นกัน เช่น กล้อง DSLR นั้นจะเกิดสัญญาณรบกวนภาพในช่วงฤดูร้อนมากกว่าช่วงฤดูหนาว เป็นต้น สำหรับประเภทของสัญญาณรบกวนภาพนั้นมีหลายประเภทด้วยกัน เช่น สัญญาณรบกวนแบบเกาส์เซียน (Gaussian noise) สัญญาณรบกวนแบบเกลือและพริกไทย (Salt-and-Pepper noise) และสัญญาณรบกวนแบบปัวซองค์ (Poisson noise) เป็นต้น

ในงานวิจัยด้านการลดสัญญาณรบกวนของภาพสำหรับสัญญาณรบกวนแบบเกาส์เซียนนั้นแบ่งออกเป็น 2 กลุ่ม ได้แก่ กลุ่มงานวิจัยด้านการลดสัญญาณรบกวนภาพแบบใช้อัลกอริทึม และกลุ่มงานวิจัยด้านการลดสัญญาณรบกวนของภาพแบบใช้ชุดข้อมูลมาฝึกสอนให้กับโมเดล โดยกลุ่มงานวิจัยด้านการลดสัญญาณรบกวนภาพแบบใช้อัลกอริทึมนั้นมีพื้นฐานมาจาก Non-local Self-Similarity [1, 2] หรือมีพื้นฐานมาจากการใช้เกรเดียนท์โมเดล (Gradient model) [3-5] โดยในงานวิจัยด้านการลดสัญญาณรบกวนของภาพที่มีพื้นฐานมาจาก Non-local Self-Similarity จะได้รับความนิยมสูงกว่าเนื่องจากมีประสิทธิภาพดีกว่าเมื่อเปรียบเทียบกับกลุ่มงานวิจัยด้านการลดสัญญาณรบกวนภาพแบบใช้อัลกอริทึมที่มีพื้นฐานมาจากการใช้เกรเดียนท์โมเดล แต่ทว่างานวิจัยด้านการลด

สัญญาณรบกวนของภาพที่มีพื้นฐานมาจาก Non-local Self-Similarity นั้นมีข้อจำกัดอยู่บางประการ เช่น มีพารามิเตอร์บางอย่างที่ต้องถูกตั้งค่าให้เหมาะสมกับลักษณะภาพที่มีสัญญาณรบกวนเพื่อทำให้ลดสัญญาณรบกวนของภาพได้อย่างมีประสิทธิภาพ นอกจากนี้ระยะเวลาที่ใช้สำหรับลดสัญญาณรบกวนของภาพแต่ละภาพนั้นยังใช้เวลานานเนื่องจากการทำงานเกี่ยวกับการคำนวณตัวเลขทางเมทริกซ์ของตัวอัลกอริทึมนั้นเกี่ยวข้องกับตัวกรองบางประเภทที่ทำงานได้ช้า

เมื่อการเรียนรู้เชิงลึก (Deep learning) เริ่มได้รับความนิยมในปัจจุบันรวมถึงงานวิจัยด้านการลดสัญญาณรบกวนของภาพ มีงานวิจัยจำนวนหนึ่งได้ใช้การเรียนรู้เชิงลึกเข้ามาประยุกต์ใช้เพื่อให้ได้ประสิทธิภาพที่ดีขึ้น [6] โดยในงานวิจัยด้านการลดสัญญาณรบกวนของภาพที่ใช้การเรียนรู้เชิงลึกมาประยุกต์นั้นยังมีข้อจำกัดในด้านระยะเวลาที่ใช้ในการฝึกสอนโมเดลที่ใช้ระยะเวลานานและต้องการปริมาณข้อมูลฝึกสอนเป็นจำนวนมากเพื่อให้โมเดลได้เรียนรู้อย่างมีประสิทธิภาพ และงานวิจัยด้านการลดสัญญาณรบกวนของภาพที่ใช้การเรียนรู้เชิงลึกมาประยุกต์นั้นยังสร้างจุดแปลกปลอมขึ้นบนภาพที่ถูกลดสัญญาณรบกวน รวมถึงมีพื้นที่บางบริเวณถูกทำให้เบลอเนื่องจากโมเดลสูญเสียความเข้าใจต่อลักษณะสำคัญของภาพไปเนื่องจากสัญญาณรบกวนได้เข้าไปรบกวนภาพเหล่านั้น

งานวิจัยที่กล่าวถึงข้างต้นนั้นไม่ได้มุ่งเน้นไปในด้านการรักษาคุณลักษณะของภาพหลังจากถูกลดสัญญาณรบกวนแล้ว เช่น ภาพที่ถูกลดสัญญาณรบกวนนั้นมีสิ่งแปลกปลอมปรากฏอยู่ในภาพ เช่น จุดสีดำในภาพ เนื่องจากว่าจุดแปลกปลอมเหล่านี้สามารถส่งผลกระทบต่อคุณลักษณะบางอย่างของภาพ เช่น การเกิดจุดสีดำบนภาพปีกของผีเสื้อ แต่ทว่าปกติแล้วนั้นผีเสื้อสายพันธุ์นี้จะไม่จุดสีดำบริเวณปีก เป็นต้น โดยรูปการเกิดจุดสีดำบนภาพปีกของผีเสื้อแสดงดังรูปที่ 1 จะเห็นได้ว่าคุณลักษณะของภาพเป็นคุณสมบัติที่สำคัญสำหรับภาพเนื่องจากเป็นคุณสมบัติที่ใช้จำแนกว่าภายในภาพประกอบไปด้วยวัตถุใดบ้าง โดยเฉพาะอย่างยิ่งในงานวิจัยหลายๆงานที่เกี่ยวข้องกับงานวิจัยคอมพิวเตอร์วิชัน เช่น งานวิจัยด้านการจำแนกวัตถุ และ งานวิจัยด้านการจดจำรูป เป็นต้น โดยงานวิจัยนี้จะมุ่งเน้นไปการใช้การเรียนรู้เชิงลึกเข้ามาประยุกต์ร่วมกับการใช้เส้นแบ่งระหว่างวัตถุกับพื้นหลัง (Edge) เพื่อปรับปรุงประสิทธิภาพของการลดสัญญาณรบกวนของภาพแบบเกาส์เซียนและรักษาโครงสร้างของภาพได้ดียิ่งขึ้น



รูปที่ 1 จุดสีดำบริเวณปีกของผีเสื้อ

1.2 วัตถุประสงค์ของงานวิจัย

เพื่อพัฒนาประสิทธิผลของโมเดลในงานด้านการลดสัญญาณรบกวนภาพแบบเกาส์เซียนร่วมกับการใช้การเรียนรู้เชิงลึกและเส้นแบ่งระหว่างวัตถุกับพื้นหลัง โดยโมเดลจะมีประสิทธิผลดียิ่งขึ้นและรักษาคุณลักษณะของภาพที่ถูกลดสัญญาณรบกวนภาพแบบเกาส์เซียนได้ดีกว่าการใช้การเรียนรู้เชิงลึกแบบมาตรฐานในการลดสัญญาณรบกวนภาพแบบเกาส์เซียน

1.3 ขอบเขตของงานวิจัย

1.3.1 ชุดข้อมูล (Datasets)

ข้อมูลที่ใช้ฝึกสอนการลดสัญญาณรบกวนของภาพสำหรับสัญญาณรบกวนแบบเกาส์เซียนคือชุดข้อมูลภาพเบิร์กกลีย์ 400 ภาพ (The Berkeley Segmentation Dataset and Benchmark 400)¹ ประกอบด้วยภาพถ่ายขาว-ดำจากสภาพแวดล้อมจริงจำนวน 400 ภาพ โดยมีขนาดของภาพคือ สูง 180 พิกเซล กว้าง 180 พิกเซล และเป็นภาพถ่ายขาว-ดำ

ส่วนข้อมูลที่ใช้ทดสอบการลดสัญญาณรบกวนของภาพสำหรับสัญญาณรบกวนแบบเกาส์เซียนนั้นประกอบไปด้วย 2 ชุดข้อมูล คือ

1.ชุดข้อมูลภาพเบิร์กกลีย์ 68 ภาพ (The Berkeley Segmentation Dataset and Benchmark 68)² ประกอบด้วยภาพถ่ายขาว-ดำจากสภาพแวดล้อมจริงจำนวน 68 ภาพ โดยมีขนาดของภาพที่มีความสูงของภาพเท่ากับความกว้างของภาพ คือ 128 x 128 พิกเซล และ 256 x 256 พิกเซลเท่านั้น

2.ชุดข้อมูลภาพ 12 ภาพ (Set12 dataset)³ ประกอบด้วยภาพถ่ายขาว-ดำจากสภาพแวดล้อมจริงจำนวน 12 ภาพ โดยมีขนาดของภาพที่มีความสูงของภาพเท่ากับความกว้างของภาพคือ 512 x 512 พิกเซล และ 1024 x 1024 พิกเซลเท่านั้น

1.3.2 การวิเคราะห์ชุดข้อมูล

การวิเคราะห์ชุดข้อมูลจะใช้ระดับความเข้มข้นของสัญญาณรบกวนแบบเกาส์เซียนที่ระดับ 15 25 และ 50 เนื่องจากระดับความเข้มข้นของสัญญาณรบกวนแบบเกาส์เซียนที่เลือกนั้นถือว่า

¹ https://github.com/cszn/DnCNN/tree/master/TrainingCodes/DnCNN_TrainingCodes_v1.0/data/Train400

² https://github.com/cszn/DnCNN/tree/master/TrainingCodes/DnCNN_TrainingCodes_v1.0/data/Test/Set68

³ https://github.com/cszn/DnCNN/tree/master/TrainingCodes/DnCNN_TrainingCodes_v1.0/data/Test/Set12

เป็นระดับความเข้มข้นของสัญญาณรบกวนแบบเกาส์เซียนเบื้องต้นที่พบได้ตามสภาพแวดล้อมในปัจจุบัน นอกจากนั้นระดับความเข้มข้นเหล่านี้ถูกใช้ในงานวิจัยที่เกี่ยวข้องกับวิทยานิพนธ์นี้

1.4 ประโยชน์ที่คาดว่าจะได้รับ

ได้โมเดลที่ประยุกต์ใช้การเรียนรู้เชิงลึก (Deep learning) ร่วมกับเส้นแบ่งระหว่างวัตถุกับพื้นหลังสำหรับงานวิจัยด้านการลดสัญญาณรบกวนภาพแบบเกาส์เซียนซึ่งทำงานบนภาพขาว-ดำซึ่งสามารถลดสัญญาณรบกวนบนภาพจากสภาพแวดล้อมจริงได้



บทที่ 2

ทฤษฎีที่เกี่ยวข้อง

2.1 แนวคิดและทฤษฎีที่เกี่ยวข้อง

ทฤษฎีที่เกี่ยวข้องกับหัวข้อวิจัยนี้ประกอบไปด้วย 4 หัวข้อหลักได้แก่ 1) สัญญาณรบกวนภาพ (Image noise) 2) ประเภทของสัญญาณรบกวนภาพ 3) โครงข่ายประสาทเทียม (Convolutional Neural Network) 4) ความคล้ายคลึงกันของโครงสร้างหลายระดับ (Multi-Scale Structural Similarity) [7]

2.1.1 สัญญาณรบกวนภาพ

งานด้านการลดสัญญาณรบกวนภาพถือว่าเป็นปัญหาในระดับตั้งต้นสำหรับงานด้านการรับรู้ภาพของคอมพิวเตอร์ เนื่องจากการลดสัญญาณรบกวนภาพมีความเกี่ยวข้องกับแอปพลิเคชันจำนวนมากในปัจจุบัน โดยสำหรับการลดสัญญาณรบกวนภาพนั้นมีจุดประสงค์เพื่อกู้ภาพต้นฉบับจากภาพที่ถูกรบกวนด้วยสัญญาณรบกวน โดยภาพที่ถูกถ่ายมาจากกล้องลั่นว่นก่อให้เกิดสัญญาณรบกวนขึ้นมาเนื่องจากเซนเซอร์หรือวงจรไฟฟ้าของกล้องถ่ายรูปลดจิ๋วรวมถึงความชื้นจากสภาพแวดล้อมในขณะนั้น เป็นต้น

2.1.2 ประเภทของสัญญาณรบกวนภาพ

2.1.2.1 สัญญาณรบกวนภาพแบบเกาส์เซียน (Gaussian noise)

เป็นสัญญาณรบกวนประเภทหนึ่งทางด้านสถิติที่ค่าฟังก์ชันความหนาแน่นของความน่าจะเป็นมีค่าเท่ากับค่าการกระจายตัวแบบปกติ ซึ่งค่าของสัญญาณรบกวนจะมีค่าอยู่ในการกระจายตัวแบบเกาส์เซียน โดยสมการของสัญญาณรบกวนภาพแบบเกาส์เซียนสามารถแสดงได้ในสมการที่ (1)

$$p_G(z) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(z-\mu)^2}{2\sigma^2}} \quad (1)$$

โดย $P_G(z)$ คือสัญญาณรบกวนภาพแบบเกาส์เซียน μ คือค่าเฉลี่ยของพิกเซลในภาพ และ σ คือค่าเบี่ยงเบนมาตรฐานของภาพ โดยสัญญาณรบกวนภาพแบบเกาส์เซียนนั้นจะเป็นสัญญาณทางสถิติประเภทหนึ่งที่ถูกคิดค้นขึ้นมาโดย นายโยฮันน์ คาร์ล ฟรีดริช เกาส์ (Johann Carl Friedrich Gauss) ซึ่งลักษณะของสัญญาณรบกวนภาพแบบเกาส์เซียนจะอยู่ในรูปของการแจกแจงแบบเกาส์เซียนและแต่ละพิกเซลจะไม่ขึ้นต่อกัน โดยสัญญาณรบกวนภาพแบบเกาส์เซียนสำหรับภาพดิจิทัลจะปรากฏขึ้น

ได้จากหลากหลายเหตุ เช่น สัญญาณรบกวนจากเซนเซอร์ที่รับแสงไม่เหมาะสมหรืออุณหภูมิของสภาพแวดล้อมสูง หรือการส่งผ่านสัญญาณของวงจรอิเล็กทรอนิกส์ที่อยู่ภายในกล้องดิจิทัล เป็นต้น โดยการลดสัญญาณรบกวนภาพแบบเกาส์เซียนจะใช้ตัวกรองแบบเกาส์เซียน แต่ทว่าตัวกรองแบบเกาส์เซียนจะทำให้ภาพที่ถูกลดสัญญาณรบกวนภาพแบบเกาส์เซียนมีลักษณะเบลอและทำให้สูญเสียลักษณะสำคัญบางอย่างในภาพ สำหรับตัวอย่างภาพที่ถูกรบกวนด้วยสัญญาณรบกวนภาพแบบเกาส์เซียนแสดงได้ดังรูปที่ 2



รูปที่ 2 สัญญาณรบกวนแบบเกาส์เซียนบนภาพขาว-ดำ

2.1.2.2 สัญญาณรบกวนภาพแบบเกลือและพริกไทย (Salt-and-pepper noise)

เป็นสัญญาณรบกวนภาพดิจิทัลประเภทหนึ่งที่มีอีกชื่อเรียกว่าสัญญาณรบกวนแบบเกลือและพริกไทย ซึ่งมีสาเหตุเกิดจากการส่งผ่านและแปลงสัญญาณแอนะล็อกเป็นดิจิทัล โดยสัญญาณรบกวนแบบเกลือและพริกไทยจะมีคุณลักษณะเด่นคือทำให้จุดภาพสีดำปรากฏในบริเวณที่สว่างและจุดภาพสีขาวปรากฏในบริเวณที่มืด โดยตัวกรองที่ใช้ในการลดสัญญาณรบกวนภาพแบบเกลือและพริกไทยอย่างมีประสิทธิภาพคือตัวกรองมัธยฐาน (Median filter) ตัวอย่างของภาพที่ถูกรบกวนด้วยสัญญาณรบกวนภาพแบบเกลือและพริกไทยแสดงได้ดังรูปที่ 3



รูปที่ 3 สัญญาณรบกวนภาพแบบเกลือและพริกไทยบนภาพขาว-ดำ โดยจะมีจุดสังเกตคือบริเวณพื้นที่
มืดจะมีจุดสีขาวปรากฏและบริเวณพื้นที่สว่างจะมีจุดสีดำปรากฏ

2.1.2.3 สัญญาณรบกวนภาพแบบปัวซองค์ (Poisson noise)

เป็นสัญญาณรบกวนที่มีการแจกแจงแบบปัวซองค์และมีลักษณะคล้ายกับสัญญาณรบกวนแบบเกาส์เซียน เช่น มีจุดบนภาพคล้ายกับสัญญาณรบกวนประเภทเกาส์เซียน โดยสัญญาณรบกวนแบบปัวซองค์นั้นจะเกิดขึ้นกับภาพที่ถูกถ่ายในสภาพแวดล้อมที่มีแสงน้อย หรือ เกิดภายในอุปกรณ์อิเล็กทรอนิกส์เนื่องจากสาเหตุที่เกี่ยวข้องกับความไม่แน่นอนในการปล่อยอิเล็กตรอนของอุปกรณ์อิเล็กทรอนิกส์ เป็นต้น นอกจากนั้นการกระจายตัวแบบปัวซองค์จะใกล้เคียงกับการกระจายตัวแบบเกาส์เซียนเนื่องจากค่าเฉลี่ยปัวซองค์ที่เพิ่มสูงขึ้นมากทำให้สามารถประมาณได้ว่าการกระจายตัวแบบปัวซองค์ก็ใกล้เคียงกับการกระจายตัวแบบเกาส์เซียน


2.1.3 โครงข่ายประสาทเทียมเชิงลึก (Convolutional Neural Network)

โครงข่ายประสาทเทียมได้รับการพัฒนามาอย่างยาวนานในช่วงตั้งแต่ ค.ศ. 1998 เป็นต้นมา โดยโครงข่ายประสาทเทียมเชิงลึกได้แสดงให้เห็นถึงประสิทธิภาพในการแข่งขัน ILSVRC 2014 โดยได้รับอันดับชนะเลิศในการแข่งขันการตรวจจำวัตถุ [8] สำหรับโครงข่ายประสาทเทียมเชิงลึกจะมีส่วนประกอบดังต่อไปนี้

2.1.3.1 ชั้นคอนโวลูชัน (Convolution layer)

ชั้นนี้จะเป็นชั้นที่สำคัญที่สุดสำหรับโครงข่ายประสาทเทียมเชิงลึกและมีหน้าที่สกัดคุณลักษณะที่สำคัญของข้อมูลนำเข้าออกมา (Feature extraction) โดยชั้นนี้ประกอบด้วยตัวกรอง (Filter) เป็นจำนวนมากเพื่อทำหน้าที่สกัดคุณลักษณะที่มีประโยชน์ต่อการเรียนรู้ของโครงข่ายประสาทเทียมเชิงลึก ซึ่งตัวกรองเหล่านี้จะมีขนาดเล็กและมีลักษณะเชิงพื้นที่เมื่อเทียบกับ

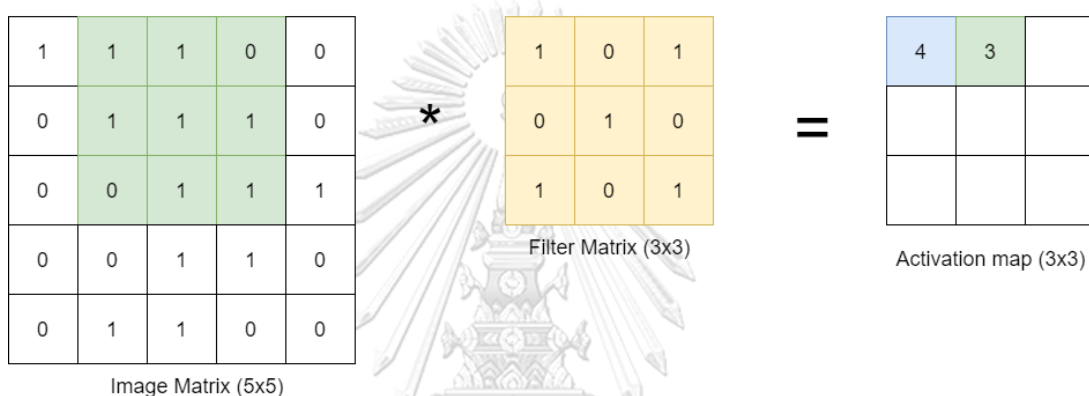
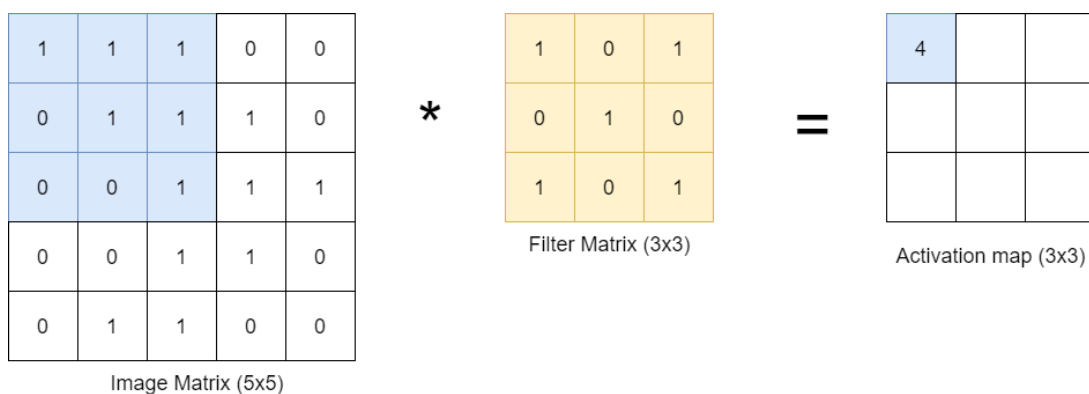
ข้อมูลนำเข้า เช่น กำหนดให้ตัวกรงมีความกว้าง 3 พิกเซล ความสูง 3 พิกเซล และความลึก 1 ช่อง ซึ่งตัวเลขในแต่ละพิกเซลภายในตัวกรงนั้นจะมีค่าน้ำหนักแบบสุ่ม ยกตัวอย่างเช่นเมื่อข้อมูลนำเข้าที่มีความกว้าง 5 พิกเซล และสูง 5 พิกเซลถูกป้อนเข้าสู่โมเดล ชั้นคอนโวลูชันจะทำการคอนโวลฟ์ (Convolve) ตัวกรงกับข้อมูลนำเข้านั้นด้วยการทำการคูณระหว่างเมทริกซ์ค่าน้ำหนักแบบสุ่มของตัวกรงกับค่าพิกเซลในแต่ละตำแหน่งของข้อมูลนำเข้าและนำผลคูณมารวมกันจะได้แผนที่การกระตุ้น (Activation map) แสดงได้ดังรูปที่ 4




รูปที่ 4 การทำงานของชั้นคอนโวลูชันโดยนำค่าน้ำหนักแบบสุ่มจากตัวกรงมาคูณกับเมทริกซ์ของภาพเพื่อให้ได้แผนที่การกระตุ้น

2.1.3.2 การขยับและการเสริมเต็ม (Striding and Padding)

ภายในชั้นคอนโวลูชันใด ๆ นั้นจะมีพารามิเตอร์ที่สำคัญอยู่ 2 พารามิเตอร์ ได้แก่ พารามิเตอร์ของการขยับ (Striding) และพารามิเตอร์ของการเสริมเต็ม (Padding) โดยพารามิเตอร์ของการขยับนั้นจะเป็นตัวควบคุมตัวกรงภายในชั้นคอนโวลูชันว่าหลังจากทำการคอนโวลฟ์แล้วจะเลื่อนตัวกรงไปกี่หน่วย เช่น เลื่อนตัวกรงไป 1 หน่วย หรือเลื่อนตัวกรงไป 2 หน่วย เป็นต้น โดยปกติแล้วพารามิเตอร์ของการขยับนั้นจะถูกกำหนดค่าให้เหมาะสมกับขนาดของข้อมูลนำเข้าเพื่อป้องกันไม่ให้เกิดการคอนโวลฟ์เกินขนาดของข้อมูลนำเข้า เช่น ขนาดของข้อมูลนำเข้ามีขนาดความกว้าง 5 พิกเซล และความสูง 5 พิกเซล เมื่อถูกนำเข้าที่ชั้นคอนโวลูชันแล้วนั้นชั้นคอนโวลูชันจะเริ่มทำการคอนโวลฟ์ด้วยการกำหนดค่าน้ำหนักแบบสุ่มให้แก่ตัวกรง (Filter) และเริ่มทำการคูณเมทริกซ์ระหว่างค่าน้ำหนักแบบสุ่มของตัวกรงกับเมทริกซ์ของข้อมูลนำเข้า โดยขนาดของตัวกรงจะมีขนาดความกว้าง 3 พิกเซล และความสูง 3 พิกเซล เมื่อทำการคูณกับตัวกรงเสร็จจะได้ค่าตัวเลขออกมาค่าหนึ่ง จากนั้นจึงกำหนดพารามิเตอร์ของการขยับ (Striding) ให้มีค่าเป็น 1 จากนั้นตัวกรงจะเลื่อนไปทางขวาทีละ 1 หน่วย โดยเมื่อตัวกรงขยับไปทางขวาจนสุดแล้ว ตัวกรงจะเลื่อนลงไปที่บริเวณล่างซ้ายของข้อมูลนำเข้าเพื่อทำการคอนโวลฟ์กับส่วนที่เหลือของข้อมูลนำเข้าในลำดับต่อไป ซึ่งแสดงได้ดังรูปที่ 5



รูปที่ 5 ตัวอย่างการขยับตัวกรองไปที่ละ 1 หน่วยบนภาพขนาด 5x5 พิกเซล โดยปกติเมื่อชั้นคอนโวลูชันทำการคอนโวลฟ์กับข้อมูลนำเข้าจะได้แผนที่การกระตุ้นที่มีขนาดลดลงซึ่งแสดงดังรูปที่ 4 เมื่อขนาดของแผนที่การกระตุ้นมีขนาดลดลงซึ่งก่อให้เกิดความสูญเสียทางข้อมูลของภาพในด้านการสังเคราะห์คุณลักษณะของโครงข่ายประสาทเทียม จึงได้นำพารามิเตอร์ของการเสริมเติมมาแก้ไขปัญหาที่กล่าวไปข้างต้น โดยพารามิเตอร์ของการเสริมเติมจะทำหน้าที่รักษาข้อมูลของภาพด้วยการเติมเลข 0 เข้าไปในบริเวณขอบแผนที่การกระตุ้น (Activation map) เพื่อทำให้ขนาดของแผนที่กระตุ้นมีขนาดเท่ากับข้อมูลนำเข้าเพื่อรักษาบริเวณขอบของภาพไม่ให้เกิดตัดออกจากการคอนโวลฟ์ ซึ่งขอบภาพนั้นเป็นคุณลักษณะสำคัญของภาพจึงต้องใช้พารามิเตอร์ของการเสริมเติมเข้ามาช่วยนั่นเอง โดยปกติแล้วข้อมูลนำเข้าจะถูกผ่านการทำงานของพารามิเตอร์การเสริมเติมก่อนถูกนำไปคอนโวลฟ์ที่ชั้นคอนโวลูชันเพื่อรักษาข้อมูลของภาพดังรูปที่ 6 จะเห็นได้ว่าแผนที่การกระตุ้นมีขนาดเท่ากับข้อมูลนำเข้าเมื่อใช้พารามิเตอร์ของการเสริมเติม



รูปที่ 6 การทำงานของพารามิเตอร์ของการเสริมเต็มภายในชั้นคอนโวลูชัน

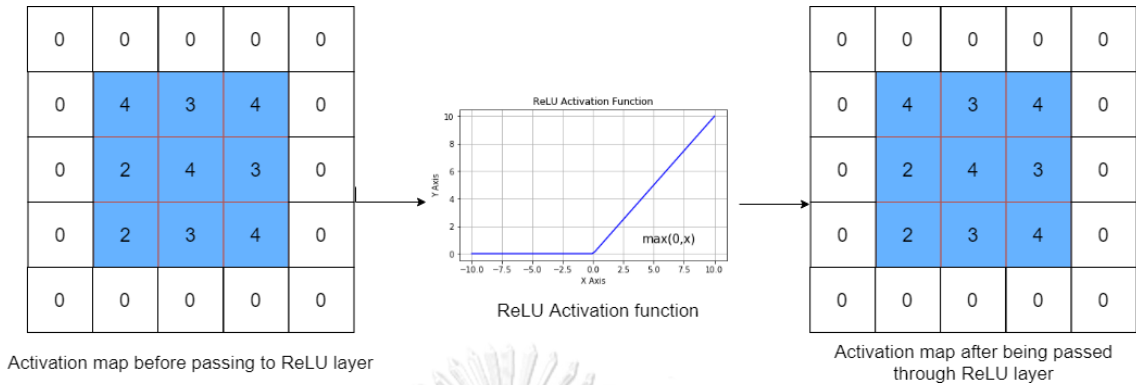
2.1.3.3 ชั้นเรกติไฟด์เชิงเส้น (Rectified Linear Unit layer: ReLU)

ชั้นนี้เป็นชั้นสำหรับฟังก์ชันกระตุ้นในโครงข่ายประสาทเทียม ซึ่งมีคุณสมบัติเป็นตัวเร่งให้โครงข่ายประสาทเทียมสามารถเรียนรู้ตัวอย่างฝึกสอนได้อย่างรวดเร็วและชั้นนี้ยังช่วยเพิ่มความสามารถของโครงข่ายประสาทเทียมในด้านคุณสมบัติแบบไม่เชิงเส้น โดยชั้นหน่วยเชิงเส้นแบบบริสุทธิ์แสดงได้ดังสมการที่ (2)

$$f(x) = \max(0, x) \tag{2}$$

ชั้นหน่วยเชิงเส้นแบบบริสุทธิ์จะนำแผนที่การกระตุ้นไปคำนวณด้วยสมการที่ (2) โดยตัวแปร x คือแผนที่การกระตุ้น ซึ่งสมการที่ (2) มีหน้าที่เปลี่ยนค่าตัวเลขใด ๆ ที่อยู่ภายในแผนที่การกระตุ้นให้กลายเป็นค่า 0 ก็ต่อเมื่อค่าตัวเลขนั้น ๆ มีค่าติดลบ ตัวอย่างการทำงานของชั้น

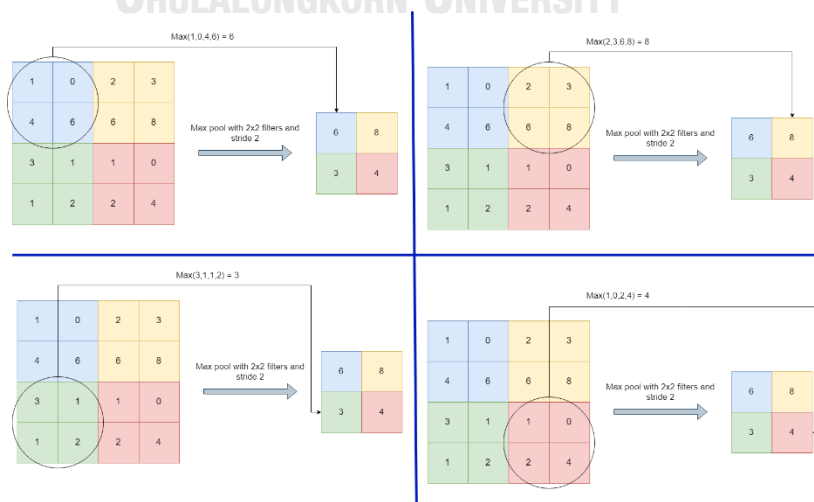
หน่วยเชิงเส้นแบบบริสุทธิ์แสดงได้ดังรูปที่ 7 โดยค่าตัวเลขภายในแผนที่การกระตุ้นที่ผ่านชั้นชั้นหน่วยเชิงเส้นแบบบริสุทธิ์จะไม่มีเปลี่ยนแปลงค่าเนื่องจากไม่มีค่าตัวเลขติดลบอยู่ในแผนที่การกระตุ้น



รูปที่ 7 แผนที่การกระตุ้นที่ผ่านชั้น ReLU

2.1.3.4 ชั้นพูลลิ่ง (Pooling layer)

ชั้นพูลลิ่งถือว่าเป็นชั้นที่สำคัญชั้นหนึ่งของโครงข่ายประสาทเทียมเนื่องจากมีความสามารถในการคัดสรรคุณสมบัติของข้อมูลที่มีประโยชน์ด้วยการลดขนาดของข้อมูลนำเข้าให้เหลือเพียงครั้งหนึ่ง เช่น การใช้ตัวกรองที่มีความกว้าง 2 พิกเซล และความสูง 2 พิกเซล และใช้พารามิเตอร์การขยับ 2 พิกเซล โดยชั้นพูลลิ่งมีหลักการทำงานคือจะนำตัวเลขที่อยู่ในแผนที่การกระตุ้นมาคัดเลือกตัวเลขที่ค่าสูงสุดในแต่ละพื้นที่ออกมา เช่น ในพื้นที่หนึ่งบนแผนที่การกระตุ้นมีตัวเลขอยู่ 4 ตัวเลข คือ 1,0,4,6 เมื่อนำตัวเลขเหล่านี้ไปผ่านชั้นพูลลิ่งจะได้ตัวเลขที่มีค่าสูงสุดออกมาคือ 6 จากนั้นจะขยับไปทางขวาทีละ 2 หน่วยและเมื่อขยับไปทางขวาจนถึงสุดขอบของข้อมูลนำเข้าแล้วจะขยับลงมาด้านซ้ายล่างและขยับไปทางขวาทีละ 2 หน่วยแสดงได้ดังรูปที่ 8



รูปที่ 8 การลดขนาดของแผนที่การกระตุ้นด้วยชั้นพูลลิ่ง

2.1.3.5 แผนที่การกระตุ้น (Activation map)

สำหรับขนาดของแผนที่การกระตุ้นของชั้นคอนโวลูชันใด ๆ จะแสดงได้ดังสมการที่ (3)

$$O = \left(\frac{W - K + 2P}{S} \right) + 1 \quad (3)$$

โดย O คือ ขนาดของแผนที่การกระตุ้น และ W คือขนาดของภาพข้อมูลนำเข้าที่มีความกว้างและความสูงเท่ากันทั้ง 2 ด้าน K คือขนาดของตัวกรอง (Filter) และ P คือพารามิเตอร์การเสริมเต็ม (Padding) โดยพารามิเตอร์การเสริมเต็มมีได้ 2 ค่าคือ 0 (ไม่เลือกใช้พารามิเตอร์การเสริมเต็ม) และ 1 (เลือกใช้พารามิเตอร์การเสริมเต็ม) และ S คือพารามิเตอร์การขยับ (Striding) เช่น เมื่อนำภาพขนาดความกว้าง 5 พิกเซล และความสูง 5 พิกเซล (5x5) เข้าสู่ชั้นคอนโวลูชันที่มีตัวกรองขนาดความกว้าง 3 พิกเซล และความสูง 3 พิกเซล (3x3) และเลือกใช้พารามิเตอร์การเสริมเต็ม (P มีค่าเป็น 1) และใช้พารามิเตอร์การขยับทีละ 2 หน่วย (S มีค่าเป็น 2) จะสามารถคำนวณได้ดังนี้ $O = [(5 - 3 + 2(1)) / 2] + 1 = 3$ ดังนั้นขนาดของแผนที่การกระตุ้นจะมีความกว้างเป็น 3 พิกเซล และความสูงเป็น 3 พิกเซล (3x3)

2.1.4 ความคล้ายคลึงกันของโครงสร้างหลายระดับ (Multi-Scale Structural Similarity)

สำหรับมาตรวัดความคล้ายคลึงกันของโครงสร้างหลายระดับ (Multi-Scale Structural Similarity: MS-SSIM) [7] เป็นมาตรวัดคุณภาพของภาพหลังจากถูกลดสัญญาณรบกวนที่วัดจากหลายคุณสมบัติของภาพโดยจะเปรียบเทียบเป็นพิกเซลต่อพิกเซล เช่น ความสว่างของภาพ (Luminance: l) ค่าคอนทราสต์ (Contrast: c) และค่าโครงสร้างของภาพ (Structure: s) โดยมาตรวัด MS-SSIM จะแสดงได้ดังสมการที่ (4) โดย f คือภาพที่ถูกลดสัญญาณรบกวน และ g คือภาพต้นฉบับ

$$MS - SSIM(f, g) = l(f, g)c(f, g)s(f, g) \quad (4)$$

สำหรับสมการที่ (5) จะวัดความสว่างของภาพ (Luminance: l) ซึ่งจะวัดความใกล้เคียงกันที่สุดของค่าความสว่างเฉลี่ยของทั้งภาพที่ถูกลดสัญญาณรบกวนและภาพต้นฉบับ โดยความสว่างของภาพจะมีค่าสูงสุดคือ 1 ก็ต่อเมื่อค่า μ_f มีค่าเท่ากับ μ_g โดย f คือภาพที่ถูกลดสัญญาณรบกวน และ g คือภาพต้นฉบับ

$$l(f, g) = \frac{2\mu_f \mu_g + C_1}{\mu_f^2 + \mu_g^2 + C_1} \quad (5)$$

สมการที่ (6) นั้นจะวัดค่าคอนทราสต์ (Contrast: c) ซึ่งจะวัดด้วยค่าส่วนเบี่ยงเบนมาตรฐาน σ ของทั้งภาพที่ถูกลดสัญญาณรบกวนและภาพต้นฉบับ และสมการนี้จะมีค่าสูงสุดคือ 1 ก็ต่อเมื่อค่า σ_f เท่ากับ σ_g โดย f คือภาพที่ถูกลดสัญญาณรบกวน และ g คือภาพต้นฉบับ

$$c(f, g) = \frac{2\sigma_f \sigma_g + C_2}{\sigma_f^2 + \sigma_g^2 + C_2} \quad (6)$$

สมการที่ (7) คือสมการสำหรับการเปรียบเทียบโครงสร้างของภาพ (Structure: s) ด้วยสัมประสิทธิ์สหสัมพันธ์ (Correlation coefficient) ระหว่างภาพที่ถูกลดสัญญาณรบกวนและภาพต้นฉบับ โดย σ_{fg} คือค่าโควาเรียนซ์ระหว่างภาพที่ถูกลดสัญญาณรบกวนกับภาพต้นฉบับ โดย f คือภาพที่ถูกลดสัญญาณรบกวน และ g คือภาพต้นฉบับ นอกจากนั้นตัวแปร C_1 C_2 C_3 คือตัวแปรค่าคงที่ถูกกำหนดให้มีค่าคงที่เป็นจำนวนเต็มบวกเพื่อป้องกันการหารด้วยจำนวนเต็มศูนย์

$$s(f, g) = \frac{\sigma_{fg} + C_3}{\sigma_f + \sigma_g + C_3} \quad (7)$$

โดยมาตรวัด MS-SSIM นั้นจะรองรับกับขนาดของภาพหลากหลายขนาดซึ่งจะประเมินประสิทธิภาพได้เหมาะสมกับชุดข้อมูลที่มีขนาดของภาพหลากหลายและสามารถเปรียบเทียบโครงสร้างของภาพได้เป็นอย่างดี


2.2 งานวิจัยที่เกี่ยวข้อง

งานวิจัยที่เกี่ยวข้องกับการลดสัญญาณรบกวนภาพนั้นประกอบไปด้วยงานวิจัยด้านการลดสัญญาณรบกวนภาพแบบใช้อัลกอริทึม และงานวิจัยด้านการลดสัญญาณรบกวนของภาพแบบใช้ชุดข้อมูลมาฝึกสอนให้กับโมเดล และงานวิจัยที่เกี่ยวข้องกับด้านการปรับพารามิเตอร์อัตราการเรียนรู้

2.2.1 งานวิจัยด้านการลดสัญญาณรบกวนภาพแบบใช้อัลกอริทึม

ในงานด้านการลดสัญญาณรบกวนภาพแบบใช้อัลกอริทึมนั้นได้ถือว่าเป็นงานวิจัยริเริ่มที่มุ่งเน้นไปในด้านการใช้อัลกอริทึมต่าง ๆ โดยมีพื้นฐานมาจาก Non-local self-similarity ซึ่งเป็นพื้นฐานสำหรับด้านการลดสัญญาณรบกวนภาพสำหรับสัญญาณรบกวนแบบเกาส์เซียน โดยในปี ค.ศ 2005 Buades และคณะ. [1] เสนออัลกอริทึมที่เกี่ยวกับการลดสัญญาณรบกวนด้วยการใช้หลักการจากความสัมพันธ์ของความคล้ายคลึงกันของบล็อกที่ไม่ใช่เพื่อนบ้านกัน (Non-neighbor block) ซึ่ง

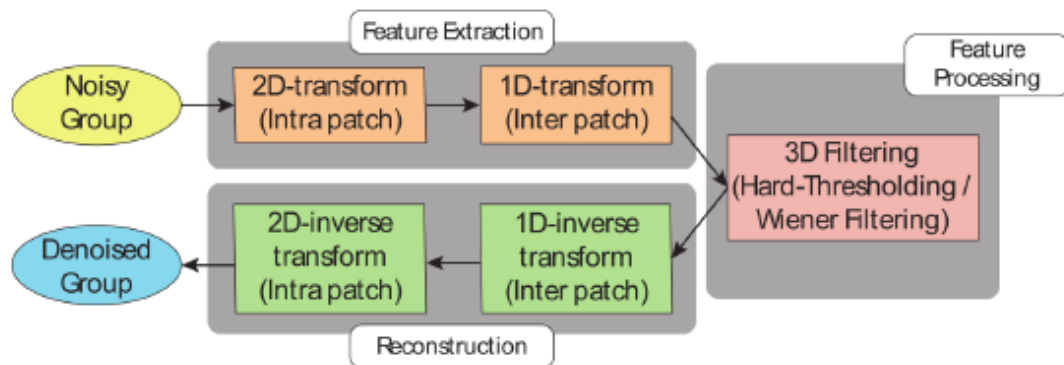
จะใช้หลักการในการดูแต่ละพิกเซลในภาพว่ามีความคล้ายเคียงกันมากเพียงใด ถ้าพิกเซลของภาพมีความใกล้เคียงกับบริเวณอื่น ๆ มาก จะให้ค่าน้ำหนัก (Weight) ในการลดสัญญาณรบกวนมาก แต่ถ้าใกล้เคียงกันน้อยจะให้ค่าน้ำหนักน้อยเพื่อใช้เป็นตัวพิจารณาว่าจะลดสัญญาณรบกวนภาพ การทำงานของอัลกอริทึม NLM แสดงได้ดังรูปที่ 9



รูปที่ 9 การใช้อัลกอริทึม NLM บนภาพที่ถูกสัญญาณรบกวนแบบเกาส์เซียน⁴

ในปี ค.ศ 2007 มีงานวิจัยของ K. Dabov และคณะ. [2] เสนออัลกอริทึมที่เรียกว่า BM3D ซึ่งจะทำงานโดยรวมอยู่ 2 ขั้นตอน โดยมีข้อมูลนำเข้าคือภาพที่ถูกรบกวนด้วยสัญญาณรบกวน จากนั้นจะถูกนำไปสกัดลักษณะประจำ (Feature extraction) ออกมา โดยการผ่านกระบวนการแปลงภาพที่ถูกรบกวนด้วยสัญญาณรบกวนให้กลายเป็นเวกเตอร์ 2 มิติ และ 1 มิติ ตามลำดับ ซึ่งจะได้ภาพที่มีขนาด 3 มิติออกมา จากนั้นนำไปเข้าสู่กระบวนการประมวลผลลักษณะประจำ (Feature processing) โดยใช้ตัวกรองแบบขีดแบ่งแบบถาวร (Hard-thresholding) เพื่อคำนวณค่าน้ำหนัก (Weight) ที่ใช้สำหรับพิจารณาในการลดสัญญาณรบกวนภาพ หลังจากนั้นนำภาพไปผ่านการแปลงแบบย้อนกลับ 3 มิติ (Inverse 3D transformation) และการประมาณการแบบบล็อก (Block-wise estimates) เพื่อให้ได้ภาพผลลัพธ์ในขั้นตอนที่ 1 และค่าน้ำหนักของภาพผลลัพธ์ในขั้นตอนที่ 1 หลังจากนั้นในขั้นตอนที่ 2 จะนำภาพผลลัพธ์ในขั้นตอนที่ 1 และค่าน้ำหนักมาทำซ้ำด้วยขั้นตอนที่ 1 แต่เปลี่ยนจากตัวกรองแบบขีดแบ่งแบบถาวรเป็นตัวกรองวีเนอร์ (Wiener filter) ซึ่งเป็นตัวกรองประเภทเส้นตรง (Linear filter) และมีพารามิเตอร์จำกัด (Fixed parameters) เป็นจำนวนมาก และประมาณค่าภาพที่ถูกลดสัญญาณรบกวนออกมาด้วยตัวกรองวีเนอร์ โดยการทำงานของอัลกอริทึมแสดงดังรูปที่ 10


⁴ อ้างอิงจาก Fig. 1 ใน [1]



รูปที่ 10 ขั้นตอนการทำงานของอัลกอริทึม BM3D⁵

นอกจากนั้นในปี ค.ศ 2014 ได้มีงานวิจัยของ Shuhang Gu และคณะ. [9] เสนออัลกอริทึมที่เรียกว่า WNNM เพื่อใช้ในการลดสัญญาณรบกวนของภาพ โดยใช้พื้นฐานที่เกี่ยวกับเมทริกซ์คือซิงกูลาร์ แวลยู ดีคอมโพสิชัน (Singular Value Decomposition : SVD) โดยค่าตัวเลขในเมทริกซ์ของภาพที่ถูกสัญญาณรบกวนนั้นจะมีค่าสูงกว่าตัวเลขอื่น ๆ ก็ต่อเมื่อบริเวณนั้นของภาพที่ถูกรบกวนด้วยสัญญาณรบกวนเป็นตัวแทนในส่วนที่มีความสำคัญของภาพ ซึ่งเป็นการป้องกันปัญหาค่าเมทริกซ์ของภาพที่มีขนาดใหญ่มากจนส่งผลกระทบต่อประสิทธิภาพในการลดสัญญาณรบกวนภาพ [10] โดยในงานวิจัยนี้ได้ประยุกต์จาก [2] โดยการเปลี่ยนแปลงจากการการใช้ตัวกรองแบบขีดแบ่งแบบถาวร (Hard-Thresholding) มาใช้ SVD เพื่อสกัดลักษณะบางอย่างจากภาพแทนที่จะใช้การแปลงภาพให้กลายเป็นเวกเตอร์ 2 มิติและ 1 มิติ (Feature extraction) และเปลี่ยนจากตัวกรองวีเนอร์ (Wiener filter) เป็นตัวกรองขีดแบ่งแบบอ่อน (Soft thresholding) ซึ่งเป็นตัวกรองประเภทเส้นตรง (Linear filter) โดยแสดงได้ดังรูปที่ 11

⁵ อ้างอิงจาก Fig. 5a ใน [10]




รูปที่ 11 ขั้นตอนการทำงานของอัลกอริทึม WNMM⁶

2.2.2 งานวิจัยด้านการลดสัญญาณรบกวนภาพแบบใช้ชุดข้อมูลมาฝึกสอนให้กับโมเดล

นอกเหนือจากงานวิจัยด้านการลดสัญญาณรบกวนภาพแบบใช้อัลกอริทึมแล้วนั้น ยังมีงานวิจัยอีกรูปแบบหนึ่งคืองานวิจัยด้านการลดสัญญาณรบกวนภาพแบบใช้ชุดข้อมูลมาฝึกสอนให้กับโมเดลเพื่อลดสัญญาณรบกวนภาพ โดยการใช้ชุดข้อมูลที่มีลักษณะเป็นภาพขาว-ดำมาฝึกสอน ซึ่งในปี ค.ศ. 2012 Burger และคณะ. [6] เสนอในส่วนของการใช้โมเดลมัลติเลเยอร์ เพอร์เซพตรอน (Multi-layer Perceptron : MLP) มาลดสัญญาณรบกวนภาพผ่านการถูกฝึกสอนด้วยชุดข้อมูลภาพขาว-ดำ โดยใช้จำนวนชั้นนำเข้า (Input layer) 1 ชั้นและจำนวนโหนดคือ 256 โหนด และจำนวนชั้นซ่อน (Hidden layer) 2 ชั้น และจำนวนโหนดในชั้นที่ 1 คือ 2,000 โหนด และจำนวนโหนดในชั้นที่ 2 คือ 1,000 โหนด นอกจากนั้นในส่วนของชั้นผลลัพธ์จะใช้จำนวนโหนดทั้งหมด 10 โหนด และใช้เทคนิคในการปรับค่าน้ำหนักของโมเดลคือการเคลื่อนลงตามความชัน (Stochastic Gradient Descent) และในส่วนของจำนวนข้อมูลนำเข้าจะใช้ 362 ล้านรูปภาพในการฝึกสอนโมเดล ซึ่งใช้เวลาในการฝึกสอนทั้งสิ้นประมาณ 1 เดือน ซึ่งถือว่าค่อนข้างเปลืองทรัพยากรทางด้านฮาร์ดแวร์มาก โดยตัวอย่างสถาปัตยกรรมของโมเดล MLP แสดงได้ดังรูปที่ 12

⁶ อ้างอิงจาก Fig. 5b ใน [10]



รูปที่ 12 สถาปัตยกรรมของโมเดล MLP ซึ่งประกอบไปด้วยชั้นข้อมูลนำเข้า ชั้นซ่อน และชั้นผลลัพธ์ ต่อมาในปี ค.ศ 2017 ได้มีงานวิจัยเกี่ยวกับการใช้โครงข่ายประสาทเทียม (Convolutional Neural Network) โดย K. Zhang และคณะ. [11] ได้ประยุกต์ใช้การเรียนรู้แบบเรซิดิวล เลิร์นนิง (Residual learning) มาร่วมกับโครงข่ายประสาทเทียมเพื่อช่วยเพิ่มประสิทธิภาพในการลดสัญญาณรบกวนของภาพ และได้ใช้การทำให้เป็นมาตรฐานเดียวกัน (Normalization) ด้วยชั้นแบช นอมอร์ไลซ์เซชัน (Batch normalization layer) [12] โดยโมเดล DnCNN ได้ใช้การเรียนรู้เรซิดิวล เลิร์นนิง (Residual Learning) เพื่อทำให้การลดสัญญาณรบกวนภาพที่ถูกรบกวนด้วยสัญญาณรบกวนแบบเกาส์เซียนนั้นสามารถลดสัญญาณรบกวนได้มีประสิทธิภาพยิ่งขึ้น เนื่องจากในงานทางด้านคอมพิวเตอร์วิชัน [8, 13-15] แสดงให้เห็นถึงความสามารถของการเรียนรู้เรซิดิวล เลิร์นนิงในงานด้านต่าง ๆ ได้อย่างมีประสิทธิภาพ นอกจากนั้นการใช้ชั้นแบช นอมอร์ไลซ์เซชัน (Batch Normalization layer) นั้นยังส่งผลต่อการเพิ่มขึ้นของความเร็วในการฝึกสอนของโมเดล DnCNN อีกด้วย และในส่วนของการใช้ชั้นเรคตีไฟด์เชิงเส้น (Rectified Linear Unit layer: ReLU) นั้นเพื่อสกัดภาพต้นฉบับออกมาจากภาพที่ถูกสัญญาณรบกวน ในส่วนของข้อมูลฝึกสอนนั้นจะใช้ข้อมูลภาพแบบแผ่นแปะ และไม่ได้ใช้จำนวนข้อมูลฝึกสอนมากเท่ากับ [6] เนื่องจากว่าในงานวิจัย [9, 11] พบว่าเมื่อใช้จำนวนข้อมูลฝึกสอนเป็นจำนวนมหาศาลนั้นจะเพิ่มประสิทธิภาพของโมเดลได้ไม่ต่างมากนักจากการใช้จำนวนข้อมูลฝึกสอนที่น้อยกว่า

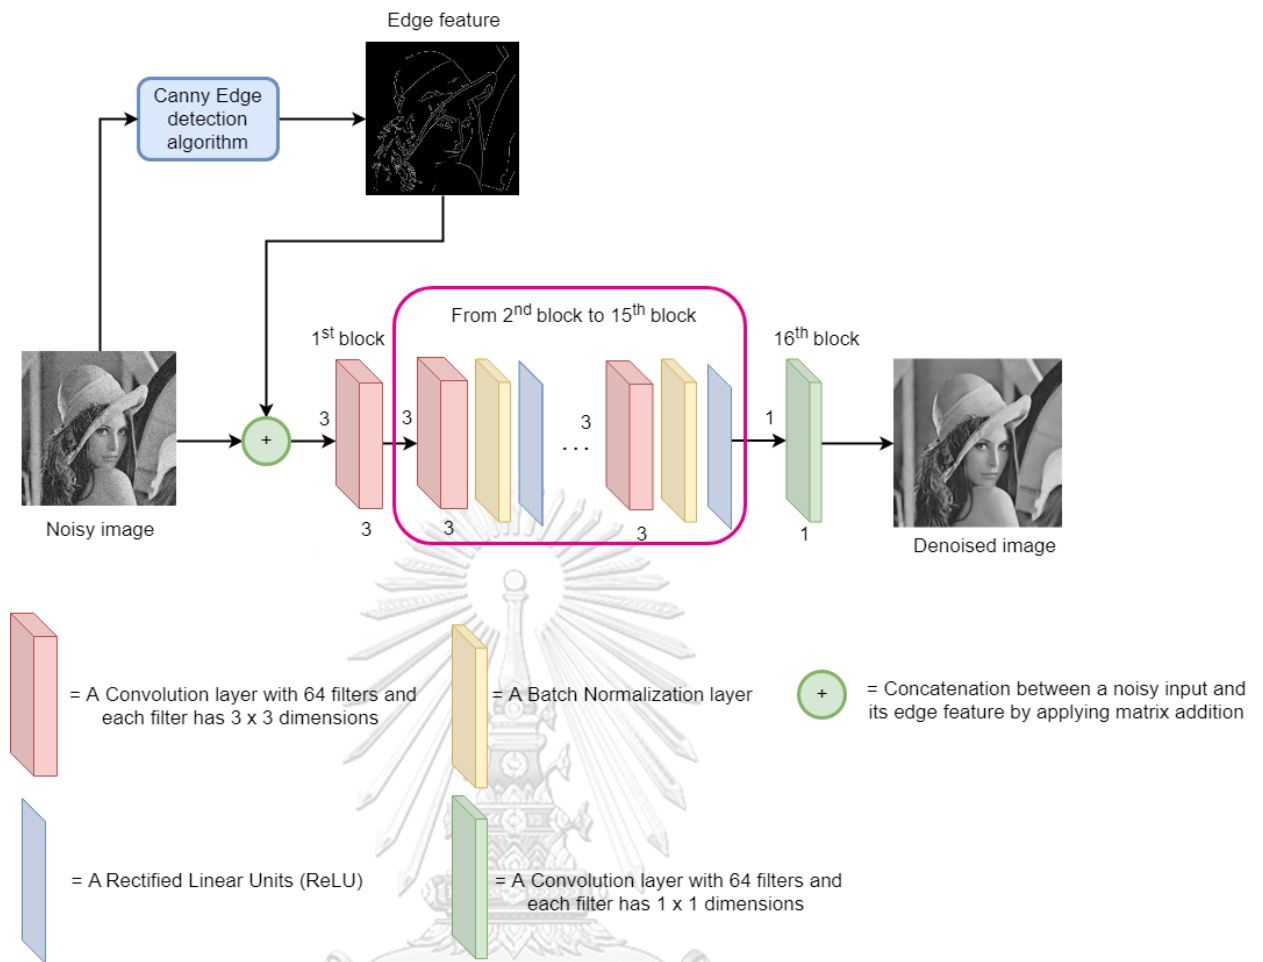
บทที่ 3

แนวคิดและวิธีการดำเนินงาน

ในบทที่ 3 จะนำเสนอเกี่ยวกับวิธีการใช้การเรียนรู้เชิงลึกเพื่อเข้ามาลดสัญญาณรบกวนภาพแบบสัญญาณรบกวนเกาส์เซียน โดยจะแบ่งขั้นตอนออกเป็น 2 ขั้นตอน คือขั้นตอนการเตรียมข้อมูล ชุดข้อมูลฝึกสอนและชุดข้อมูลทดสอบ และขั้นตอนการทดลองและผลการทดลอง

3.1 แนวคิดที่เสนอในการทดลอง

สำหรับงานวิจัยที่เกี่ยวข้องกับการลดสัญญาณรบกวนภาพแบบเกาส์เซียนที่ผู้วิจัยได้ศึกษามานั้นแสดงให้เห็นถึงข้อจำกัดบางอย่างของงานวิจัยด้านการลดสัญญาณรบกวนแบบใช้อัลกอริทึมและงานวิจัยด้านการลดสัญญาณรบกวนแบบใช้ชุดข้อมูลมาฝึกสอนให้กับโมเดล เช่น พารามิเตอร์ที่มีจำนวนมาก หรือระยะเวลาในการฝึกสอนค่อนข้างใช้เวลานาน ผู้วิจัยจึงได้เสนอแนวคิดที่จะใช้เส้นแบ่งระหว่างวัตถุกับพื้นหลัง (Edge) ที่ได้มาจากอัลกอริทึมในการหาเส้นขอบภาพคือ Canny Edge detection Algorithm [16] เข้ามาช่วยในส่วนของโมเดลการเรียนรู้เชิงลึก กล่าวคือการนำคุณลักษณะประจำของเส้นแบ่งระหว่างวัตถุกับพื้นหลังมาใช้รวมเข้ากับภาพที่ถูกรบกวนด้วยสัญญาณรบกวนเพื่อช่วยให้โมเดลมีประสิทธิภาพในด้านการลดสัญญาณรบกวนภาพมากยิ่งขึ้น เนื่องจากผู้วิจัยสังเกตเห็นว่าเส้นแบ่งระหว่างวัตถุกับพื้นหลังเป็นลักษณะที่สำคัญอย่างหนึ่งของภาพสำหรับโมเดลที่ใช้ลดสัญญาณรบกวนภาพแบบเกาส์เซียน ผู้วิจัยใช้การรวมกันระหว่างเวกเตอร์เส้นแบ่งระหว่างวัตถุกับพื้นหลังกับเวกเตอร์ภาพที่ถูกรบกวนด้วยสัญญาณรบกวนแบบเกาส์เซียนจะใช้การเรียงต่อกัน (Concatenation) และใช้ชั้นคอนโวลูชัน (Convolutional layer) และชั้นแบช นอร์มัลไลเซชัน (Batch Normalization layer) และใช้ชั้นเรคตีไฟด์เชิงเส้น (Rectified Linear Unit layer: ReLU) รวมกันทั้งหมด 16 ชั้น แนวคิดที่เสนอในการทดลองแสดงได้ดังรูปที่ 13



รูปที่ 13 แนวคิดที่เสนอในการทดลองในการใช้เส้นแบ่งระหว่างวัตถุกับพื้นหลังเข้ามาประยุกต์ร่วมกับภาพที่ถูกรบกวนด้วยสัญญาณรบกวนภาพ

3.2 ขั้นตอนการเตรียมชุดข้อมูลฝึกสอนและชุดข้อมูลทดสอบ


ผู้วิจัยได้จัดเตรียมชุดข้อมูลภาพสำหรับการทดลองโดยเลือกใช้ชุดข้อมูลฝึกสอนคือชุดข้อมูลภาพเบิร์กลีย์ 400 ภาพ (The Berkeley Segmentation Dataset and Benchmark 400) และเลือกใช้ชุดข้อมูลภาพเบิร์กลีย์ 68 ภาพ (The Berkeley Segmentation Dataset and Benchmark 68) และชุดข้อมูลภาพ 12 ภาพ (Set12 dataset) เพื่อทดสอบประสิทธิภาพของโมเดล

3.2.1 ขั้นตอนการประมวลผลก่อนหน้าสำหรับรูปภาพ (Preprocessing image)

สำหรับในขั้นตอนการประมวลผลก่อนหน้าสำหรับรูปภาพนั้นจะประกอบไปด้วยการเพิ่มสัญญาณรบกวนภาพให้กับรูปภาพ (Noise generation) และการแปลงรูปภาพให้อยู่ในรูปของเวกเตอร์นัมพาย (NumPy)

3.2.1.1 การเพิ่มสัญญาณรบกวนเกาส์เซียนภาพให้กับรูปภาพ (Noise generation)

สำหรับการเพิ่มสัญญาณให้กับรูปภาพในชุดข้อมูลภาพเบิร์กลีย์ 400 ภาพ (The Berkeley Segmentation Dataset and Benchmark 400) ด้วยสัญญาณรบกวนเกาส์เซียนนั้นจะถูกสุ่มค่าเป็นตัวเลขออกมาและถูกจัดเก็บไว้ในรูปของเมทริกซ์ที่มีขนาดเท่ากับขนาดของรูปภาพชุดข้อมูลภาพเบิร์กลีย์ 400 โดยการสุ่มตัวเลขเหล่านั้นจะใช้การสุ่มแบบการกระจายตัวปกติ (Normal distribution) และกำหนดให้ค่าเฉลี่ย (Mean) มีค่าเป็น 0 และค่าส่วนเบี่ยงเบนมาตรฐาน (Standard deviation) เป็นระดับความเข้มข้นของสัญญาณรบกวนโดยจะมีระดับได้แต่ 0 ถึง 50 เมื่อได้ตัวเลขเหล่านั้นมาแล้วจึงนำไปบวกเข้ากับเวกเตอร์รูปภาพเพื่อสร้างรูปภาพที่ถูกรบกวนด้วยสัญญาณรบกวนเกาส์เซียน ตัวอย่างของสัญญาณรบกวนภาพที่ถูกสุ่มขึ้นมาแสดงดังรูปที่ 14



รูปที่ 14 สัญญาณรบกวนภาพแบบเกาส์เซียนที่ถูกสุ่มขึ้นมา

3.2.1.2 การแปลงรูปภาพให้อยู่ในรูปของเวกเตอร์นัมพาย (NumPy)


สำหรับการแปลงรูปให้อยู่ในรูปของเวกเตอร์นัมพาย (NumPy) นั้นถือว่าเป็นขั้นตอนปฏิบัติเบื้องต้นสำหรับงานด้านคอมพิวเตอร์วิชัน (Computer Vision) เนื่องจากคอมพิวเตอร์จะสามารถอ่านและจัดการไฟล์รูปภาพได้ก็ต่อเมื่อไฟล์ภาพนั้นถูกแปลงให้เป็นเวกเตอร์ โดยในงานวิทยานิพนธ์ฉบับนี้จะใช้นัมพายซึ่งเป็นเครื่องมือในภาษาไพธอนในการแปลงรูปภาพให้เป็นเวกเตอร์ ตัวอย่างของรูปภาพเมื่อถูกแปลงเป็นเวกเตอร์นัมพายแสดงดังรูปที่ 15

```
[ [162 162 162 ... 169 155 128]
  [162 162 162 ... 169 155 128]
  [162 162 162 ... 169 155 128]
  ...
  [ 42  42  49 ... 104 100  98]
  [ 43  43  54 ... 103 105 108]
  [ 43  43  54 ... 103 105 108]]
```

รูปที่ 15 ตัวอย่างของรูปภาพเมื่อถูกแปลงเป็นเวกเตอร์นัมพาย

3.2.1.3 การเพิ่มจำนวนรูปภาพบนชุดข้อมูลฝึกสอน (Augmentation)

เนื่องจากโมเดลการเรียนรู้เชิงลึกนั้นต้องการจำนวนข้อมูลบนชุดข้อมูลฝึกสอนเป็นจำนวนมากเพื่อให้โมเดลสามารถทำงานได้อย่างมีประสิทธิภาพ สำหรับงานด้านการลดสัญญาณรบกวนภาพแบบเกาส์เซียนนั้นต้องการจำนวนข้อมูลมากเช่นกัน ผู้วิจัยจึงได้เพิ่มจำนวนข้อมูลบนชุดข้อมูลฝึกสอนด้วยวิธีการกลับรูปภาพบนชุดข้อมูลจากซ้ายไปขวา หรือ หมุนภาพไป 90 องศา หรือ หมุนภาพไป 45 องศา เป็นต้น เพื่อให้ได้จำนวนของข้อมูลฝึกสอนที่เพิ่มมากขึ้นดังรูปที่ 16



รูปที่ 16 การเพิ่มจำนวนข้อมูลฝึกสอน (Augmentation)

3.3 การทดลองและผลการทดลอง

สำหรับการทดลองในงานวิทยานิพนธ์ฉบับนี้แบ่งการทดลองออกเป็น 3 กลุ่มคือ 1) การทดลองลดสัญญาณรบกวนภาพแบบเกาส์เซียนด้วยการฝึกสอนแบบแบ่งระดับความเข้มข้น 2) การทดลองลดสัญญาณรบกวนภาพแบบเกาส์เซียนด้วยการฝึกสอนแบบคละระดับความเข้มข้น และ 3) การทดลองลดสัญญาณรบกวนภาพจริง

3.3.1 การฝึกสอน

สำหรับการทดลองลดสัญญาณรบกวนภาพแบบเกาส์เซียนด้วยการฝึกสอนแบบแบ่งระดับความเข้มข้นและการทดลองลดสัญญาณรบกวนภาพแบบเกาส์เซียนด้วยการฝึกสอนแบบคละระดับความเข้มข้นใช้แนวทางการฝึกสอนเดียวกัน เริ่มแรกผู้วิจัยใส่สัญญาณรบกวนภาพแบบเกาส์เซียนเข้าไปในชุดข้อมูลภาพเบิร์ตส์ และนำข้อมูลภาพเบิร์ตส์ที่มีสัญญาณรบกวนเกาส์เซียนไปหาเส้นแบ่งระหว่างวัตถุกับพื้นหลังของภาพ (Edge) จากนั้นนำเส้นแบ่งระหว่างวัตถุกับพื้นหลังของภาพไปรวมเข้ากับข้อมูลภาพเบิร์ตส์ที่มีสัญญาณรบกวนเกาส์เซียนเพื่อป้อนเป็นข้อมูลนำเข้าให้กับโมเดล

เพื่อให้โมเดลลดสัญญาณรบกวนบนภาพและแสดงผลลัพธ์ของภาพออกมา โดยจำนวนชุดข้อมูลฝึกสอนจะถูกเพิ่มจำนวนด้วยการเพิ่มจำนวนรูปภาพบนชุดข้อมูลฝึกสอน (Augmentation) เป็นจำนวน 55,000 รูปที่มีขนาด 180x180 พิกเซล สำหรับโมเดลจะประกอบไปด้วย 16 บล็อก โดยบล็อกที่ 1 จะมีชั้นคอนโวลูชันที่มีขนาดตัวกรอง 3x3 และจำนวนตัวกรอง 64 ตัวกรอง สาเหตุที่เลือกใช้ตัวกรองขนาด 3x3 นั้นเนื่องจาก Kobayashi T. [17] แสดงให้เห็นถึงประสิทธิผลของการเลือกใช้ตัวกรองขนาด 3x3 ว่ามีประสิทธิผลดีกว่าตัวกรองขนาดอื่นและเหมาะกับการแยกคุณสมบัติของภาพมากกว่า ส่วนบล็อกที่ 2 ถึงบล็อกที่ 15 จะมีชั้นคอนโวลูชันที่มีขนาดตัวกรอง 3x3 และจำนวนตัวกรอง 64 ตัวกรอง และชั้นชั้นแบบ นอมอร์ไลซ์เซชันและชั้นเรกติไฟด์เชิงเส้น โดยผู้วิจัยเลือกใช้ชั้นชั้นแบบ นอมอร์ไลซ์เซชันเพื่อเร่งความเร็วในการฝึกสอนของโมเดล และเลือกใช้ชั้นเรกติไฟด์เชิงเส้นเนื่องจาก Li และคณะ. [18] แสดงให้เห็นถึงประสิทธิภาพในการลู่เข้าของโมเดลอย่างรวดเร็วเมื่อใช้ชั้นเรกติไฟด์เชิงเส้นและช่วยลดปัญหาการขาดหายไปของเกรเดียนท์ (Gradient vanishing) และบล็อกสุดท้ายคือบล็อกที่ 16 จะมีชั้นคอนโวลูชันที่มีขนาดตัวกรอง 3x3 และจำนวนตัวกรองเพียง 1 ตัวกรองเพื่อสร้างภาพที่ถูกลดสัญญาณรบกวนออกมา สำหรับพารามิเตอร์ของโมเดลในวิทยานิพนธ์นี้ ผู้วิจัยได้เลือกใช้พารามิเตอร์ในการปรับอัตราการเรียนรู้ด้วยวิธีการสโตแคสติกเกรเดียนต์เดสเซนท์ (Stochastic Gradient Descent หรือ SGD) โดยปรับค่าอัตราการเรียนรู้ที่ 0.001 และค่าโมเมนตัมอยู่ที่ 0.9 เนื่องจากการตั้งค่าให้อัตราการเรียนรู้มีค่าต่ำนั้นจะทำให้โมเดลสามารถลู่เข้าได้ดีกว่าการตั้งค่าให้อัตราการเรียนรู้เชิงลึกมีค่าสูงและช่วยให้โมเดลการเรียนรู้เชิงลึกไม่ติดอยู่ที่โลคัลออปติมา (Local optima) และจำนวนรอบในการฝึกสอนคือ 100 รอบ และจำนวนตัวอย่างที่ส่งเข้าไปแต่ละรอบในการฝึกสอนคือ 100 ตัวอย่าง โดยแต่ละรอบของการฝึกสอน (Epoch) ใช้เวลา 50 นาทีโดยประมาณ นอกจากนั้นพารามิเตอร์สำหรับการทำให้ดีที่สุด (Optimization) กับตัวโมเดลนั้น จะใช้การทำให้ดีที่สุดแบบอาดัม (Adam optimization) และการกำหนดค่าน้ำหนักเริ่มต้นให้กับโมเดล (Initialize weight) จะใช้เทคนิคการเริ่มต้นของซาร์เวียร์ (Xavier initialization) [19] และฟังก์ชันต้นทุน (Cost function) จะใช้ค่าเฉลี่ยความผิดพลาดกำลังสอง (Mean Square Error) ในการคำนวณความแตกต่างระหว่างภาพที่ถูกลดสัญญาณรบกวนกับภาพต้นฉบับ

3.3.2 การทดสอบ













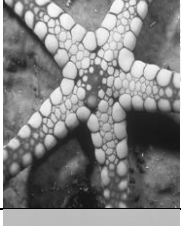
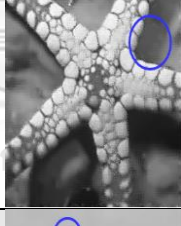

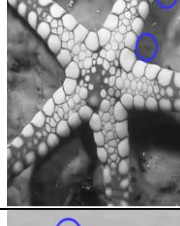








การทดสอบในวิทยานิพนธ์นี้ทดสอบประสิทธิภาพของโมเดลบนการฝึกสอนแบบแบ่งระดับความเข้มข้นของสัญญาณรบกวนภาพเกาส์เซียนและการฝึกสอนแบบลดระดับความเข้มข้นของสัญญาณรบกวนภาพเกาส์เซียน การทดสอบใช้ชุดข้อมูลภาพเบิร์กกลีย์ 68 ภาพ (The


Berkeley Segmentation Dataset and Benchmark 68) ประกอบด้วยภาพถ่ายขาว-ดำจากสภาพแวดล้อมจริงจำนวน 68 ภาพ และชุดข้อมูลภาพ 12 ภาพ (Set12 dataset) ประกอบด้วยภาพถ่ายขาว-ดำจากสภาพแวดล้อมจริงจำนวน 12 ภาพ โดยมาตรวัดที่ใช้ในการวัดประสิทธิภาพคือมาตรวัดความคล้ายคลึงกันของโครงสร้างหลายระดับ (Multi-Scale Structural Similarity: MS-SSIM) โดยถ้าภาพที่ถูกลดสัญญาณรบกวนมีความคล้ายคลึงกับภาพต้นฉบับจะได้ค่าความคล้ายคลึงกันของโครงสร้างหลายระดับเป็น 1 แต่ถ้าไม่คล้ายคลึงกันจะได้ค่าเป็น 0

3.3.3 ผลการทดลอง

ในการทดลองจะเปรียบเทียบกับอัลกอริทึม BM3D [2] และ DnCNN [11] ที่ได้รับการยอมรับว่าเป็นอัลกอริทึมที่ดีที่สุดในปัจจุบันสำหรับงานด้านลดสัญญาณรบกวนภาพ โดยผลการทดลองในแต่ละระดับความเข้มข้นของสัญญาณรบกวนนั้นจะถูกวัดประสิทธิภาพบนมาตรวัดความคล้ายคลึงกันของโครงสร้างหลายระดับ (Multi-Scale Structural Similarity: MS-SSIM) สำหรับผลการทดลองแสดงดังต่อไปนี้ ตารางที่ 1 ตารางเปรียบเทียบผลลัพธ์รูปภาพของการลดสัญญาณรบกวนภาพเกาส์เซียนบนระดับความเข้มข้นที่ 15 ระหว่างอัลกอริทึม BM3D และ DnCNN และโมเดลของผู้วิจัยบนชุดข้อมูลทดสอบ Set12 ตารางที่ 2 แสดงประสิทธิภาพของการลดสัญญาณรบกวนภาพเกาส์เซียนด้วยระดับความเข้มข้นของสัญญาณรบกวนภาพเกาส์เซียนที่ระดับ 15 (ฝึกสอนแบบแบ่งระดับความเข้มข้น) ในชุดข้อมูลภาพ 12 ภาพระหว่างอัลกอริทึม BM3D DnCNN ด้วยมาตรวัด MS-SSIM (เป็นการทดลองเดียวกันกับตารางที่ 1) ตารางที่ 1 ผลการทดลองบนชุดข้อมูลทดสอบ Set12 บนระดับความเข้มข้นที่ 25 (ฝึกสอนแบบแบ่งระดับความเข้มข้น) ซึ่งวัดในรูปแบบค่า MS-SSIM โดยตัวหนาคือผลลัพธ์ที่ดีที่สุด ตารางที่ 4 ผลการทดลองบนชุดข้อมูลทดสอบ Set12 บนระดับความเข้มข้นที่ 50 (ฝึกสอนแบบแบ่งระดับความเข้มข้น) ซึ่งวัดในรูปแบบค่า MS-SSIM โดยตัวหนาคือผลลัพธ์ที่ดีที่สุด ตารางที่ 5 ผลการทดสอบบนชุดข้อมูลทดสอบ BSD68 (The Berkeley Segmentation Dataset and Benchmark 68) (ฝึกสอนแบบแบ่งระดับความเข้มข้น) ซึ่งวัดในรูปแบบค่าเฉลี่ยของมาตรวัด MS-SSIM โดยตัวหนาคือผลลัพธ์ที่ดีที่สุด ตารางที่ 2 การเปรียบเทียบประสิทธิภาพของโมเดลของผู้วิจัยระหว่างการฝึกสอนแบบละระดับความเข้มข้นกับแบบแบ่งระดับความเข้มข้นบนมาตรวัด MS-SSIM บนชุดข้อมูลทดสอบ Set12 และตารางที่ 3 การเปรียบเทียบประสิทธิภาพของโมเดลของผู้วิจัยระหว่างการฝึกสอนแบบละระดับความเข้มข้นกับแบบแบ่งระดับความเข้มข้นบนมาตรวัดแบบเฉลี่ย MS-SSIM บนชุดข้อมูลทดสอบ BSD68

ตารางที่ 4 ตารางเปรียบเทียบผลลัพธ์ของการลดสัญญาณรบกวนภาพเกาส์เซียนบนระดับความ
 เข้มข้นที่ 15 ระหว่างอัลกอริทึม BM3D และ DnCNN และโมเดลของผู้วิจัยบนชุดข้อมูลทดสอบ
 Set12

ชื่อรูป	Original image	BM3D	DnCNN	โมเดลของผู้วิจัย
Monarch				
Boat				
Airplane				
Starfish				
House				
Lena				



ตารางที่ 5 ผลการทดลองบนชุดข้อมูลทดสอบ Set12 บนระดับความเข้มข้นที่ 15 (ฝึกสอนแบบแบ่งระดับความเข้มข้น) ซึ่งวัดในรูปแบบค่า MS-SSIM โดยตัวหนาคือผลลัพธ์ที่ดีที่สุด

Method ($\sigma = 15$)	BM3D	DnCNN	โมเดลของผู้วิจัย
Monarch	0.886	0.911	0.965

Boat	0.770	0.889	0.886
Airplane	0.834	0.937	0.920
Starfish	0.802	0.940	0.941
House	0.846	0.959	0.894
Lena	0.846	0.916	0.913
Parrot	0.839	0.925	0.903
Camera man	0.831	0.910	0.919
Man	0.837	0.930	0.923
Barbara	0.849	0.886	0.933
Peppers	0.855	0.903	0.940
Couple	0.752	0.903	0.904
Average	0.872	0.917	0.920

ตารางที่ 6 ผลการทดลองบนชุดข้อมูลทดสอบ Set12 บนระดับความเข้มขั้นที่ 25 (ฝึกสอนแบบแบ่งระดับความเข้มขั้น) ซึ่งวัดในรูปแบบค่า MS-SSIM โดยตัวหนาคือผลลัพธ์ที่ดีที่สุด

Method ($\sigma = 25$)	BM3D	DnCNN	โมเดลของผู้วิจัย
Monarch	0.846	0.942	0.852
Boat	0.728	0.840	0.857
Airplane	0.771	0.894	0.872
Starfish	0.770	0.900	0.912
House	0.734	0.874	0.889

Lena	0.774	0.885	0.890
Parrot	0.771	0.852	0.839
Camera man	0.739	0.881	0.879
Man	0.775	0.891	0.895
Barbara	0.810	0.897	0.900
Peppers	0.811	0.909	0.941
Couple	0.711	0.857	0.884
Average	0.770	0.885	0.884

ตารางที่ 7 ผลการทดลองบนชุดข้อมูลทดสอบ Set12 บนระดับความเข้มข้นที่ 50 (ฝึกสอนแบบแบ่งระดับความเข้มข้น) ซึ่งวัดในรูปแบบค่า MS-SSIM โดยตัวหนาคือผลลัพธ์ที่ดีที่สุด

Method ($\sigma = 50$)	BM3D	DnCNN	โมเดลของผู้วิจัย
Monarch	0.724	0.886	0.795
Boat	0.571	0.739	0.816
Airplane	0.623	0.826	0.843
Starfish	0.645	0.807	0.810
House	0.583	0.831	0.876
Lena	0.619	0.825	0.818
Parrot	0.633	0.743	0.813
Camera man	0.577	0.805	0.812
Man	0.633	0.824	0.792

Barbara	0.637	0.800	0.736
Peppers	0.675	0.847	0.737
Couple	0.569	0.754	0.752
Average	0.724	0.806	0.800

ตารางที่ 8 ผลการทดสอบบนชุดข้อมูลทดสอบ BSD68 (ฝึกสอนแบบแบ่งระดับความเข้มข้น) ซึ่งวัดในรูปแบบค่าเฉลี่ยของมาตรวัด MS-SSIM โดยตัวหนาคือผลลัพธ์ที่ดีที่สุด

Method	BM3D	DnCNN	โมเดลของผู้วิจัย
$\sigma = 15$	0.872	0.890	0.906
$\sigma = 25$	0.801	0.885	0.884
$\sigma = 50$	0.686	0.746	0.740

จากตารางที่ 1 นั้นตัวอย่างภาพของชุดข้อมูลทดสอบ Set12 ที่ถูกลดสัญญาณรบกวนภาพแบบเกาส์เซียนบนระดับความเข้มข้นที่ 15 โมเดลของผู้วิจัยนั้นสามารถให้ประสิทธิผลได้ในระดับดี เช่น ภาพ Monarch นั้นไม่มีจุดเบลอปรางในภาพและไม่มีจุดแปลกปลอมเช่นเดียวกัน ภาพ Boat ไม่มีจุดเบลอบริเวณข้างเรือ ภาพ Airplane ไม่มีจุดแปลกปลอมบนบริเวณปีกหลังของเครื่องบิน ภาพ Starfish ไม่เกิดพื้นที่เบลอบริเวณแขนของปลาดาว ภาพ House มีจุดเบลอน้อยกว่าอัลกอริทึมอื่น ภาพ Lena ไม่มีพื้นที่บริเวณพื้นหลังของภาพ ภาพ Parrot จะให้รายละเอียดของภาพที่ชัดเจนกว่าอัลกอริทึมอื่น ภาพ Camera man พื้นหลังของภาพบริเวณตึกจะให้ความคมชัดมากกว่าอัลกอริทึมอื่น ภาพ Man มีความคมชัดกว่าและไม่มีจุดแปลกปลอมเกิดขึ้น ภาพ Barbara จะให้ความคมชัดมากกว่าอัลกอริทึมอื่น ภาพ Peppers ให้ความคมชัดบนรอยหยักบนผิวของพริกมากกว่าอัลกอริทึมอื่น ภาพ Couple ไม่มีจุดแปลกปลอมปรากฏบนเพดานและบริเวณใต้กรอบรูปที่แขวนอยู่บนฝาผนัง เป็นต้น

จากตารางที่ 2 ซึ่งเป็นผลที่ได้จากนำรูปภาพในตารางที่ 1 ไปคำนวณค่าประสิทธิผลในการลดสัญญาณรบกวนภาพเกาส์เซียนด้วยมาตรวัด MS-SSIM พบว่าโมเดลของผู้วิจัยสามารถลดสัญญาณรบกวนภาพแบบเกาส์เซียนบนระดับความเข้มข้นที่ 15 ได้ดีกว่าอัลกอริทึม BM3D เนื่องจากประสิทธิภาพของโมเดลการเรียนรู้เชิงลึก และเมื่อเปรียบเทียบกับโมเดล DnCNN พบว่าโมเดลของผู้วิจัยสามารถทำงานได้ดีกว่าโมเดล DnCNN ในมาตรวัด MS-SSIM เนื่องจากการใช้เส้นแบ่งระหว่างวัตถุกับพื้นหลังเข้ามาประยุกต์ใช้นั้นจะส่งผลให้โมเดลของผู้วิจัยสามารถเข้าใจลักษณะบางอย่างของภาพที่ถูกรบกวนด้วยสัญญาณรบกวนได้เพิ่มมากขึ้นเนื่องจากได้รับคุณสมบัติบางอย่างจากเส้นแบ่งระหว่างวัตถุกับพื้นหลังเข้ามาช่วยในการลดสัญญาณรบกวนภาพ และจากตารางที่ 3 นั้น พบว่าโมเดลของผู้วิจัยสามารถลดสัญญาณรบกวนภาพได้ดีกว่าอัลกอริทึม BM3D และโมเดล DnCNN โดยวัดบนมาตรวัด MS-SSIM แบบเฉลี่ย

จากตารางที่ 3 การลดสัญญาณรบกวนภาพแบบเกาส์เซียนบนระดับความเข้มข้นที่ 25 เห็นได้ว่าโมเดลของผู้วิจัยนั้นสามารถลดสัญญาณรบกวนได้เทียบเท่าโมเดล DnCNN เนื่องจากสัญญาณรบกวนภาพแบบเกาส์เซียนมีระดับความเข้มข้นมากขึ้นทำให้โมเดลไม่สามารถลดสัญญาณรบกวนได้ดีและอัลกอริทึมแคนนี่ เอ็จ ดีเท็กซันนั้นยังอ่อนไหวกับสัญญาณรบกวนภาพแบบเกาส์เซียนที่มีความเข้มข้นสูง แต่ทว่าการประยุกต์ใช้เส้นแบ่งระหว่างวัตถุกับพื้นหลังยังช่วยให้โมเดลของผู้วิจัยสามารถลดสัญญาณรบกวนภาพแบบเกาส์เซียนได้ดีกว่าอัลกอริทึม BM3D และจากตารางที่ 3 โมเดลของผู้วิจัยสามารถลดสัญญาณรบกวนได้ดีกว่าเมื่อเทียบกับโมเดล DnCNN

จากตารางที่ 4 การลดสัญญาณรบกวนภาพแบบเกาส์เซียนบนระดับความเข้มข้นที่ 50 นั้นพบว่าโมเดลของผู้วิจัยมีประสิทธิผลในการลดสัญญาณรบกวนภาพบนระดับความเข้มข้นนี้ได้ไม่เท่ากับโมเดล DnCNN เนื่องจากว่าความเข้มข้นของสัญญาณรบกวนนั้นมีความเข้มข้นมากซึ่งส่งผลต่อการเรียนรู้ของโมเดลผู้วิจัยและส่งผลต่ออัลกอริทึมแคนนี่ เอ็จ ดีเท็กซัน ในการหาเส้นแบ่งระหว่างวัตถุกับพื้นหลังเนื่องจากว่าตัวอัลกอริทึมนี้ไปหาเส้นแบ่งระหว่างวัตถุกับพื้นหลังบนภาพที่มีสัญญาณรบกวนมาก และอัลกอริทึมแคนนี่ เอ็จ ดีเท็กซันนั้นจะทำงานไม่ได้ประสิทธิผลมากนักเมื่อทำงานกับภาพที่มีสัญญาณรบกวนมาก และจากการทดลองลดสัญญาณรบกวนภาพแบบเกาส์เซียนที่ระดับความเข้มข้น 15 25 และ 50 บนชุดข้อมูลทดสอบภาพ 12 ภาพนั้นพบว่าโมเดลของผู้วิจัยสามารถลดสัญญาณรบกวนได้มีประสิทธิผลกับภาพที่มีจำนวนวัตถุภายในภาพน้อยและมีรายละเอียดของวัตถุไม่ซับซ้อนมากนัก เนื่องจากว่าการเรียนรู้เชิงลึกที่ถูกระยุกต์ใช้กับงานด้านการลดสัญญาณรบกวนภาพ

แบบเกาส์เซียนนั้นมีข้อจำกัดเกี่ยวกับการสกัดคุณลักษณะของภาพเนื่องจากการรบกวนคุณลักษณะของภาพด้วยสัญญาณรบกวนภาพแบบเกาส์เซียนที่ถูกเพิ่มเข้าไปในภาพ

จากตารางที่ 5 การลดสัญญาณรบกวนภาพแบบเกาส์เซียนบนระดับความเข้มข้นที่ 15 25 และ 50 บนชุดข้อมูลทดสอบภาพเบิร์กลีย์ 68 ภาพนั้นพบว่าโมเดลของผู้วิจัยสามารถลดสัญญาณรบกวนได้มีประสิทธิภาพบนระดับความเข้มข้นของสัญญาณรบกวนเกาส์เซียนที่ 15 แต่บนระดับความเข้มข้นของสัญญาณรบกวนเกาส์เซียนที่ 25 และ 50 นั้นพบว่ายังทำประสิทธิภาพได้ไม่เทียบเท่ากับโมเดล DnCNN

เมื่อเปรียบเทียบการฝึกสอนแบบแบ่งระดับความเข้มข้นของสัญญาณรบกวนภาพเกาส์เซียนกับการฝึกสอนแบบลดระดับความเข้มข้นของสัญญาณรบกวนภาพเกาส์เซียนพบว่าโมเดลของผู้วิจัยที่ฝึกสอนแบบลดระดับความเข้มข้นของสัญญาณรบกวนภาพเกาส์เซียนให้ประสิทธิภาพได้ดีต่ำกว่าโมเดลของผู้วิจัยที่ฝึกสอนแบบแบ่งระดับความเข้มข้นของสัญญาณรบกวนภาพเกาส์เซียนเนื่องจากโมเดลของผู้วิจัยพยายามปรับค่าน้ำหนักให้เหมาะสมกับความเข้มข้นในแต่ละระดับ และโมเดลการเรียนรู้เชิงลึกจะไม่สามารถให้ประสิทธิภาพได้ดีซึ่งเป็นข้อจำกัดของโมเดลการเรียนรู้เชิงลึกในงานด้านการลดสัญญาณรบกวนภาพเมื่อฝึกสอนในชุดข้อมูลฝึกสอนแบบลดระดับความเข้มข้น [11] โดยผลการเปรียบเทียบประสิทธิภาพในชุดข้อมูล Set 12 ระหว่างโมเดลของผู้วิจัยแบบลดระดับความเข้มข้นเปรียบเทียบกับโมเดลของผู้วิจัยแบบแบ่งระดับความเข้มข้นแสดงดังตารางที่ 6 จะเห็นได้ว่ามีภาพ 3 ภาพจากชุดข้อมูลทดสอบ Set12 ที่โมเดลของผู้วิจัยแบบแบ่งระดับความเข้มข้นนั้นมีประสิทธิภาพดีกว่าโมเดลของผู้วิจัยแบบลดระดับความเข้มข้นเนื่องจากโมเดลของผู้วิจัยแบบลดระดับความเข้มข้นนั้นพยายามปรับค่าน้ำหนักให้เหมาะสมกับทุกระดับของความเข้มข้นในสัญญาณรบกวนภาพเกาส์เซียนแต่หาว่าไม่สามารถปรับได้อย่างเหมาะสมและความเข้มข้นของสัญญาณรบกวนภาพแบบเกาส์เซียนที่ระดับความเข้มข้น 50 ยังส่งผลกระทบต่อค่าปรับค่าน้ำหนักที่เหมาะสม จึงไม่สามารถลดสัญญาณรบกวนภาพแบบเกาส์เซียนบนระดับความเข้มข้นที่ 50 ได้อย่างมีประสิทธิภาพ และผลการเปรียบเทียบประสิทธิภาพในชุดข้อมูล BSD68 ระหว่างโมเดลของผู้วิจัยแบบลดระดับความเข้มข้นเปรียบเทียบกับโมเดลของผู้วิจัยแบบแบ่งระดับความเข้มข้นแสดงดังตารางที่ 7

ตารางที่ 9 การเปรียบเทียบประสิทธิภาพของโมเดลของผู้วิจัยระหว่างการฝึกสอนแบบคละระดับความ
เข้มข้นกับแบบแบ่งระดับความเข้มข้นบนมาตรวัด MS-SSIM บนชุดข้อมูลทดสอบ Set12

ชื่อรูปภาพ (ระดับความเข้มข้นของสัญญาณ รบกวนภาพแบบเกาส์เซียนในข้อมูลทดสอบ)	โมเดลของผู้วิจัยแบบ คละระดับความเข้มข้น	โมเดลของผู้วิจัยแบบแบ่ง ระดับความเข้มข้น
Monarch (15)	0.772	0.965
Boat (15)	0.803	0.886
Airplane (15)	0.814	0.920
Starfish (15)	0.763	0.941
House (25)	0.854	0.889
Lena (25)	0.785	0.890
Parrot (25)	0.788	0.839
Camera man (25)	0.794	0.879
Man (50)	0.730	0.785
Barbara (50)	0.740	0.726
Peppers (50)	0.743	0.722
Couple (50)	0.754	0.735
Average	0.778	0.848

ตารางที่ 10 การเปรียบเทียบประสิทธิภาพของโมเดลของผู้วิจัยระหว่างการฝึกสอนแบบคละระดับ ความเข้มข้นกับแบบแบ่งระดับความเข้มข้นบนมาตรวัดแบบเฉลี่ย MS-SSIM บนชุดข้อมูลทดสอบ BSD68

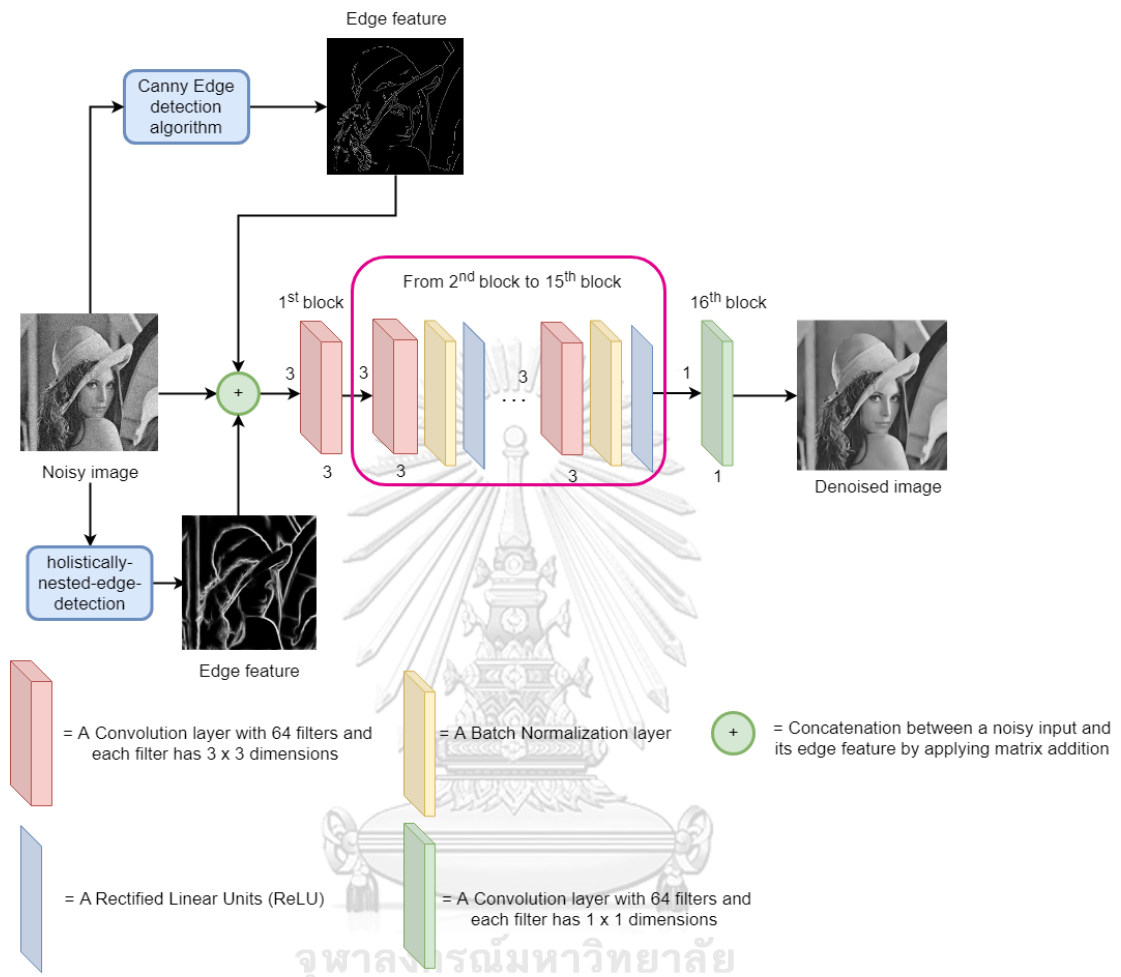
ชื่อชุดข้อมูล	โมเดลของผู้วิจัยแบบ คละระดับความเข้มข้น	โมเดลของผู้วิจัยแบบแบ่ง ระดับความเข้มข้น
BSD68	0.735	0.812

เนื่องจากการอัลกอริทึมแคนนี่ เอ็จ ดีเท็กชันนั้นจะให้เส้นแบ่งระหว่างวัตถุกับพื้นหลังของภาพที่มีความละเอียดในส่วนพื้นหลังของภาพ ซึ่งผู้วิจัยวิเคราะห์ว่าเส้นแบ่งระหว่างวัตถุกับพื้นหลังของภาพรูปแบบนี้อาจจะไม่เพียงพอต่อการลดสัญญาณรบกวนของภาพจริง จึงได้มีแนวคิดที่จะใช้การเรียนรู้เชิงลึกเข้ามาประยุกต์ใช้กับการลดสัญญาณรบกวนภาพจริง โดยได้ใช้โมเดล HED [20] เพื่อสกัดเส้นแบ่งระหว่างภาพกับวัตถุ โดยผู้วิจัยเลือกใช้โมเดล HED เนื่องจากโมเดล HED ให้รายละเอียดของวัตถุในภาพโดยจะเน้นไปที่พื้นหลังของวัตถุที่มีขนาดใหญ่ในภาพ ซึ่งผู้วิจัยคาดว่าเส้นแบ่งระหว่างวัตถุกับพื้นหลังที่ได้จากโมเดล HED จะช่วยเพิ่มความเข้าใจในคุณลักษณะของภาพที่ถูกรบกวนด้วยสัญญาณรบกวนมากขึ้นและเพิ่มประสิทธิภาพของการลดสัญญาณรบกวนภาพจริง นอกจากนั้นในขั้นตอนการฝึกสอนโมเดลของผู้วิจัยเพื่อลดสัญญาณรบกวนภาพจริงนั้นมีข้อจำกัดอยู่บางอย่างคือ เนื่องจากไม่มีข้อมูลเฉลี่ยสำหรับภาพที่ถูกรบกวนโดยสัญญาณรบกวนภาพจริง [11] จึงได้นำโมเดลของผู้วิจัยไปฝึกสอนกับชุดข้อมูลภาพเบิร์กลีย์ 400 ภาพ (The Berkeley Segmentation Dataset and Benchmark 400) ที่ถูกรบกวนด้วยสัญญาณรบกวนภาพเกาส์เซียนที่ระดับความเข้มข้นแบบคละ คือภายในชุดข้อมูลนี้จะถูกใส่ความเข้มข้นของสัญญาณรบกวนเกาส์เซียนที่ระดับ 15 25 และ 50 และกำหนดพารามิเตอร์ต่าง ๆ ให้เหมือนกับการทดลองในส่วนที่ 3.1 นอกจากนั้นชุดข้อมูลทดสอบนั้นผู้วิจัยได้เก็บข้อมูลภาพถ่ายจากกล้องดิจิทัล Canon 3Ti โดยถ่ายในสภาพแวดล้อมที่เอื้อต่อการเกิดสัญญาณรบกวนภาพ เช่น ถ่ายภาพในสภาพแวดล้อมที่มีแสงน้อย เป็นต้น

3.3.4 แนวคิดใหม่ที่เสนอในการทดลอง

สำหรับแนวคิดที่เสนอในการทดลองครั้งนี้คือการประยุกต์ใช้โมเดล HED เข้ามาช่วยสกัดเส้นแบ่งระหว่างวัตถุกับพื้นหลังและนำเส้นแบ่งระหว่างวัตถุกับพื้นหลังที่ได้จากโมเดล HED ไป

รวมเข้ากับเส้นแบ่งระหว่างวัตถุกับพื้นหลังที่ได้จากอัลกอริทึมแคนนี่ เอ็จ ดีเท็กชันก่อนที่จะป้อนเป็นข้อมูลนำเข้าให้กับโมเดลของผู้วิจัย โดยแสดงได้ดังรูปที่ 17



รูปที่ 17 โมเดลที่นำเสนอในการลดสัญญาณรบกวนภาพจริงที่ถูกฝึกสอนบนชุดข้อมูลที่ถูกรบกวนด้วยสัญญาณภาพเกาส์เซียนแบบคละระดับความเข้มข้นที่ 15 25 และ 50

3.3.5 ชุดข้อมูลทดสอบ

สำหรับการเก็บข้อมูลของชุดข้อมูลทดสอบนั้นจะเก็บจากภาพถ่ายดิจิทัลที่มีสัญญาณรบกวนภาพจริงบนกล้องดิจิทัล โดยผู้วิจัยได้เก็บชุดข้อมูลทดสอบมาเป็นจำนวน 10 รูป โดยถ่ายจากสภาพแวดล้อมในตอนกลางคืนที่มีแสงน้อยซึ่งส่งผลให้เกิดสัญญาณรบกวนภาพจริงบนภาพถ่ายดิจิทัล เมื่อได้รับชุดข้อมูลทดสอบมาครบแล้วจะนำชุดข้อมูลทดสอบนี้ไปแปลงเป็นภาพขาว-ดำเพื่อเตรียมนำไปทดสอบกับโมเดลของผู้วิจัยในลำดับถัดไป สำหรับตัวอย่างของชุดข้อมูลทดสอบ (ภาพขาว-ดำ) จะแสดงดังตารางที่ 8

ตารางที่ 11 ชุดข้อมูลทดสอบภาพที่ถูกรบกวนด้วยสัญญาณรบกวนภาพจริง

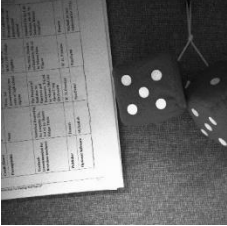











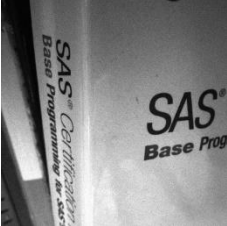







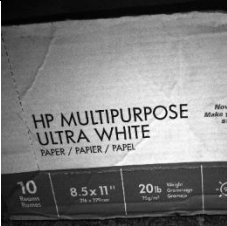
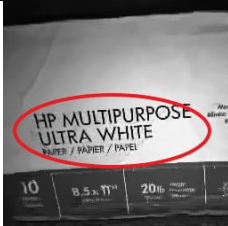

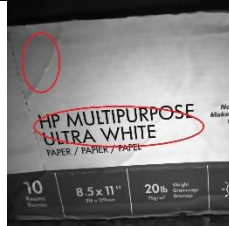
ชุดข้อมูลทดสอบ		
		
		
		
		


3.3.6 ผลการทดลองบนสัญญาณรบกวนภาพจริง

จากการทดสอบโมเดลของผู้วิจัยที่ทดสอบบนชุดข้อมูลที่ถูกรบกวนด้วยสัญญาณภาพจริง (สัญญาณรบกวนภาพที่อยู่ในสภาพแวดล้อมจริง) นั้นพบว่าโมเดลของผู้วิจัยสามารถลดสัญญาณ

รบกวนภาพจริงบนชุดข้อมูลทดสอบได้ โดยตัวอย่างภาพที่ถูกลดสัญญาณรบกวนภาพจริงด้วยโมเดล
ของผู้วิจัยจะแสดงดังตารางที่ 9

ตารางที่ 12 ผลการทดลองการลดสัญญาณรบกวนภาพจริงบนชุดข้อมูลทดสอบ

รูป ที่	ภาพที่มีสัญญาณ รบกวนภาพจริง	BM3D	DnCNN	โมเดลที่เสนอในส่วนที่ 3.3.4 (Canny + HED)
1				
2				
3				
4				
5				
6				



จากตารางที่ 9 การทดสอบบนชุดข้อมูลทดสอบที่ถูกบกรวนด้วยสัญญาณรบกวนภาพจริงนั้นพบว่าโมเดลของผู้วิจัยสามารถลดสัญญาณรบกวนภาพจริงบนชุดข้อมูลทดสอบได้ แต่ทว่าในส่วนพื้นที่หลังของภาพที่ถูกลดสัญญาณรบกวนภาพจริงนั้นจะถูกทำให้เบลอและสูญเสียรายละเอียดของพื้นที่หลังไป และเนื่องจากขาดชุดข้อมูลฝึกสอนที่เป็นชุดข้อมูลเฉลี่ยที่มีสัญญาณรบกวนภาพจริงจึงทำให้โมเดลของผู้วิจัยไม่สามารถประเมินประสิทธิภาพได้ เนื่องด้วยสาเหตุนี้จึงนำเสนอภาพผลลัพธ์ที่ถูกลดสัญญาณรบกวนภาพจริงมาแสดงในวิทยานิพนธ์นี้เท่านั้น

3.3.7 ผลการทดลองบนสัญญาณรบกวนภาพเกาส์เซียน

ผู้วิจัยได้ทดสอบประสิทธิภาพโมเดลของผู้วิจัยที่ได้นำเสนอขึ้นในส่วนที่ 3.3.4 (Canny + HED) เพื่อเปรียบเทียบประสิทธิภาพของการลดสัญญาณรบกวนภาพเกาส์เซียนกับโมเดลที่ถูกเสนอขึ้นในส่วนที่ 3.1 (Canny) สำหรับการฝึกสอนโมเดลจะฝึกสอนด้วย 2 วิธีดังนี้ 1) การฝึกสอนโมเดลของผู้วิจัยแบบแบ่งระดับความเข้มข้น 2) การฝึกสอนโมเดลของผู้วิจัยแบบลดระดับความเข้มข้น และพารามิเตอร์ในการฝึกสอนรวมทั้งชุดข้อมูลฝึกสอนและทดสอบจะใช้ชุดเดียวกันกับส่วนที่ 3.1 สำหรับ

ผลการทดลองบนสัญญาณรบกวนภาพเกาส์เซียนโดยใช้การฝึกสอนโมเดลของผู้วิจัยแบบแบ่งระดับความเข้มข้นที่ระดับความเข้มข้นของสัญญาณรบกวนภาพแบบเกาส์เซียน 15 ในชุดข้อมูลทดสอบ Set12 แสดงดังตารางที่ 10 ผลการทดลองบนสัญญาณรบกวนภาพเกาส์เซียนบนการฝึกสอนโมเดลของผู้วิจัยแบบแบ่งระดับความเข้มข้นที่ระดับความเข้มข้นของสัญญาณรบกวนภาพแบบเกาส์เซียน 25 ในชุดข้อมูลทดสอบ Set12 แสดงดังตารางที่ 11 ผลการทดลองบนสัญญาณรบกวนภาพเกาส์เซียนบนการฝึกสอนโมเดลของผู้วิจัยแบบแบ่งระดับความเข้มข้นที่ระดับความเข้มข้นของสัญญาณรบกวนภาพแบบเกาส์เซียน 50 ในชุดข้อมูลทดสอบ Set12 แสดงดังตารางที่ 12 ผลการทดลองบนสัญญาณรบกวนภาพเกาส์เซียนบนการฝึกสอนโมเดลของผู้วิจัยแบบแบ่งระดับความเข้มข้นในชุดข้อมูลทดสอบ BSD68 แสดงดังตารางที่ 13 สำหรับผลการทดลองบนสัญญาณรบกวนภาพเกาส์เซียนบนการฝึกสอนโมเดลของผู้วิจัยแบบลดระดับความเข้มข้นที่ระดับความเข้มข้นของสัญญาณรบกวนภาพแบบเกาส์เซียนที่ 15 25 และ 50 ในชุดข้อมูลทดสอบ Set12 แสดงดังตารางที่ 14 และผลการทดลองบนสัญญาณรบกวนภาพเกาส์เซียนบนการฝึกสอนโมเดลของผู้วิจัยแบบลดระดับความเข้มข้นที่ระดับความเข้มข้นของสัญญาณรบกวนภาพแบบเกาส์เซียนที่ 15 25 และ 50 ในชุดข้อมูลทดสอบ BSD68 แสดงดังตารางที่ 15

ตารางที่ 13 ตารางเปรียบเทียบประสิทธิภาพในการลดสัญญาณรบกวนภาพเกาส์เซียนในระดัความเข้มข้นที่ 15 ซึ่งวัดในรูปแบบค่า MS-SSIM โดยตัวหนาคือผลลัพธ์ที่ดีที่สุด

Method ($\sigma = 15$)	BM3D	DnCNN	โมเดลของผู้วิจัยที่ เสนอ (Canny)	โมเดลของผู้วิจัยที่ เสนอ (Canny + HED)
Monarch	0.886	0.911	0.965	0.969
Boat	0.770	0.889	0.886	0.895
Airplane	0.834	0.937	0.920	0.942
Starfish	0.802	0.940	0.941	0.945
House	0.846	0.959	0.894	0.902
Lena	0.846	0.916	0.913	0.918

Parrot	0.839	0.925	0.903	0.927
Camera man	0.831	0.910	0.919	0.923
Man	0.837	0.930	0.923	0.932
Barbara	0.849	0.886	0.933	0.937
Peppers	0.855	0.903	0.940	0.941
Couple	0.752	0.903	0.904	0.906
Average	0.872	0.917	0.920	0.927

ตารางที่ 14 ตารางเปรียบเทียบประสิทธิภาพในการลดสัญญาณรบกวนภาพเกาส์เซียนสีในระดับความเข้มขั้นที่ 25 ซึ่งวัดในรูปแบบค่า MS-SSIM โดยตัวหนาคือผลลัพธ์ที่ดีที่สุด

Method ($\sigma = 25$)	BM3D	DnCNN	โมเดลของผู้วิจัยที่ เสนอ (Canny)	โมเดลของผู้วิจัยที่ เสนอ (Canny + HED)
Monarch	0.846	0.942	0.852	0.856
Boat	0.728	0.840	0.857	0.860
Airplane	0.771	0.894	0.872	0.874
Starfish	0.770	0.900	0.912	0.915
House	0.734	0.874	0.889	0.892
Lena	0.774	0.885	0.890	0.891
Parrot	0.771	0.852	0.839	0.841
Camera man	0.739	0.881	0.879	0.879

Man	0.775	0.891	0.895	0.897
Barbara	0.810	0.897	0.900	0.902
Peppers	0.811	0.909	0.941	0.942
Couple	0.711	0.857	0.884	0.886
Average	0.770	0.885	0.884	0.886

ตารางที่ 15 ตารางเปรียบเทียบประสิทธิภาพในการลดสัญญาณรบกวนภาพเกาส์เซียนสีในระดับความเข้มขั้นที่ 50 ซึ่งวัดในรูปแบบค่า MS-SSIM โดยตัวหนาคือผลลัพธ์ที่ดีที่สุด

Method ($\sigma = 50$)	BM3D	DnCNN	โมเดลของผู้วิจัยที่ เสนอ (Canny)	โมเดลของผู้วิจัยที่ เสนอ (Canny + HED)
Monarch	0.724	0.886	0.795	0.796
Boat	0.571	0.739	0.816	0.817
Airplane	0.623	0.826	0.843	0.846
Starfish	0.645	0.807	0.810	0.813
House	0.583	0.831	0.876	0.877
Lena	0.619	0.825	0.818	0.819
Parrot	0.633	0.743	0.813	0.814
Camera man	0.577	0.805	0.812	0.815
Man	0.633	0.824	0.792	0.794
Barbara	0.637	0.800	0.736	0.738
Peppers	0.675	0.847	0.737	0.738

Couple	0.569	0.754	0.752	0.756
Average	0.724	0.806	0.800	0.801

ตารางที่ 16 ตารางผลการทดสอบบนชุดข้อมูลทดสอบ BSD68 ซึ่งวัดในรูปแบบค่าเฉลี่ยของมาตรวัด MS-SSIM โดยตัวหนาคือผลลัพธ์ที่ดีที่สุด

Method	BM3D	DnCNN	โมเดลของผู้วิจัยที่ เสนอ (Canny)	โมเดลของผู้วิจัยที่ เสนอ (Canny + HED)
$\sigma = 15$	0.872	0.890	0.906	0.908
$\sigma = 25$	0.801	0.885	0.884	0.887
$\sigma = 50$	0.686	0.746	0.740	0.741

ตารางที่ 17 ตารางเปรียบเทียบประสิทธิภาพระหว่างโมเดลของผู้วิจัยที่เสนอ Canny กับ Canny + HED โดยฝึกสอนแบบลดระดับความเข้มข้นของสัญญาณรบกวนภาพเกาส์เซียนในชุดข้อมูลทดสอบ Set12

ชื่อรูปภาพ (ระดับความเข้มข้นของสัญญาณรบกวน ภาพแบบเกาส์เซียนในข้อมูลทดสอบ)	โมเดลของผู้วิจัยที่ เสนอ (Canny)	โมเดลของผู้วิจัยที่เสนอ (Canny + HED)
Monarch (15)	0.772	0.774
Boat (15)	0.803	0.807
Airplane (15)	0.814	0.816
Starfish (15)	0.763	0.766
House (25)	0.854	0.857

Lena (25)	0.785	0.788
Parrot (25)	0.788	0.791
Camera man (25)	0.794	0.796
Man (50)	0.730	0.731
Barbara (50)	0.740	0.741
Peppers (50)	0.743	0.744
Couple (50)	0.754	0.756
Average	0.778	0.780

ตารางที่ 18 ตารางเปรียบเทียบประสิทธิภาพระหว่างโมเดลของผู้วิจัยที่เสนอ Canny กับ Canny + HED โดยฝึกสอนแบบลดระดับความเข้มข้นของสัญญาณรบกวนภาพเกาส์เขียนในชุดข้อมูลทดสอบ BSD68

ชื่อชุดข้อมูล	โมเดลของผู้วิจัยที่เสนอ (Canny)	โมเดลของผู้วิจัยที่เสนอ (Canny + HED)
BSD68	0.735	0.737

บทที่ 4

สรุปผลการดำเนินวิจัย

4.1 สรุปผลการวิจัย

จากการทดลองในการลดสัญญาณรบกวนภาพแบบเกาส์เซียนด้วยโมเดลของผู้วิจัยที่นำเสนอในบทที่ 3.3.4 (Canny + HED) ด้วยวิธีฝึกสอนแบบแบ่งระดับความเข้มข้นของสัญญาณรบกวนภาพแบบเกาส์เซียนพบว่าสามารถทำประสิทธิภาพได้ดีกว่าโมเดลของผู้วิจัยที่นำเสนอในบทที่ 3.1 (Canny) และอัลกอริทึมอื่นบนระดับความเข้มข้นของสัญญาณรบกวนภาพแบบเกาส์เซียนที่ 15 25 ซึ่งแสดงให้เห็นถึงความสำคัญของเส้นแบ่งระหว่างวัตถุของภาพที่ได้จากอัลกอริทึมแคนนี เอ็จ ดีเท็กชันและโมเดล HED ต่อการลดสัญญาณรบกวนภาพแบบเกาส์เซียน แต่บนระดับความเข้มข้นของสัญญาณรบกวนภาพแบบเกาส์เซียนที่ 50 พบว่าสัญญาณรบกวนภาพแบบเกาส์เซียนส่งผลกระทบต่อโมเดลของผู้วิจัยที่นำเสนอในบทที่ 3.3.4 (Canny + HED) โดยจากตารางที่ 12 แสดงให้เห็นประสิทธิภาพของโมเดลของผู้วิจัยที่นำเสนอในบทที่ 3.3.4 (Canny + HED) ไม่สามารถทำประสิทธิภาพได้เทียบเท่าอัลกอริทึม DnCNN และแสดงให้เห็นว่าสัญญาณรบกวนภาพแบบเกาส์เซียนที่มีระดับความเข้มข้นสูงส่งผลกระทบต่ออัลกอริทึมหรือโมเดลสำหรับหาเส้นแบ่งระหว่างวัตถุกับภาพพื้นหลัง

จากการทดลองในการลดสัญญาณรบกวนภาพแบบเกาส์เซียนด้วยโมเดลของผู้วิจัยที่นำเสนอในบทที่ 3.3.4 (Canny + HED) ด้วยวิธีฝึกสอนแบบลดระดับความเข้มข้นของสัญญาณรบกวนภาพแบบเกาส์เซียนพบว่าโมเดลของผู้วิจัยที่นำเสนอในบทที่ 3.3.4 (Canny + HED) ได้ประสิทธิภาพที่ดีกว่าโมเดลของผู้วิจัยที่นำเสนอในบทที่ 3.1 (Canny) ซึ่งแสดงให้เห็นถึงความสำคัญของเส้นแบ่งระหว่างวัตถุของภาพที่ได้จากอัลกอริทึมแคนนี เอ็จ ดีเท็กชันและโมเดล HED ต่อการลดสัญญาณรบกวนภาพแบบเกาส์เซียนอีกเช่นเดียวกัน แต่ในชุดตัวอย่างทดสอบบางภาพที่มีสัญญาณรบกวนภาพแบบเกาส์เซียนที่มีระดับความเข้มข้นสูงจะยังทำประสิทธิภาพได้ไม่ดีเนื่องจากเหตุผลที่กล่าวไปข้างต้นเช่นเดียวกัน

จากการทดลองในการลดสัญญาณรบกวนภาพจริงด้วยโมเดลที่ผู้วิจัยเสนอในบทที่ 3.3.4 (Canny + HED) เมื่อเปรียบเทียบกับอัลกอริทึม BM3D และDnCNN พบว่าภาพที่ถูกลดสัญญาณรบกวนจริงที่ได้จากโมเดลของผู้วิจัยนั้นมีความคมชัดกว่าอัลกอริทึมอื่นทั้งในส่วนของพื้นหลังภาพและรายละเอียดต่าง ๆ ของภาพ แต่ทว่าบางส่วนของภาพยังเบลอซึ่งอาจเกิดจากโมเดลของผู้วิจัยนั้นไม่ได้ฝึกสอนกับชุดข้อมูลฝึกสอนที่ถูกรบกวนด้วยสัญญาณรบกวนภาพจริงเนื่องจากขาดข้อมูลเฉลย จึงไปฝึกสอนกับ

ชุดข้อมูลฝึกสอนที่ถูกครอบด้วยสัญญาณรบกวนภาพเกาส์เขียนแทน ด้วยสาเหตุนี้จึงทำให้โมเดลของผู้วิจัยไม่สามารถทำประสิทธิภาพที่ดี

4.2 แนวทางวิจัยในขั้นถัดไป

ผู้วิจัยคาดหวังว่าถ้ามีชุดข้อมูลฝึกสอนที่ถูกครอบด้วยสัญญาณรบกวนภาพจริงพร้อมเฉลยโมเดลของผู้วิจัยที่เสนอในบทที่ 3.3.4 (Canny + HED) จะสามารถลดสัญญาณรบกวนภาพจริงได้และประเมินประสิทธิภาพของโมเดลนี้ได้ อีกทั้งยังเป็นการพัฒนาแนวทางวิจัยสำหรับการลดสัญญาณรบกวนภาพจริงด้วยการเรียนรู้เชิงลึกให้ก้าวไปข้างหน้าได้ และนำไปประยุกต์ใช้กับการทดลองในชุดข้อมูลฝึกสอนภาพสีและชุดข้อมูลทดสอบภาพสี



บรรณานุกรม

1. Buades, A., Coll, B., Morel, J.-M.: A non-local algorithm for image denoising. In: Computer Vision and Pattern Recognition. CVPR 2005. IEEE Computer Society Conference on, pp. 60-65. IEEE, (2005)
2. Dabov, K., Foi, A., Katkovnik, V., Egiazarian, K.: Image denoising by sparse 3-D transform-domain collaborative filtering. IEEE Transactions on image processing 16, 2080-2095 (2007)
3. Rudin, L.I., Osher, S., Fatemi, E.: Nonlinear total variation based noise removal algorithms. Physica D: nonlinear phenomena 60, 259-268 (1992)
4. Osher, S., Burger, M., Goldfarb, D., Xu, J., Yin, W.: An iterative regularization method for total variation-based image restoration. Multiscale Modeling & Simulation 4, 460-489 (2005)
5. Weiss, Y., Freeman, W.T.: What makes a good model of natural images? In: IEEE Conference on Computer Vision and Pattern Recognition, pp. 1-8. IEEE, (2007)
6. Burger, H.C., Schuler, C.J., Harmeling, S.: Image denoising: Can plain neural networks compete with BM3D? In: Computer Vision and Pattern Recognition (CVPR), IEEE Conference on, pp. 2392-2399. IEEE, (2012)
7. Wang, Z., Simoncelli, E.P., Bovik, A.C.: Multiscale structural similarity for image quality assessment. In: The Thirty-Seventh Asilomar Conference on Signals, Systems & Computers,, pp. 1398-1402. IEEE, (2003)
8. Simonyan, K., Zisserman, A.: Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556 (2014)
9. Gu, S., Zhang, L., Zuo, W., Feng, X.: Weighted nuclear norm minimization with application to image denoising. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. 2862-2869. (2014)
10. Recht, B., Fazel, M., Parrilo, P.A.J.S.r.: Guaranteed minimum-rank solutions of linear matrix equations via nuclear norm minimization. 52, 471-501 (2010)

11. Zhang, K.a.Z., Wangmeng and Chen, Yunjin and Meng, Deyu and Zhang, Lei: Beyond a Gaussian denoiser: Residual learning of deep {CNN} for image denoising. IEEE Transactions on Image Processing 26, 3142-3155 (2017)
12. Ioffe, S., Szegedy, C.: Batch normalization: Accelerating deep network training by reducing internal covariate shift. arXiv preprint arXiv:1502.03167 (2015)
13. Ren, S., He, K., Girshick, R., Sun, J.: Faster r-cnn: Towards real-time object detection with region proposal networks. In: Advances in neural information processing systems, pp. 91-99. (2015)
14. Chen, L.-C., Papandreou, G., Kokkinos, I., Murphy, K., Yuille, A.L.: Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs. IEEE transactions on pattern analysis and machine intelligence 40, 834-848 (2018)
15. He, K., Zhang, X., Ren, S., Sun, J.: Identity mappings in deep residual networks. In: European conference on computer vision, pp. 630-645. Springer, (2016)
16. Canny, J.: A computational approach to edge detection. Readings in computer vision, pp. 184-203. Elsevier (1987)
17. Kobayashi, T.: Analyzing Filters Toward Efficient ConvNet. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. 5619-5628 (2018)
18. Li, Y., Yuan, Y.: Convergence analysis of two-layer neural networks with relu activation. In: Advances in Neural Information Processing Systems, pp. 597-607. (2017)
19. Glorot, X., Bengio, Y.: Understanding the difficulty of training deep feedforward neural networks. In: Proceedings of the thirteenth international conference on artificial intelligence and statistics, pp. 249-256. (2010)
20. Xie, S., Tu, Z.: Holistically-nested edge detection. In: Proceedings of the IEEE international conference on computer vision, pp. 1395-1403. (2015)



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

ประวัติผู้เขียน

ชื่อ-สกุล	ศุภกร ชูประภาวรรณ
วัน เดือน ปี เกิด	26 ตุลาคม 2537
สถานที่เกิด	ขอนแก่น
วุฒิการศึกษา	สำเร็จการศึกษาปริญญาวิทยาศาสตรบัณฑิต สาขาเทคโนโลยีสารสนเทศ และการสื่อสาร ภาควิชาวิทยาการคอมพิวเตอร์ มหาวิทยาลัยขอนแก่นในปี การศึกษา 2560 และเข้าศึกษาหลักสูตรวิทยาศาสตรมหาบัณฑิต สาขาวิชา วิทยาศาสตร์คอมพิวเตอร์ ภาควิชาวิศวกรรมคอมพิวเตอร์ คณะ วิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย ในปีการศึกษา 2560 ภาค การศึกษาด้าน
ที่อยู่ปัจจุบัน	ไทยเรสซิเดนซ์ อพาร์ทเมนท์ เลขที่ 222 ห้อง204 ถนนวิภาวดี22 แขวง จอมพล เขตจตุจักร กรุงเทพมหานคร 10900
ผลงานตีพิมพ์	Chupraphawan, S., & Ratanamahatana, C. A. (2019, July). Deep Convolutional Neural Network with Edge Feature for Image Denoising. In International Conference on Computing and Information Technology (pp. 169-179). Springer, Cham. The international conference was located at Arnoma Grand hotel, 99 Ratchadamri Rd, Khwaeng Lumpini, Khet Pathum Wan, Bangkok, Thailand Conference website: https://ic2it.org/